

**Szegedi Tudományegyetem**

Szent-Györgyi Albert Orvostudományi Kar  
Elméleti Orvostudományok Doktori Iskola

**Eltérő összetettségű képi asszociációs  
egyenértékűségi tanulások EEG jeleinek  
összehasonlítása gépi tanulással**

Tézisfüzet

Kiss Ádám

Témavezetők:

Dr. habil. Nagy Attila – egyetemi docens

Dr. Kelemen András – főiskolai docens

Szeged

2025

## Disszertációhoz kötődő publikációk

1. Á. Kiss, K. Tót, N. Harcsa-Pintér és tsai., „Machine Learning Analysis of Cortical Activity in Visual Associative Learning Tasks with Differing Stimulus Complexity”, *Physiology International*, 2025, ISSN: 2498-602X. cím: <https://m2.mtmt.hu/api/publication/35759496>
2. Á. Kiss, O. M. Huszár, B. Bodosi és tsai., „Automated preprocessing of 64 channel electroencephalograms recorded by biosemi instruments”, *MethodsX*, 11. évf., 102378. old., 2023. dec., ISSN: 2215-0161. DOI: 10.1016/j.mex.2023.102378. cím: <http://dx.doi.org/10.1016/j.mex.2023.102378>

## 1. Kivonat

Ez a dolgozat az asszociatív tanulás neurális alapjait vizsgálja EEG és gépi tanulás alkalmazásával. Az elemzés összehasonlítja a hagyományos Rutgers-féle Szerzett Egyenértékűség Tesztet (RAET) egy leegyszerűsített változatával, a Polygon teszttel, hogy meghatározza, miként befolyásolja az inger összetettsége a tanulást. Az EEG-adatokat Független Komponens Analízissel dolgoztuk fel, majd LSTM-hálózatok és Support Vector Classification algoritmus segítségével elemeztük az agyfelszín kulcsfontosságú területein. Az eredmények azt mutatják, hogy a homloklebeny a legérzékenyebb a feladatok közötti különbségekre, míg a fali lebenyben minimális változás figyelhető meg. Bár a mintaszám korlátozott volt, a tanulmány rávilágít ezen technikák potenciáljára a kognitív folyamatok mélyebb megértésében.

## Rövidítésjegyzék

**EEG** Elektroencefalográfia

**fMRI** Funkcionális mágneses rezonanciavizsgálat

**ICA** Independent Component Analysis

**LSTM** Long Short-Term Memory

**ML** Gépi tanulás

**RAET** Rutgers szerzett egyenértékűség teszt

**SVC** Support Vector Classification

## 2. Bevezetés

Az asszociatív tanulás lehetővé teszi az élőlények számára, hogy előre jelezzenek eseményeket és reagáljanak az ingerekre, ezzel elősegítve az alkalmazkodásukat. Ez a dolgozat a szerzett egyenértékűség tanulásra összpontosít, amely során az asszociációk láncolatai nagyobb csoportokat alkotnak. Catherine Mayers és munkatársai a Rutgers Egyetemen hal- és arcingereket alkalmazva fejlesztették ki azt a generalizációs lépést tartalmazó módszert, amelyet később RAET<sup>1</sup> tesztként neveztek el. Eredményeik azt sugallják, hogy a hippokampusz működése kulcsfontosságú az asszociatív tanulás generalizáció részében, és jelentős különbségek figyelhetők meg az egészséges egyének és a Parkinson-kóros betegek között.

Az a kérdés, hogy az agy mely területei vesznek részt az egyenértékűség-tanulásban, a felidézési vagy generalizációs lépésekben, alapvető jelentőségű, bár a válasz összetett.

Az fMRI<sup>2</sup> eredmények azt mutatják, hogy mind a középső halánték-lebény, mind a caudatus mag aktív az asszociatív feladatok során, míg az EEG<sup>3</sup> eredmények a figyelem és a döntéshozatal szerepét hangsúlyozzák — különösen a Brodmann 11-es területen — a tanulási alatt. Emellett a vizuális ingerek összetettsége is befolyásolja a tanulást, mivel a gazdagabb vizuális támpontok vagy a könnyebb verbalizáció összetettebb agyi folyamatokat mozgósíthat. Ennek vizsgálatára a RAET teszt különböző változatait, például a Polygon tesztet fejlesztették ki.

