

OTDK-dolgozat

2025

**EÖTVÖS LÓRÁND TUDOMÁNYEGYETEM
PEDAGÓGIAI ÉS PSZICHOLÓGIAI KAR**

**PREDIKTÍV FELDOLGOZÁS AUTIZMUS
SPEKTRUMON BIZONYTALAN
KÖRÜLMÉNYEK KÖZT**

Szerző neve: Nagy Zita Olívia

Konzulensek neve: Hann Flóra, Pesthy Orsolya

Kézirat lezárása: 2025.01.08.

Bevezetés

A prediktív feldolgozás az az automatikus kognitív funkciónk, amely során agyunk folyamatosan elméleteket gyárt az elkövetkezendő eseményekről (Friston, 2010). Ehhez monitorozni kell a jelen eseményeket is, és különösen azok az események hívhatják fel magukra a figyelmet, amik eltérnek az elvárásainktól. Ahhoz, hogy minél megbízhatóbb legyen az eseményekről alkotott elvárásunk, ezeknek az eltéréseknek hosszútávú minimalizálására törekszünk különböző módokon. Ha az eltérés egyszeri eseménynek tűnik, ami kis valószínűséggel fordul majd elő a jövőben, akkor nem érdemes nagyon megváltoztatnunk az elvárásainkat, hiszen a világunk szabályszerűségei nem tökéletesek, előfordulnak bejósolhatatlan események. Ugyanakkor, ha egy olyan eltéréssel találkozunk, ami hosszabb távon is fennállhat a jövőben, akkor érdemes mihamarabb változtatni az elvárásainkon. Az elvárásaink frissítése tehát szituációfüggő, az az adaptív, ha rugalmasan változtatjuk. Az autizmus spektrumzavar (Autism Spectrum Disorder, rövidítve: ASD) fő jellemzői, mint a rugalmatlanság és a változatos, szociális környezetben jelentkező nehézségek mind együtt járhatnak azzal, hogy a prediktív feldolgozásuk eltér a neurotipikus személyekétől (Palmer és mtsai., 2017; Van de Cruys és mtsai., 2014). Kutatásomban ez alapján azt vizsgáltam, hogy vajon van-e eltérés a predikciós frissítés mintázatában bizonytalan körülmények közt az autisztikus vonások mentén.

Az autizmus spektrumzavar és a spektrumszemlélet

Az autizmus spektrumzavar egy multifaktoriális és multidimenzionális, eltérő idegrendszeri fejlődéssel járó pervazív állapot (Volkmar, 2021). Bár már több ezer gént feltártak, amelyek az autisztikus tüneteket okozhatják, ezek rendkívül változatos és komplex mintázatban jelenhetnek meg, így még további vizsgálatokra van szükség egyértelmű biomarkerek azonosításához. Emiatt a viselkedéses szintet tekintjük a diagnosztika fő mutatójának, amely (szintén) rendkívül heterogén. A fő diagnosztikus rendszerek, mint a DSM-V (APA, 2013) és BNO-11 (WHO-2019) két fő tünetcsoportba sorolják az autizmus spektrumzavar viselkedéses jellemzőit: (1) szociális kommunikációs nehézségek, és (2) rugalmatlan, repetitív viselkedés, érdeklődés jellemzi az érintett személyeket (APA, 2013; WHO, 2019). Bár a diagnosztikus megközelítés még mindig kategorikusan jelöli ki az autizmus spektrumzavarban érintett és nem érintett személyek viselkedési formáinak számszerű kritériumait, a DSM és a BNO korábbi verzióihoz képest (APA, 1994; WHO, 1992) a legfrissebb verzió a nagy heterogenitás miatt

eltörölte az autizmushoz tartozó egyéb kategóriákat (pl. Asperger szindróma), és ehelyett vezette be a multidimenzionális spektrum fogalmát a diagnosztikába. Erre azért is volt szükség, mert így az autisztikus profil alapján a személyre szabott támogatás tud a középpontba kerülni a kategorizáció helyett (APA, 2013, Happé, 2011, Volkmar & Reichow, 2013, WHO, 2019).

Számos kutatás támogatja az autizmus spektrum fogalmának további kiterjesztését, az alapján, hogy autisztikus vonásokkal eltérő mértékben, de a teljes populáció rendelkezik (Baron-Cohen és mtsai., 2001, De Groot & Van Strien, 2017, Hoekstra és mtsai., 2007). Természetesen az autizmus spektrumzavarral diagnosztizálható személyeknek az autisztikus vonásai a legerősebbek, de lehetnek erősen szubklinikus szinten érintett személyek is, a genetikai háttér miatt sokszor a diagnosztizált személyek rokonai például ebbe a csoportba tartoznak (Bralten és mtsai., 2018, Hoekstra és mtsai., 2007, Nayar és mtsai., 2021, Rubenstein & Chawla, 2018, Sucksmith és mtsai., 2011, Wallace és mtsai., 2016). Erre a jelenségre vezették be a szélesebb autizmus fenotípus (Broader Autism Phenotype, rövidítve: BAP) fogalmát, amely szerint a diagnosztizált autizmus spektrumzavarral élő személyek és a BAP-ba tartozó személyek autisztikus vonásai közt inkább mennyiségi, és nem minőségi különbség van (Baron-Cohen és mtsai., 2001, Hoekstra és mtsai., 2007). Kognitív és személyiségpszichológiai kutatások olyan személyeket is vizsgáltak, akik nem feltétlenül rendelkeznek ASD diagnózissal, és arra jutottak, hogy a magasabb autizmus spektrum kvóciens (azaz erősebb autisztikus vonások) összefügg több ASD diagnózisú személyekre jellemző tulajdonsággal és teljesítménymintázattal (Baron-Cohen és mtsai., 2001, Jankowska és mtsai., 2019, Kunihiro és mtsai., 2006, Stewart és mtsai., 2009). Összességében tehát a BAP alapján a teljes populáció spektrumszemléletű vizsgálata használható és érvényes információkat adhat az autizmus spektrumra nézve.

Az autizmuskutatás utóbbi évtizedeiben erős a törekvés egy, a tünetek és a személyek heterogenitására átfogó, ugyanakkor kellően autizmusspecifikus, neurokognitív megalapozottságú magyarázat létrehozására. Bár születtek ez idő alatt ígéretes elméletek, mint naiv tudatelmélet (Baron-Cohen, 2000), a centrális koherencia (Frith & Happé, 1994, Happé & Frith, 2006) vagy a végrehajtó funkciók eltérése (Ozonoff, 1995), az előbb felsorolt feltételeket önmagukban nem elégítik ki (Csepregi & Stefanik, 2019, Van de Cruys és mtsai., 2014, Volkmar, 2021). A prediktív feldolgozás autisztikus sajátosságainak meghatározásával viszont közelebb kerülhetünk egy ilyen elmélet létrehozásához. A prediktív feldolgozás az autizmuskutatás egy friss (kb. 15 éve jelenlévő), ugyanakkor dinamikusan fejlődő területe. Folyamatosan bővülő kognitív és neurobiológiai vizsgálatok is alátámasztják, hogy jelentős

különbség lehet a prediktív feldolgozásában a magas és alacsony autisztikus vonásokkal jellemezhető személyek közt, ugyanakkor vannak még kérdések az eredmények magyarázatában. Dolgozatomban a kognitív információfeldolgozás szintjén szeretném bemutatni a prediktív feldolgozás működését, hiszen a vizsgálatban használt mérőeszközök és a dolgozat terjedelmi korlátai is erre adnak lehetőséget, ugyanakkor jelentős neurobiológiai bizonyítékok is az elmélet megalapozottságát bizonyítják (Van de Cruys és mtsai., 2014; Friston, 2010; Palmer és mtsai., 2017; Palmer és mtsai., 2017; ...)

Prediktív feldolgozás

A prediktív feldolgozás kognitív folyamatát több elméleti keret is magyarázza, amelyek közül az egyik legelterjedtebb a bayesi modell. A bayesi modell szerint az agy előzetes információk alapján elvárásokat (*priorokat*) alakít ki, amelyeket az újonnan beérkező adatok (*likelihood*) segítségével frissít. E folyamat eredményeként egy *poszterior* modell jön létre, amely az agy által generált predikció eredményét tükrözi. Az új tapasztalatok alapján a prior modell valószínűségi eloszlása folyamatosan frissül, és amikor hipotézist állítunk fel, ebben a komputációs keretben a legvalószínűbb eseményt választjuk ki az új körülmények (*likelihood*) figyelembevételével (Palmer és mtsai., 2017; Pálffy és mtsai., 2022). Az új információk automatikusan beépülnek a priorokba és frissítik azokat (Friston, 2010; Palmer és mtsai., 2017), bár a frissítési folyamat nem minden helyzetben működik ugyanúgy (lásd később).

Előfordul, hogy a prediktált és a valós esemény eltérnek egymástól. Életszerű példa, ha várunk a buszra, ami 20 percet késik. Ezt az eltérést nevezzük *predikciós hibának*. A predikciós hibáknak két fajtáját különböztethetjük meg: a *tanulás-függő* és a *nem tanulás-függő hibát*. *Tanulás-függő hiba* az, amikor tényleges szabályszerűség alapján helyesen prediktálunk, ám egy kis valószínűségű, a szabály szempontjából nem releváns inger (*zaj*) miatt mégis predikciós hiba keletkezik. Például, megtanultuk már a busz menetrendjét (*prior*), ami holnap is érvényes lesz, ma csak véletlen egy baleset miatt késve érkezik (*zaj*). *Nem-tanulás-függő hiba* akkor történik, amikor az újonnan érzékelt információ tükrözi a valóságot, és a predikciós modellünk a hibás (Pesthy, 2023). Lehet például, hogy a busz azért késett 20 percet, mert megváltozott a menetrend, amit addig nem vettem észre. Automatikusan törekszünk arra, hogy a modellünket pontosítsuk a predikciós hiba jelzése után, ugyanakkor érdemes helyzettől függően rugalmasan alakítani a predikciós hibák súlyozását (Friston, 2010, Palmer és mtsai., 2017, Pálffy és mtsai., 2022, Sapey-Triomphe és mtsai., 2022). A súlyozás mértéke a *tanulási ráta*, más szóval az új információ (*likelihood*) becsült pontosságának aránya a *prior* modell becsült precizitásához

képest. Statisztikailag nagyobb *precizitást* akkor észlelhetünk, ha nagyobb a mintánk elemszáma vagy kisebb a mintánk szórása. Ha a priorunk becsült pontossága kisebb, mint a likelihood becsült pontossága, akkor az új információt (likelihood) jobban fogjuk súlyozni a prior modell frissítésekor, mint a prior eddigi adatait, ami magas tanulási rátát jelent. Ilyenkor a meglévő elvárásainkat gyakrabban írjuk felül. Akkor érdemes nagyobb súlyt adni a likelihood alapján történő prior modell frissítésnek egy tanulási folyamatban, amikor nem-tanulás-függő hibát követünk el. A buszos példával élve, érdekesebb mihamarabb észlelnünk, hogy az új információ (20 perc késés) pontosabb, mint a korábbi menetrend szerinti elvárásunk, és felülrni a prior modellünket. Ha a priorunk becsült pontossága nagy, akkor az eddigi prior modell lesz megbízhatóbb, azt kevésbé fogja befolyásolni az új információ, így alacsony lesz a tanulási ráta. Akkor érdemes a prior modellt kevésbé módosítani a likelihood által, ha a predikciós hiba tanulás-függő: tehát ismerjük a szabályt (menetrendet), ami általánosan érvényes, ez csak véletlen hiba (pl. baleset). A prior modell nagyobb súlyozása segít a zajos, félrevezető információk szűrésében, amik így kevésbé torzítanak (Palmer és mtsai., 2017; Pálffy és mtsai., 2022, Sapey-Triomphe és mtsai., 2022). Az észlelésben a predikciós hibák súlyozása a figyelmi folyamatokon keresztül nyilvánul meg. (Palmer és mtsai., 2017).

Elméleti keretek az autizmussal élő személyek prediktív feldolgozására

A prediktív feldolgozás autisztikus kognitív fenotípusra jellemző folyamatára különböző elméleti keretek születtek. Ebben az alfejezetben két markánsan eltérő, empirikusan alátámasztott elméleti keretet fogok bemutatni, amik az autisztikus sajátosságokat próbálják magyarázni a prediktív feldolgozásban. Annak vizsgálata, hogy melyik ad pontosabb modellt az autisztikus prediktív feldolgozásra kritikusan fontos, mert az autisztikus tünetek megértésén túl eltérő klinikai implikációk (terápiák, diagnosztikus folyamat) kidolgozását teheti lehetővé.