A RAET és a legtöbb hasonló teszt két fő szakaszból áll. Az elsőt gyakran tanulási szakasznak nevezik, míg a másodikat tesztfázisként jelölik. A tesztfázis a visszaidézési és a generalizációs feladatokat ötvözi. A visszaidézés során az explicit memória teljesítményét mérjük a tanulási szakaszban bemutatott párokkal. A generalizáció során pedig a kitöltő személy asszociációs transzfer képességeit mérjük.

---

<sup>1</sup>Rutgers szerzett egyenértékűség teszt

<sup>2</sup>Funkcionális mágneses rezonanciavizsgálat

<sup>3</sup>Elektroencefalográfia

### 3. Célkitűzések

Számos kognitív teljesítménybeli különbség figyelhető meg RAET-szerű tesztek során különböző csoportok között, azonban ezek elektrofiziológiai vetülete nagyrészt feltáratlan maradt.

Célunk az volt, hogy meghatározzuk, miként befolyásolja a vizuális ingerek összetettsége az agykérgi aktivitást az asszociatív tanulás során. Különösen az EEG által kimutatható, megkülönböztethető korrelátumokat kívántuk azonosítani a két teszt esetében.

A dolgozatban bemutatott kutatás átfogó célja olyan módszerek, algoritmusok és szoftverkomponensek fejlesztése volt, amelyek lehetővé teszik a többcsatornás EEG jelek kiértékelését asszociatív tanulási tesztek során.

A pontos célkitűzések a következők voltak:

- egy önműködő EEG előfeldolgozási rendszer kifejlesztése, amely magában foglalja az izomaktivitás műtermékének észlelését és megjelölését.
- a gépi tanulás alkalmazhatóságának vizsgálata az agykérgi aktivitás elemzésére olyan vizuális asszociatív tanulási feladatokban, amelyek eltérő összetettségű ingereket használnak.
- a fent említett módszereket használva a RAET és a Polygon tesztek összehasonlítása az agykérgi aktivitás szempontjából.

## 4. Módszerek

### 4.1. Önkéntesek

A vizsgálat megfelelt a Helsinkai Nyilatkozat alapelveinek, és a Szegedi Tudományegyetem Regionális Orvostudományi Kutatásetikai Bizottsága jóváhagyta (27/2020-SZTE). A részvétel teljes mértékben önkéntes és díjazás nélküli volt. Az önkénteseket a szerzők személyes hálózatán keresztül toboroztuk, és teljes körű tájékoztatást kaptak a vizsgálat céljairól és eljárásairól. Biztosítottuk őket arról is, hogy a részvétel önkéntes, és bármikor következmények nélkül visszavonható. Azok, akik vállalták a részvételt, tájékoztató és beleegyező nyilatkozatot írtak alá.

Összesen 32 fő jelentkezett a vizsgálatra, és mindegyikük megfelelt a részvételi feltételeknek. Azonban rögzítési hibák miatt végül csak 26 résztvevő (14 férfi és 12 nő) adatait elemeztük. A résztvevők átlagéletkora 23,81 év volt, szórása pedig 5,33 év.

### 4.2. Vizsgálati eljárás

Mind a RAET, mind a Polygon teszt két fő szakaszból áll: a tanulási és a tesztfázisból, amelyek több próbából tevődnek össze. Minden próbában a résztvevő feladata egy előzetes inger

párosítása egy következményingerrel.

A döntés mindvégig saját tempóban zajlik, így a résztvevők időnyomás nélkül válaszolhatnak. A válasz megadása gombnyomással történik, amit a tanulási fázis során egy másodpercnyi visszajelzés követ. Ez a szekvencia ismétlődik a tesztfázisig, ahol már nem adunk visszajelzést, azonban minden más változatlan marad.

Az EEG hullámformák rögzítése párhuzamosan történt a RAET és a Polygon tesztekkel egy 64 csatornás Biosemi Active Two készülékkel, 2048 Hz-es mintavételezéssel. Ez a rendszer magas közös-módusú elnyomással rendelkezik, amely szükségtelenné tette egy árnyékoló mérőszoba használatát.