A lassú frissítés elmélet szerint az autisztikus személyek az új információt (likelihood) azonnal kevésbé, viszont később hasonlóan építik be a prior modelljükbe, mint a kevésbé erős autisztikus vonásokkal rendelkező személyek. Ez adaptív lehet hosszútávon egy zajos környezetben, hiszen kevésbé hat rájuk a hirtelen megjelenő zajos inger, inkább a hosszútávú statisztikákat veszik figyelembe. A már beépült információkat tovább is tudják hasznosítani az autisztikus vonásokkal kevésbé jellemezhető személyekkel összehasonlítva (Lieder és mtsai., 2019). Predikcióik viszont eszerint rövidtávon rugalmatlanabbak lehetnek: míg neurotipikus személyeknek folyamatosan nőtt idővel a helyes predikcióik aránya változó környezetben, addig ez a progresszió autizmus spektrumzavarban érintett személyeknél nem volt

megfigyelhető (Sapey-Triomphe, 2022). Ez az elmélet magyarázhatná az autisztikus viselkedések közül a rugalmatlanságot, illetve a sokszor változó és kiszámíthatatlan szociális helyzetekhez való nehezebb alkalmazkodásukat.

A rugalmatlanul magas predikciós hibasúlyozás elmélete szerint az autisztikus személyek minden predikciós hibával nagy súllyal frissítik a prior modelljüket. Emögött az állhat, hogy a világ változékonyságát túlbecsülik, hiszen nap mint nap találkoznak olyan szituációkkal, amelyekre nehezen találnak magyarázatot. Ha ezt a stratégiát alkalmazzák, akkor azzal csökkenthetik a predikciós hibából fakadó frusztrációjukat, hogy mindig a legfrissebb információkra támaszkodnak. Ugyanakkor, ha minden predikciós hibával frissítenek, akkor azzal nem veszik figyelembe a „természetes zaj” hatását, vagyis azt, hogy ha néha az elvárásunktól eltérő dolog történik, az még nem biztos, hogy megváltoztatná az egész szabályrendszert (prior). Így fennáll a veszélye a folyamatosan magas tanulási ráta mellett a prior modell túlillesztésének (overfitting). A rugalmatlanul magas frissítés elmélet szerint tehát autisztikus fenotípus esetén sokkal többet változtatnak a predikcióikon, és pontosan az előző predikciós hiba alapján (azt nagy súllyal beépítve) (Van de Cruys és mtsai., 2014; Palmer és mtsai., 2017).

A prediktív feldolgozás mérése

A többféle elméleti keret és az azokat alátámasztó különböző eredmények a prediktív feldolgozás vizsgálatában részben fakadhat a nem egységes mérési módszerek használatából. Jelen vizsgálati elrendezésünkben törekedtünk a korábbi tanulmányok limitációinak kiküszöbölésére, hogy minél megbízhatóbb legyen az eredményünk a prediktív feldolgozás mérésével kapcsolatban.

Az Alternáló Szeriális Reakcióidő feladattal (Alternating Serial Reaction Time task, röviden: ASRT, Howard Jr. & Howard, 1997) megbízhatóan mérhető az implicit prediktív feldolgozás (Farkas és mtsai., 2022). Ez egy probabilisztikus feladat, amiben vannak valószínűbb, így jobban bejósolható elemek és kevésbé valószínű elemek (a feladat részletes leírását ld. a Módszerek fejezetben). A valószínűbb elemeket egy rejtett szabály (szekvencia) idézi elő. A kevésbé valószínű elemek egy folyamatos zajt, bizonytalanságot teremtenek, hiszen ezek lehetőségek a hibázásra akkor is, ha megtanultuk a szabályt (ld. tanulás-függő hiba). Emellett viszont a bizonytalanság másik forrása lehet, ha globális szabályváltozást idézünk elő, ha a zajos környezeten túl a teljes szabály megváltozik. Ezt a szabályváltást kutatásunkban egy interferencia szakasszal idéztük elő az eredeti szakasz után.

A korábbi kutatások limitációja lehet, hogy motoros választ (legtöbbször gombnyomást) várt el vizuális inger megjelenésére. A reakcióidőnek a lehető legrövidebbnek kell lennie egy ilyen implicit kognitív funkciót mérő folyamatban, amire a vizsgálati személy a feladatban képes, hogy valóban az automatikus választ mérhessük. A vizuális inger észlelése utáni motoros válasz a reakcióidőt hosszabbá teheti, hiszen egy plusz motoros komponens kerül a vizsgálati személy válaszába a vizuális komponensen felül. Ha szemmozgáskövető vizsgálatot alkalmazunk, akkor minimálisra csökkenthetjük a válaszreakciót, és közelebb kerülhetünk az automatikus kognitív folyamat méréséhez. További előnye a szemmozgáskövető eszköz használatának, hogy a reakcióidőn felül anticipátoros szemmozgásokat is mérhetünk, amiből következtethetünk a predikciós feldolgozás folyamatára (Tal & Vakil, 2020; Zolnai és mtsai.; 2022, Pesthy és mtsai.; 2023, Pesthy, 2023). Az ASRT feladat elvégzése szemmozgáskövető eszközzel lehetőséget biztosíthat a minél pontosabb kép feltárására a prediktív feldolgozás folyamatával kapcsolatban bizonytalan körülmények közt.

Hipotézisek

Kutatásomban azt vizsgálom, hogy az autisztikus vonások erőssége mentén (az AQ összpontszám mentén) hogyan különbözik a vizsgálati személyek predikciós modellfrissítése globális szabályváltozás esetén és zajos környezetben. Az általános zajt az ASRT feladat biztosította, míg a globális szabályváltozást interferencia szakasz bevezetésével állítottunk elő, ahol más volt a szabály, mint a korábbi, eredeti szakaszban (ld. részletesebben a Módszerek fejezetben).

Az első hipotézisem szerint, függetlenül az autisztikus vonások erősségétől, a magas valószínűségű elemekre a vizsgálati személyek gyorsabban reagálnak, mint az alacsony valószínűségű elemekre az eredeti, illetve az interferencia szekvencia szakaszban is, külön-külön. Ennek a vizsgálata azt a célt szolgálja, hogy megbizonyosodjak róla, hogy megtörtént az implicit statisztikai tanulás, ami alapján lehet elvárásuk a tripletok kimeneteivel kapcsolatban.



A második és harmadik hipotézisemet a két, korábban ismertetett elmélet (lassú frissítés elmélet és rugalmatlanul magas hibasúlyozás elmélet) két markáns különbségére alapoztam. A továbbiakban hipotézisként a különbségtétel szempontjait emelem ki, illetve a két elméletre alapozott eredményeket.

Különbség van a két elmélet közt abban (második hipotézis), hogy az eredeti szakaszban megtanult szekvenciát milyen gyakorisággal alkalmazzák a vizsgálati személyek a szabályváltozás után (tehát az interferencia szakasz alatt) az autisztikus vonások erősségével összefüggésben. A lassú frissítés elmélete szerint minél erősebbek valakinek az autisztikus vonásai, annál valószínűbb az eredeti szabály alkalmazása az interferencia szakaszban (hiszen annál lassabban frissítik a prior tudásukat). A rugalmatlanul magas predikciós hibasúlyozás elmélete szerint minél erősebbek az autisztikus vonásai egy személynek, annál kevésbé valószínű az eredeti szabály alkalmazása az interferencia szakaszban (hiszen a hibáik alapján azonnal frissítik a prior tudásukat).


Különbség van abban is a két elmélet közt (harmadik hipotézis), hogy a vizsgálati személyek milyen gyakorisággal frissítik predikcióikat a predikciós hibák alapján az autisztikus vonások erősségével összefüggésben. A lassú frissítés elmélete szerint minél erősebbek valakinek az autisztikus vonásai, annál kevesebbszer frissíti predikcióit az előző predikciós hiba alapján. A rugalmatlanul magas predikciós hibasúlyozás elmélete szerint minél erősebbek valakinek az autisztikus vonásai, annál többször frissíti predikcióit az előző predikciós hiba alapján. A második és harmadik hipotézisem predikcióit az 1. táblázat foglalja össze.

1. Táblázat

A második és harmadik hipotézis összefoglaló táblázata a két elmélet különböző várt eredményei szerint

Hipotézisek	Rugalmatlanul magas predikciós hibasúlyozás elmélete	Lassú frissítés elmélete
Eredeti szekvencia tanulásfüggő hibájának valószínűsége összefügg az autisztikus vonások erősségével	 Autisztikus vonáserősség Régi tanulásfüggő hiba valószínűsége	 Autisztikus vonáserősség Régi tanulásfüggő hiba valószínűsége

A frissítések gyakorisága a predikciós hibák alapján összefügg az autisztikus vonások erősségével



Módszertan

Vizsgálati személyek

A vizsgálatban ép intellektusú felnőtt személyek vettek részt. A vizsgálati személyek toborzására kényelmi mintavételt alkalmaztunk: ismerősök által terjesztve vontunk be résztvevőket, illetve egy egyetemi kurzus hallgatói jelentkeztek a kutatásba. Az autizmus spektrumzavar diagnózis nem volt se feltétel, se kizáró indok a részvételhez, így két, diagnosztikusan biztosan érintett személy bekerült a mintába. Kizáró indok volt viszont, ha valakinek más jellegű pszichiátriai diagnózisa volt, illetve ha végzett már korábban ASRT feladatot.

Kutatásomban végül 44 vizsgálati személy adatait használtam fel. Adatminőségi szempontok miatt előzetesen ki kellett zárnom azokat a személyeket, akiknek a szemmozgáskövető eszköz túl sok hiányzó adatot rögzített, illetve akiknek a két szemük távolságát túl nagynak vagy kicsinek érzékelték (ld. Zolnai és mtsai., 2022). A hipotéziseim miatt azokat a vizsgálati személyeket is kizártam a kutatásomból, akik nem töltötték ki az Autizmus Kvóciens (AQ) kérdőívet (ami alapján az autisztikus vonások erősségét mérem, lásd a Mérőeszközök című fejezetben). Az általam vizsgált csoportba 30 fő nő (68,18%), 13 fő férfi (29,54%) és 1 fő „más” nemi identitású személy (2,27%) tartozik. A vizsgált személyek átlagéletkora 21,55 év, életkori szórásuk 2,82 év.

Mérőeszközök

Autizmus Spektrum Kvóciens kérdőív (Baron-Cohen és mtsai., 2001). Az Autizmus Spektrum Kvóciens (Autism Spectrum Quotient, rövidítve: AQ) kérdőív arra szolgál, hogy az ép intellektusú felnőtt személyeknél felmérje az autisztikus vonások erősségét. Ez egy 50 tételes önkitöltős kérdőív, aminek tételeit egy 4 fokú Likert-skálán kell értékelniük a vizsgálati

személyeknek aszerint, hogy mennyire értenek egyet a tételekben felsorolt viselkedésükre, gondolkodásukra vonatkozó állításokkal („egyáltalán nem értek egyet – nem értek egyet – egyetértek – teljesen egyetértek”). A kérdőív alszámai olyan készségeket mérnek, mint a figyelemváltás, figyelem a részletekre, kommunikáció, képzelet és a társas készségek. Ezek alapján akár egy heterogén képességprofil is mérhető, de az összpontszám magában is informatív az autisztikus vonások általános erősségét tekintve a személyben. Az egyes tételekre 1-1 pontot lehet kapni aszerint, hogy azok az autisztikus fenotípusra jellemzőbbek/kevésbé jellemzőek, így legfeljebb 50 pont szerezhető a kérdőív alatt. A kérdőív nem diagnosztikus értékű, ugyanakkor a diagnózissal rendelkező személyek, illetve a széles autizmus fenotípusba tartozó személyek vizsgálata alátámasztotta az eszköz megbízhatóságát az autisztikus vonások erősségének mérésére (Hoekstra és mtsai., 2008; Woodbury-Smith és mtsai., 2005).

Alternáló Szeriális Reakcióidő feladat (Howard és Howard, 1997, Zolnai és mtsai., 2022). Az Alternáló Szeriális Reakcióidő feladat (Alternating Serial Reaction Time, rövidítve: ASRT; Howard és Howard, 1997) egy megbízható mérőeszköz az implicit prediktív feldolgozás mérésére (Farkas és mtsai., 2022; Zolnai és mtsai., 2022). A feladat lényege, hogy az ingerek részben egy előre meghatározott sorrendet követnek, ami miatt nagyobb valószínűséggel fordulnak elő egyes kimenetek. Emellett a feladatban vannak alacsony valószínűségű kimenetek is, amik „zajos” közeget teremtenek az impliciten “megtanulandó” szabály (szekvencia) köré. Az ASRT feladatnak több verziója létezik, mi a Zolnai és munkatársai (2022) által kidolgozott szemmozgáskövető eszközre adaptált verzióját használtuk, amit az alábbiakban ismertetek részletesen.