Az elektródasapka és az elektródák elhelyezése minden felvétel során egységes volt, a tesztelés közben megszakítás nem történt. Az eszköz belső szűrője aluláteresztő karakterisztikát mutatott, 410 Hz-es vágási frekvenciával. Az elektródaelrendezés a nemzetközi 10-10 rendszerre épülő szokásos Biosemi 64 csatornás konfigurációt követte.

### 4.3. Független Komponens Analízis

Az egyik legelterjedtebb modern forrás-szeparációs módszer az ICA<sup>4</sup>, melynek legismertebb implementációja a FastICA algoritmus. Az ICA alkalmazásának eredményeként független összetevőket kapunk, ahol minden csatorna egyedi súlyokkal rendelkezik. Az ICA transzformáció visszafordításához csatornánként ezen összetevők egyszerű súlyozott összegzését kell elvégezni.

### 4.4. Gépi tanulás alkalmazása EEG vizsgálatokban

Ebben a vizsgálatban a ML<sup>5</sup> segítségével elemeztük, hogy az agy bizonyos részei eltérő aktivitást mutatnak-e a RAET és a Polygon teszt kitöltése során. Ha a mesterséges intelligencia képes mintázatokat tanulni és felismerni egy adott hullámformából a teszt típusát, akkor állíthatjuk, hogy eltérések figyelhetők meg közöttük.

Az alábbi osztályozási algoritmusokat alkalmaztuk. Bár csak két különböző gépi tanulási algoritmust használtunk, a jellemzők kiválasztásának különbségei miatt összességében négy különálló modell készült. Időtartománybeli nyers jeleken az LSTM<sup>6</sup> és az SVC<sup>7</sup> került alkalmazásra. Ezenkívül két további SVC modellt is tanítottunk és értékeltünk, amelyek a feladatokhoz kapcsolódó jelalakok Fourier-spektrumából származó jellemzőket használták.

Minden osztályozást tíz különböző tanítási-tesztelési adathalmazon végeztünk, ahol a tesztadatok az elérhető adatok 20 százalékát tették ki. Az egyes önkéntesek esetében elemeztük a modell pontosságának eloszlását, hogy becsüljük a RAET és a Polygon tesztek közötti meg-

<sup>4</sup>Independent Component Analysis

<sup>5</sup>Gépi tanulás

<sup>6</sup>Long Short-Term Memory

<sup>7</sup>Support Vector Classification

különböztetés mértékét. Amennyiben bármelyik módszer átlagos pontossága meghaladta a 90 százalékot, az adott ICA komponenszt ábrázoltuk és elmentettük.

## 5. Eredmények

### 5.1. Kétoldali referencia algoritmus

A kifejlesztett EEG referencia algoritmus jobb teljesítményt nyújtott, mint a hagyományos átlagérték-referencia. A javasolt izomaktivitás-detektor támaszkodik ezen a kétoldali referencia módszerre [2].

Azonban az ICA megszüntette a referencia szükségességét, így az algoritmust végül nem alkalmaztuk a tényleges értékelés során [1].

### 5.2. Izomműtermék-jelölő algoritmus

Az EEG jelek izomműtermék-tartalmú szakaszainak elemzése során, a Welch-algoritmus alkalmazásával, 350 és 650 Hz között szélessávú teljesítménynövekedést figyeltünk meg.

Az izomműtermék-domináns szakaszokat automatikusan azonosítottuk. Négy kutató függetlenül validálta a módszert, és megerősítette, hogy az algoritmus által azonosított szakaszok egybeestek az általuk manuálisan kijelölt területekkel [2].

### 5.3. Értékelési protokoll

Sikeresen implementáltunk és publikáltunk egy gépi tanulási protokollt a RAET és a Polygon tesztek összehasonlítására [1].

### 5.4. ML által azonosított EEG eltérések a RAET és a Polygon tesztek között

A felsorolt módszereket alkalmazva ábrákat készítettünk minden résztvevő komponenséről, amennyiben bármely osztályozási stratégia pontossága meghaladta a 90 százalékot.

Összesen 32 résztvevőtől rögzítettünk EEG adatokat, akik mind a RAET, mind a Polygon tesztek elvégezték. Hatot azonban kizártunk az elemzésből adatkonzisztencia-problémák, túlzott zaj vagy elégtelen számú értékelhető szaksz miatt. További egy felvételt figyelmen kívül hagytunk a magas műterméktartalom miatt. Ezek után részletes elemzést végeztünk a megmaradt 25 résztvevő EEG adataival.

Az adatok azt mutatják, hogy a homloklebény reagált leginkább különbözően a RAET és a Polygon tesztek között. Ezzel szemben a fali régió a tesztfázis során mutatta a legkisebb mértékű megkülönböztethetőséget [1].

## 6. Megbeszélés

### 6.1. Izomműtermék-jelölő algoritmus

Érdeemes kiemelni, hogy az EEG vágási frekvenciája feletti jel detektálása arra utalhat, hogy a bemeneti jelek elég erősek voltak ahhoz, hogy áthaladjanak az eszköz hardveres szűrőjén, amely 410 Hz feletti frekvenciákat csillapít. Ez a jelenség keresztmoduláció vagy túlvezérlés jelenlétére utalhat. Amikor az EEG eszköz egy rádióadó, például egy mobiltelefon által túlvezérlődött, a spektrális teljesítmény növekedett az érintett frekvenciasávokban is, és az így keletkezett zajos szakaszokat az algoritmus módosítás vagy bővítés nélkül eltávolította. Egy másik megfigyelés szerint a résztvevő köhögése is műtermékeket generált, amelyeket az algoritmus szintén sikeresen azonosított és megjelölt.

### 6.2. Kétoldali közös-módus eltávolítás

Kifejlesztettünk egy kétoldali referenciáló algoritmust. A módszer lényege, hogy az adott műszerkábelekhez számítunk egy-egy átlagos referenciát. Azonban mivel az ICA – mely az elemzés központi eleme – nem igényel referenciát, az algoritmust végül közvetlen nem használtuk fel.

### 6.3. A RAET és a Polygon tesztek összehasonlítása

Tudomásunk szerint ez az első tanulmány, amely EEG jeleket és ML-t alkalmaz két, a vizuális inger összetettségében és megfogalmazhatóságában eltérő, asszociatív egyenértékűség-tanulási feladat (RAET és Polygon) megkülönböztetésére. Az itt bemutatott eredmények lehetővé teszik az agykérgi aktivitás közvetlen összehasonlítását az eredeti RAET és az egyszerűsített Polygon teszt között.

Jól ismert, hogy a törzsdúcok motoros és szenzomotoros funkcióikon túl kiemelt szerepet játszanak a kognitív feladatokban és számos memóriafolyamatban. Azonban a törzsdúcok aktivitása EEG-vel közvetlenül nem mérhető; csupán az agyi hálózatokon keresztül agykérgen tükröződő közvetett aktivitás figyelhető meg. A funkcionális mágneses rezonancia képalkotás (fMRI) alkalmas a mélyebb agyi struktúrák specifikus szerepeinek vizsgálatára: az fMRI a vér oxigenizációs szintjének változását mérve becsüli az agyi aktivitást. Számos fMRI-vizsgálat elemzett már kognitív feladatokat, és ennek az alkalmazása segíthet megválaszolni, hogy a RAET és a Polygon tesztek eltérő agyi hálózatokat aktiválnak-e. E hálózatok összehasonlítása fontos következő lépést jelenthet ezen kutatási területen.

Vizsgálatunkban a 25 értékelt résztvevő közül 24 (96%) EEG-jelei eltéréseket mutattak a RAET és a Polygon tesztek között. Ezek az eltérések elsősorban az elülső régióban jelentkeztek, és leginkább a tanulási fázis során voltak kifejezettek. Időbeli átfedés miatt nem zárható ki, hogy ezek az eltérések részben az előző feladatból származó memorizációs folyamatokat is

tükrözik.

A homloklebeny aktivitása végrehajtó funkciókkal, figyelemmel és a munkamemória terhelésével hozható összefüggésbe. A két teszt közötti elsődleges különbség az ingerek komplexitásában rejlik, különösen azok szemantikai tartalmában és megfogalmazhatóságában. A homloklebeny fölött mért agykérgi aktivitás eltérései figyelmi különbségekből is eredhetnek, amelyek befolyásolhatják a döntéshozatali folyamatokat. Ezek a különbségek különböző tanulási stratégiákból, például explicit és implicit megközelítésekben adódhatnak, beleértve a rejtett megfogalmazásokat is. A jövőbeli kutatásoknak érdemes lenne felmérni a résztvevők tanulási módszereit ezen eltérések pontosabb megértése érdekében.