Ebben az ASRT-feladat változatban a vizsgálati személyek előtti képernyőn négy helyen jelenhet meg az inger egy adott próbában. A négy lehetséges ingermegjelenési helyet üres körvonalak jelzik. A feladat utasítása, hogy ha kékre színeződik a kör, a lehető leggyorsabban rá kell néznie a vizsgálati személynek. A beszíneződés akkor tűnik el, amikor a vizsgálati személy ránéz a megfelelő körre. Egy inger eltűnése után 500 ms késleltetéssel jelenik meg a következő inger. A résztvevők nem tudják, hogy az ingerek sorrendje részben előre meghatározott, és részben véletlenszerű, ami így egy félig szabályszerű sorozatot (szekvenciát) hoz létre. Pontosabban minden második célinger rögzített sorrendben „megy végig” a négy lehetséges ingermegjelenési helyen egy szekvenciában. Ezek közt a „szabályos” sorrendben megjelenő célingerek közt random, a négy lehetséges ingermegjelenési hely közül bármelyikben feltűnhetnek célingerek. A négy lehetséges ingermegjelenési helyet

megszámozva (1., 2., 3., 4. hely) leírhatunk a szekvenciát úgy, mint például 2-random-4-random-3-random-1-random (és ezután a szekvencia ismétlődik) (ld. 1. Ábra).

A szabályos elemek állandó sorrendje miatt lesznek olyan elemhármasok (*tripletek*), amiknek első eleme után bizonyos elemek két elemmel később nagyobb valószínűséggel fognak előfordulni. Az előbb bemutatott szabály szerint tehát a 2-random-4, 4-random-3, 3-random-1 és 1-random-2 tripletek nagyobb valószínűséggel fognak előfordulni a sorozatban; ezek a *magas valószínűségű tripletek*. A többi lehetséges triplet (1-random-1, 1-random-3, 1-random-4, 2-random-1, 2-random-2, 2-random-3, 3-random-2, 3-random-3, 3-random-4, 4-random-1, 4-random-2, 4-random-4) ritkábban fordul elő, hiszen a random elemek miatt jöhetnek létre; ezek az *alacsony valószínűségű tripletek*. A feladat során a magas valószínűségű tripletek előfordulási aránya 62,5%, míg az alacsony valószínűségű tripleteké 37,5% (ld. 1. Ábra). A szekvencia hatékony megtanulását az jelzi, ha inkább a magasabb valószínűségű tripleteket építik be nagyobb hangsúllyal a prior modelljükbe, mint az alacsonyabb valószínűségű tripleteket (tehát pl. a reakcióidejük gyorsabb lesz a magas valószínűségű tripletekre).

1. Ábra

Ingerek megjelenése egy szekvencián keresztül az ASRT feladatban.



Megjegyzés. A) Az ingerek megjelenése egy szekvencia alatt a képernyőn. Egy inger négy helyen jelenhet meg a képernyőn. Egy szekvenciában négy szabályos és négy random inger váltja egymást. Az ábrán a 2-random-4-random-3-random-1-random szekvencia látható példaként. *B)* Lehetséges tripletvégzõdések szerinti kategorizáció a 2-es inger után. 50-50% az esély, hogy a 2-es ingermegjelenés random vagy szabályos elem volt. Ha a 2-es inger random elem volt, akkor random lesz a triplet 3. eleme, a triplet végzõdés is. Random tripletvégzõdés a 4 közül bármelyik ingermegjelenési helyen előfordulhat, tehát az egyes ingermegjelenési helyekre ez esetben 12,5% esély van. Mivel a 2-es ingermegjelenési hely után csak a 4-es tripletvégzõdés lesz magas valószínűségű, ezért random tripletvégzõdés esetén 12,5% valószínűséggel fordulhat elő, hogy így magas valószínűségű lesz a triplet. Ha a 2-es ingermegjelenési hely szabályos elem volt, tehát a tripletvégzõdés is szabályos elem lesz, akkor

az nem fordulhat elő más módon, mint hogy a tripletvégződés a 4-es helyen legyen. Ez szabályos ingerek esetén tehát 50%-ban fog teljesülni. A magas valószínűségű tripletok így összesen az ingerek 62,5%-ban fognak megjelenni, míg az alacsony valószínűségű tripletok 37,5%-ban. **C)** Egy ismétlődő szekvenciában megjelenő tripletok valószínűsége. Két egymás utáni szabályos elem egy tripletben (egy random elemmel közbeékelve) magas valószínűségű triplet lesz. Két egymás utáni random elem egy tripletben (egy szabályos elemmel közbeékelve) alkothat alacsony és magas valószínűségű tripletet is. Mivel a random elemek a 4 lehetséges ingermegjelenési hely bármelyikén megjelenhetnek, így lehetséges, hogy magas valószínűségű tripletet alkoznak. A feladat úgy van megtervezve, hogy a tripletok 62,5%-a magas valószínűségű triplet, míg 37,5% alacsony valószínűségű triplet lesz. A szekvencia szabályos elemei ciklikusan ismétlődnek, de a random elemek változóak lehetnek a szekvencián belül. Egy szekvencia 10-szer ismétlődik blokkonként, és 5 blokk alkot egy epochot.

A feladatban a predikciós feldolgozás megnyilvánulásának vizsgálatára az *anticipátoros szemmozgásokat* mértük. Ez itt azt jelenti, hogy egy inger eltűnése után (miután a vizsgálati személy ránézett az ingerre), és a következő inger megjelenése előtt közvetlenül lesz a szemmozgásban egy *fixáció* oda, ahova a következő ingert várják. Az inger eltűnése és a következő inger megjelenés közt 500 ms idő telik el. Ahhoz, hogy ne csupán véletlen helyre történő gyors szemmozgásokat (szakkádokat) mérjünk, szükséges néhány paraméter meghatározása. A szemmozgást akkor számítjuk fixációnak, ha legalább 100 ms ideig tart, és a lehetséges ingermegjelenési helyet jelölő kör középpontjára helyezett 4×4 centiméteres négyzetben belül van (Zolnai és mtsai., 2022, Pesthy és mtsai., 2023, Pesthy, 2023).

Predikciós hiba akkor történik, ha másik ingermegjelenési helyre történik anticipátoros szemmozgás, mint ahol valójában az inger végül megjelenik. Ahogy a bevezetőben ismerttettem, létezik tanulásfüggő és nem-tanulásfüggő hiba. Tanulásfüggő hiba itt az, mikor magas valószínűségű tripletre számítunk (a példa szerint tehát ha az egyik ingernél 2-est látunk, kettő ingerrel később 4-es helyre számítunk), mégis alacsony valószínűségű triplet következik be (mondjuk a 2-es után kettővel 1-es). Nem-tanulásfüggő hibának azt vesszük itt, amikor alacsony valószínűségű tripletet jósolunk (pl. 2-es után kettő ingerrel az 1-es helyre várjuk az ingert), de magas valószínűségű triplet jön (pl. 2-es után kettő ingerrel a 4-es). A predikciós hiba alapján történő frissítésnek azt tekintjük, ha egy bizonyos ingermegjelenés (pl. 2-es helyen) legközelebbi előfordulásánál az előző predikciós hibát (pl. hibásan az 1-es helyre vártam az ingert, de a 4-es helyen jelent meg) „megtanuljuk”, és a következő alkalommal azt alkalmazzuk


(pl. most már a 2-es megjelenése után kettővel nem az 1-es helyen várom az ingert, hanem a 4-es helyen).

Az ASRT feladaton belül több egységet határozhatunk meg az ingerek száma szerint. Egy szekvenciában nyolc inger szerepel (négy szabályos elem felváltva négy véletlenszerű elemmel), és 10 darab szekvencia ($10 \times 8 = 80$ inger) (és ezen felül két random inger az elején, amik még nem alkothatnak tripletet) tartozik egy blokkba. Az egyes blokkok végén a vizsgálati személyek visszajelzést kapnak a képernyőn az átlagos reakcióidejükről, ami az ingermegjelenés és a szemmozgáskövető eszköz által érzékelt fixáció közt eltelik. Öt blokk tartozik egy epochba. Az egyes epochok végén a vizsgálatvezető visszajelzést kap arról, hogy a szemmozgáskövető eszköz észlelt-e extrém reakcióidőt a vizsgálati személynél. Ha igen, akkor a szemmozgáskövető eszköz újraprogramozása ad lehetőséget a szemmozgás pontos érzékeléséhez szükséges dőlésszög és távolság javítására. Egy epoch körülbelül öt percig tart, és négy epoch alkot egy szakaszt.

Kutatásomban két egymás utáni szakaszt vizsgáltam: az 1. eredeti szekvencia szakaszt, és a 2. interferencia szekvencia szakaszt (ld. 2. ábra). A két szakasz utasításban és ingermennyiségben teljesen azonos, viszont a szabályos ingerek által követett szekvencia különbözik. Például, ha az eredeti szekvencia ez: 2-r-4-r-1-r-3, akkor az interferencia szekvencia például lehet ez: 4-r-2-r-3-r-1, és emiatt az interferencia szakaszban módosul a tripleték előfordulási valószínűsége az eredeti szakaszhoz képest. Tehát amik az eredeti szekvenciában magas valószínűségű tripleték voltak, azok az interferencia szekvenciában lehetnek alacsony valószínűségű tripleték (pl. 2-r-4), vagy maradhatnak magas valószínűségű tripleték is (pl. 4-r-2).

2. Ábra

Kutatási elrendezés az eredeti és interferencia szekvencia szakasszal



Megjegyzés. Az első szakasz tartalmazza az eredeti szekvenciát, a második szakasz az interferencia szekvenciát. Az egyes szakaszok négy epochot tartalmaznak. Egy szakasz körülbelül 20 percig tart. A két szakasz közt van egy kis szünet.

Szemmozgás-követés. A vizsgálatban a Tobii Pro Fusion (Tobii Pro, 2019) szemmozgáskövető eszközt és a hozzá tartozó szoftvert használtuk. Az eszközhöz egy 250 Hz-es (másodpercenként 250 képet készítő) szenzor tartozik, ami a két szem mozgását külön kamerákkal rögzíti. Ilyen sűrű és folyamatos adatfelvételen természetes, hogy vannak hiányzó adatok, például pislogás miatt. A szenzor által érzékelt szemmozgások adatait a Tobii Pro Python SDK programmal (Tobii Pro, 2020) rögzítettük.

Eljárás

A teljes vizsgálat két részből állt: egy otthoni kérdőívsomag kitöltéséből és egy személyes vizsgálatból. Az otthon kitöltendő tesztcsomagot a vizsgálati személyek jelentkezéskor megkapták, ennek része volt az Autizmus Spektrum Kvóciens (Baron-Cohen és mtsai., 2001) kérdőív. Ezután az ELTE Damjanich utcai laborjában vizsgálatvezető jelenlétében személyesen kellett elvégezniük az ASRT feladatot. A feladat a Psychopy 3.2.3 programon lett kódolva és futtatva a vizsgálati személyeknek (Peirce és mtsai., 2019).

Az ASRT feladat általam elemzett szakaszainak (1. eredeti szekvencia szakasza és 2. interferencia szekvencia szakasza) felvétele körülbelül 20-20 percig tartott. Az egyes szakaszok

alatt a vizsgálati személyek egy képernyő előtt ültek egy irodai székben, a vizsgálatvezető utasítására amennyire csak lehetett, mozdulatlanul. A két szakasz közt lehetőség volt szünet tartására, amikor mozoghattak. A vizsgálatvezető állította be a szemmozgáskövető szenzort a feladat elején a vizsgálati személynek kényelmes pozícióhoz igazítva, hogy a szenzor a lehető legpontosabban érzékelje a szemmozgásukat a feladat közben. A vizsgálatvezető az utasítást, ami a vizsgálati személyek előtti képernyőn szerepelt, egységesen felolvasta a feladat indításakor. Ebben az szerepelt, hogy a vizsgálati személynek olyan gyorsan kell a felvillanó célingerre néznie, amennyire csak tud, és addig ott tartani a tekintetét, amíg az inger el nem tűnik. A feladat első indításakor a vizsgálati személyek egy epoch mennyiségű próbaingert kaptak, ami nem tartozott sem az eredeti, sem az interferencia szekvenciához. Ez azt a célt szolgálta, hogy a szemmozgáskövető eszköz érzékelését ellenőrizzük és a vizsgálati személy gyakorolhassa a feladatot. Ezután következett először az eredeti szekvenciát tartalmazó szakasz, majd szünettel közbeékelve az interferencia szekvencia szakasz, négy-négy epochnyi ingeranyaggal. Az interferencia szekvencia szakaszhoz pontosan ugyanaz volt az utasítás, mint az eredeti szekvencia szakaszhoz. Mivel a vizsgálati személyek egyáltalán nem voltak tudatában annak, hogy tanulási helyzetben vesznek részt (hiszen a tanulás impliciten történt), azzal sem voltak tisztában, hogy a szünet után a szekvencia megváltozott. Az egyes epochok végén a program visszajelzést adott a vizsgálatvezetőnek arról, hogy hányszor észlelt a vizsgálati személy fixációjában lényegesen hosszabb reakcióidőt (>1000 ms). Ha legalább egy ilyen extrém reakcióidő volt az epochban, a vizsgálatvezető a feladatból kilépve újrakalibrálta az eszközt, amíg az pontosabban nem érzékelte a vizsgálati személy szemmozgását. A kalibráció és ellenőrzés után a feladat ott folytatódhatott, ahol abbamaradt korábban. A feladat más jellegű megszakítása nem fordult elő.