A halántéklebeny aktivitása, amely az információfeldolgozásban, a nyelvi megértésben és a memóriában játszik szerepet, szintén függhet a megfogalmazáshoz kötődő folyamatoktól, különösen verbalizált tanulás esetén. A későbbi kísérletekben utólagos kérdőívek alkalmazása segíthet e lehetséges zavaró tényező utólagos figyelembevételében. Ha a verbalizáció hatással van a halántéklebeny aktivitására, az azt sugallhatja, hogy a verbalizáció folyamata eltér a két teszt között. Mivel ezek a különbségek leginkább a tanulási fázis során jelentkeztek, valószínűsíthető, hogy a két esetben eltérő tanulási mechanizmusok működnek.

A nyakszirti lebeny elsősorban a vizuális információk feldolgozásában játszik szerepet, beleértve az olyan összetettebb funkciókat, mint az arcfelismerés és a színek meghatározása. Ezen kívül hozzájárul a munkamemóriához és a tárgyfelismeréshez, valamint funkcionális kapcsolatban áll a homloklebeny aktivitásával. Bár ez a régió kevesebb eltérést mutatott a homloklebenyhez képest, az inger-megjelenés és a gombnyomás események között nagyobb változékonyság figyelhető meg, ami arra utal, hogy ez a terület vizuális és motoros feldolgozásban is részt vehet.

Ezzel szemben a fali lebeny minimális eltéréseket mutatott a RAET és a Polygon tesztek között. Ez arra utalhat, hogy a fali lebeny szerepe vagy elhanyagolható a tanulási és visszakeresési folyamatokban, vagy független az inger komplexitásától és verbalizálhatóságától.

Végezetül meg kell említenünk ezen ML-alapú eredményeink fő korlátait. A tanulmány elsődleges korlátja a kis mintaszám. Mindazonáltal ennek az adathalmaznak az elemzése megmutatta, hogy a mesterséges intelligencia képes kimutatni az asszociatív tanulási feladatokban az ingerkomplexitáshoz és verbalizálhatósághoz kapcsolódó agykérgi aktivitási mintázatokat egészséges résztvevők esetében. Az EEG-adatok további biomatematikai elemzése szükséges ezen agykérgi különbségek pontosabb azonosításához, amely hozzájárulhat az érintett neurális mechanizmusok mélyebb megértéséhez.

## 7. Összegzés

Ez a dolgozat az asszociatív tanulás mögöttes neurális mechanizmusait vizsgálja EEG<sup>8</sup> és ML<sup>9</sup> technikák alkalmazásával. Az asszociatív tanulás egy alapvető kognitív folyamat, amely során az egyének kapcsolatokat alakítanak ki ingerek és válaszok között. A vizsgálat két különböző feladatot – az eredeti RAET<sup>10</sup> tesztet és egy leegyszerűsített, Polygon nevű változatát – hasonlít össze annak érdekében, hogy feltárja, hogyan befolyásolja az inger komplexitása az agykérgi aktivitást.

Az általunk kifejlesztett új automatikus módszer versenyképes alternatívát kínál az izom-műtermékek megjelölésére az EEG felvételeken.

Az ML osztályozók, például az LSTM<sup>11</sup> hálózatok és az SVC<sup>12</sup>, a RAET és a Polygon tesztek közötti agyi aktivitásbeli eltérések azonosítására használtuk. Az elemzés különböző agykérgi területekre összpontosít, beleértve a homlok, halánték-, nyakszirti és fali lebenyt, azaz a céllal, hogy feltárja, ezek a területek eltérően reagálnak-e az inger komplexitásának és verbalizálhatóságának különböző szintjeire.

Az eredmények alapján az ML alkalmas módszernek bizonyult az olyan EEG vizsgálatok értékelésére, amelyek hasonló, de nem teljesen azonos ismétlésekből állnak.