Statisztikai módszerek

A statisztikai elemzéseimhez a Jupyter Notebook (verzió: 7.2.2; Project Jupiter, 2024), az R (verzió: 4.2.2; R Core Team, 2021) és az RStudio (verzió: 2024.09.0; Posit Team, 2024) programokat használok. Az adatminőség alapján kizártunk 18 embert, akiknek az szemmozgáskövető eszköz által rögzített adatai nem feleltek meg a kritériumainknak (hiányzó mérési pontok és szem-szem távolság, ld. Zolnai és munkatársai, 2022). A kizárt személyek nélkül, 44 vizsgálati személynek néztem meg a vizsgálati személyek leíró statisztikáit. Ezután kezdtem el elvégezni a hipotéziseimhez tartozó elemzéseket.

Az első hipotézishez tartozóan megvizsgáltam, hogy megtörtént-e a tanulás az egyes szakaszokban. Ehhez azt kellett megnéznem, hogy gyorsabb-e a reakcióidejük a vizsgálati személyeknek a magas valószínűségű tripletokra, mint az alacsony valószínűségű tripletokra. Erre kevert lineáris modellt alkottam, amiben azt vizsgálom, hogy a reakcióidőre hatással van-e a triplet valószínűségi típusa (magas/alacsony), az epoch száma (idő tényező), illetve az AQ pontszám a vizsgálati személyek különbözőségének figyelembevételével. Az epoch változót centráltam, hogy a négy epoch hatását egyben láthassam. Emellett az AQ pontszámot is centráltam és skáláztam, mivel a pontszámok eloszlása nem kiegyenlített. A triplet valószínűségét kódoló változót dichotóm faktorrá alakítottam, mivel két értéke lehet: alacsony vagy magas. A vizsgálati személyek azonosítóját is faktorrá alakítva kezeltem. Rögzített hatásként ezután a triplet valószínűségi típusát kódoló változót, az epoch változóját, illetve az AQ pontszám változóját állítottam be, egymással hármassal interakcióban. A modellben figyelembe vettem az egyéni különbségeket (a vizsgálati személyeket azonosító változóval) az alap reakcióidőben (random intercept) és az epochok szerinti (idő) változásban, mint random hatások. Ezt a modellt mindkét szakaszban (eredeti és interferencia) külön-külön megalkottam. A modell ezt az általános szintaxist követte:

1. *Triplet-tanulás az egyes szakaszokban*

Reakcióidő ~ Epoch × Triplet-valószínűség × AQ pontszám + (1 + Epoch | Vizsgálati személy azonosítója)

Azt várom, hogy a triplet valószínűségének hatása lesz a reakcióidőre mindkét szakaszban, pontosabban, hogy a magas valószínűségű tripletokra rövidebb lesz a reakcióidő, mint az alacsony valószínűségű tripletokra. Továbbá azt is várom, hogy az AQ pontszámtól független lesz a reakcióidő, nem lesz szignifikáns hatása egyik szakaszban alkotott modell esetén sem.

A második hipotézis miatt vizsgáltam meg, hogy van-e hatása az eredeti szekvencia szerinti tanulás-függő hiba előfordulási valószínűségére az AQ pontszámnak és az epochok számának az interferencia szakaszban. Az AQ pontszámot centráltam és skáláztam, ahogy a korábbi modellnél is, az epoch változója esetén pontosabb képet szerettem volna kapni az egyes epochok hatásáról, így azt csak faktorizáltam. A második hipotézisemre szintén kevert lineáris modellt építettem, amelynek rögzített hatásai az epoch, illetve a centrált és skálázott AQ pontszám, random hatása pedig az egyéni különbségekből fakadó alap-valószínűsége lesz az eredeti szekvencia tanulás-függő hibájának (random intercept). Mindkét korábban kiemelt elmélet (lassú frissítés elmélet és rugalmatlanul magas frissítés elmélet) szerint azt várom, hogy

lesz hatása az AQ pontszámnak a modellben. A lassú frissítés elméletére alkotott hipotézisem szerint a magasabb AQ pontszám nagyobb valószínűséggel jósolja be az eredeti szekvencia szerinti tanulásfüggő hiba előfordulását. Ezzel szemben a rugalmatlanul magas predikciós hibasúlyozás elmélet alapján magasabb AQ pontszámmal kevesebb eredeti szekvencia szerinti tanulás-függő hiba fog együttjárni.

2. Eredeti szekvencia szerinti tanulás-függő hiba az interferencia szakaszban

Eredeti szekvencia szerinti tanulás-függő hiba valószínűsége $\sim$ Epoch $\times$ AQ pontszám + (1 | Vizsgálati személy azonosítója)

Végül generalizált (logisztikus) kevert lineáris modellel vizsgáltam meg az előző hasonló tripletben elkövetett predikciós hibatípus és az AQ pontszám frissítésre tett hatását (3. hipotézis). Az AQ pontszám változót itt is centrálva és skálázva használtam, az előző hibatípust pedig dichotóm faktorként, aminek eredeti értékei a tanulás-függő és nem-tanulás-függő hibatípusok voltak az előző, mostanival megegyező tripletben. Rögzített hatásként tehát az előző hibatípus változóját és az AQ pontszám centrált változóját állítottam be. Random hatásként az előző hibatípusok hatásának személyek közötti eltérését vontam be (random meredekség), azaz megengedtem, hogy az előző hibatípusok hatása a frissítésre vizsgálati személyenként eltérjen. Szintén azt várom, hogy az AQ pontszámnak lesz hatása arra, hogy megtörténik-e a predikciós hiba utáni modellfrissítés az adott tripletekre. A rugalmatlanul magas predikciós hibasúlyozás elmélete szempontjából azt várom, hogy magasabb AQ pontszámmal együttjár a gyakoribb frissítés. A lassú frissítés elmélete szempontjából inkább azt várom, hogy a magasabb AQ pontszámmal kisebb mértékű modellfrissítés jár együtt.