További kulcsfontosságú megállapításunk szerint a homloklebeny a legtöbb, míg a fali lebeny a legkevesebb eltérést mutatta a két teszt között. Bár a mintaszám korlátozott, a tanulmány igazolta, hogy az EEG és az ML képes agykérgi aktivitási mintázatokat feltárni, és alapot biztosít a további asszociatív tanulási és kognitív idegtudományi kutatásokhoz.

Ez a munka hozzájárul az EEG jelanalízis módszereinek fejlesztéséhez, és hangsúlyozza az elektrofiziológiai adatok és a gépi tanulás kombinációjának fontosságát a kognitív folyamatok jobb megértésében.

---

<sup>8</sup>Elektroencefalográfia

<sup>9</sup>Gépi tanulás

<sup>10</sup>Rutgers szerzett egyenértékűség teszt

<sup>11</sup>Long Short-Term Memory

<sup>12</sup>Support Vector Classification

## 8. Köszönetnyilvánítás

Mindenekelőtt szeretném kifejezni őszinte hálámat témavezetőimnek, Dr. habil. Nagy Attila egyetemi docensnek és Dr. Kelemen András főiskolai docensnek, akik fáradhatatlan útmutatással és türelmükkel végig támogattak hallgatói éveim során.

Mély hálával tartozom Prof. Bari Ferencnek és Prof. Széll Mártának, amiért lehetőséget biztosítottak számomra az Idegtudomány PhD-programban való részvételre. Doktori iskolájuk jelentős szerepet játszott tudományos fejlődésemben, értékes tanulási tapasztalatokat és konferencialátogatási lehetőségeket kínálva.

Őszinte hálámat fejezem ki Prof. Sáry Gyulának és Dr. Berényi Antalnak, az Élettani Intézet vezetőinek, amiért biztosították számomra a kutatás lehetőségét intézetükben.

Külön szeretném megköszönni Dr. Juhász Zoltánnak, hogy nagylelkűen megosztotta velem széleskörű EEG-szakértelmét, mely nagyban hozzájárult kutatásom sikereihez.

Különösen hálás vagyok Dr. Bodosi Balázsnak, amiért bevezetett az alapvető tudományos kérdésekbe, valamint Liszli Péternek, aki önzetlenül megosztotta velem tapasztalatait.

Köszönet illeti továbbá Dr. Braunitzer Gábort, aki értékes munkájával segítette cikkeim érthetőbbé tételét.

Legmélyebb elismerésemet fejezem ki laboratóriumi és intézeti kollégáimnak, különösen Dr. Tót Kálmánnak, akinek támogatása kulcsszerepet játszott többek között a mintaszám bővítésében.

Hálás vagyok az SZTE Móra Ferenc Szakkollégiumnak is, amely interdiszciplináris tudományos szemináriumaival gazdagította akadémiai utamat.

Mindenekelőtt szeretném kifejezni szívből jövő hálámat családomnak, akik végig kitartó támogatásukkal és bátorításukkal segítettek ezen az úton. Jelenlétük folyamatos erőforrásként szolgált számomra.

Végül köszönetemet fejezem ki mindazoknak, akik bármilyen módon inspiráltak vagy segítettek -- kollégáknak, barátoknak és hallgatóknak. Kisebb és nagyobb hozzájárulásaitok egyaránt jelentős hatással voltak e munkára.

## 9. Intézményi Etikai Bizottsági Nyilatkozat

A vizsgálati protokoll minden tekintetben megfelelt a Helsinkai Nyilatkozat alapelveinek, és azt a Szegedi Tudományegyetem Regionális Orvostudományi Kutatásetikai Bizottsága jóváhagyta (protokollszám: 27/2020-SZTE).

## 10. Finanszírozás

Ez a PhD-munka a Szegedi Tudományegyetem, Szent-Györgyi Albert Orvostudományi Kar SZTE-SZAOK-KKA támogatásával valósult meg, a 2019/270-62-2 számú pályázat keretében. Ez a PhD-munka a Szegedi Tudományegyetem, Szent-Györgyi Albert Orvostudományi Kar SZTE-SZAOK-KKA támogatásával valósult meg, a 2023/5S479 számú pályázat keretében.

## 11. Licenc

Ez a dolgozat a Creative Commons Attribution NonCommercial 4.0 International License (CC-BY-NC) alatt áll.

További részletekért kérjük, tekintse meg a licenc teljes szövegét.