3. Frissítés az előző predikciós hiba alapján

Frissítés $\sim$ Előző hibatípus $\times$ AQ pontszám + (1 + Előző hibatípus | Vizsgálati személy azonosítója)

A modellek alkotása után teszteltek bizonyos előfeltételeket. A kevert lineáris modell alkalmazásához szükséges a reziduálisok normalitásának vizsgálata, továbbá a multikollinearitás és a heteroszkedaszticitás tesztelése. A reziduálisok eloszlásának hasonlóságát a normál eloszláshoz Shapiro-Wilk teszttel fogom értékelni. A multikollinearitást varianciainflációs faktorról állapítottam meg, amelyben 3 alatti értéket tekintettem megfelelőnek. A heteroszkedaszticitást a reziduálisok eloszlásának megfigyelése mellett Breusch-Pagan teszttel állapítottam meg.

Amennyiben a modelljeimben szignifikáns főhatásokat vagy interakciókat azonosítok, azokat post-hoc tesztekkel is megvizsgálom. A post-hoc elemzésekhez az R program *emmeans*


csomagját használtam, amely becsült marginalizált átlagokat számít a rögzített hatások alapján, és ezeket hasonlítja össze párhuzamos tesztekkel.

Eredmények

A kutatásomba bevett 44 személy AQ összpontszámainak eloszlása a 3. ábrán látható. Az AQ pontszámok átlaga 16,25 pont, szórása 7,129 pont. A vizsgálatba bevett két autizmus spektrum diagnózissal rendelkező személy rendelkezik a két 30 pont feletti pontszámmal. Mivel az AQ pontszámok eloszlása eltérő a normál eloszlástól, a modellekbe való beépítéskor centrálást és skálázást alkalmazok rajtuk.

3. Ábra

AQ pontszámok eloszlása a vizsgált személyeknél




Az implicit tanulás sikerességének vizsgálatához megalkotott kevert lineáris modellben (1. modell) a reakcióidő változó előrejelzése volt a cél. Rögzített hatásokként a triplet valószínűségének típusát (magas/alacsony), a centrált epochokat, illetve az centrált és skálázott AQ pontszámot építettem be. A modellben random hatások bevonásával figyelembe vettem az egyéni különbségeket az alap reakcióidőben és az epochok szerinti (idői) változásban. Az eredeti szekvenciában ebben a modellben szignifikáns főhatása lett a tripletok valószínűségi típusának ($\beta_{std.} = 0,06$; $p = <0,001$; 95% CI [10,65 - 17,97]), míg az AQ pontszámnak nem ($\beta_{std.}$

= -0,03; $p = 0,302$; 95% CI [-20,3 – 6,29]) (ld. 2. Táblázat). A (centrált) epochnak interakcióban volt hatása a reakcióidőre a tripletlek valószínűségi típusával ($\beta_{std} = 3,48$; $p = 0,037$; 95% CI [0,2 – 6,75]). A 3. Ábrán látható, hogy az alacsonyabb valószínűségű tripletre mindegyik epochban lassabban reagáltak a vizsgálati személyek, illetve a két valószínűségű tripletre adott reakcióidő közti különbség idővel nő.

3. Ábra

Reakcióidő változásának vizsgálata tripletlek valószínűségei szerint az eredeti szekvencia szakaszban. Az y tengely a reakcióidőt mutatja, az x tengely az idő múlását epochonként, a zöld szín a ritka, a barna a gyakori tripletteket. A két vonal közötti rés mértéke mutatja a statisztikai tanulást. A hibaszávok a 95% konfidencia intervallumot mutatják.




A modell rögzített hatásokkal is gyenge illeszkedést mutat (feltételes $R^2 = 0,037$). Az előfeltételek tesztelésekor reziduálisok normalitás vizsgálata szignifikáns eredményt adott, tehát a modellem reziduálisainak eloszlása nem normális eloszlású (ld. 1. Melléklet). A heteroszkedaszticitás vizsgálata is szignifikáns eredményt mutatott, ami homoszkedaszticitásra utal az eredményemben (ld. 2. Melléklet). A multikolinearitás viszont megfelelő lett a modellemben ($GVIF < 5$) (ld. 3. Melléklet). A random hatások további mutatóit a 4. Mellékletben írtam le.

Az interferencia szekvenciában egyedül a triplet valószínűségi típusának volt szignifikáns hatása mint főhatás a modellemben ($\beta_{std} = 0,05$; $p = <0,001$; 95% CI [8,16 – 15,09]). Az AQ pontszámoknak ebben a szakaszban sem volt hatása a reakcióidő bejósolásában ($\beta_{std} = -0,03$; $p = 0,304$; 95% CI [-18,61 – 5,8]) (ld. 2. táblázat). A 4. Ábrán látható, hogy a magas és alacsony valószínűségi tripletlek közti reakcióidő különbség szintén jelen van, illetve a

különbség idővel nő. Hasonlóan az eredeti szakasz modelljében tapasztaltakkal, a modellemben a reziduálisok nem normális eloszlásúak, illetve homoszkedaszticitás is megjelenik, de a multikollinearitás megfelelőnek tűnik a modell elemzéséhez (ld. 1-3. Mellékletek). A modell keretén belül vizsgált random hatásokat az 5. Mellékletben írtam le.

4. Ábra

Reakcióidő változásának vizsgálata tripletok valószínűségei szerint az interferencia szekvencia szakaszban (azaz miután a globális szabályszerűség megváltozott). Az y tengely a reakcióidőt mutatja, az x tengely az idő múlását epochonként, a zöld szín a ritka, a barna a gyakori tripleteket. A két vonal közötti rés mértéke mutatja a statisztikai tanulást. A hibasávok a 95% konfidencia intervallumot mutatják.



2. Táblázat

A reakcióidő bejósolására vonatkozó lineáris modell (1. modell) főbb eredményei az eredeti és az interferencia szekvencia szakaszokra vonatkozóan


A reakcióidő vizsgált lehetőséges prediktorai	Eredeti szekvencia szakasza			Interferencia szekvencia szakasza		
	Std. β	95% CI	p-érték	Std. β	95% CI	p-érték
(Metszés)	-0,02	292,34 – 318,93	<0,001	-0,02	286,54 – 310,94	<0,001

Triplet valószínűségi típusa [alacsony]	0,06	10,65 – 17,97	<0,001	0,05	8,16 – 15,09	<0,001
Epoch	-0,01	-5,98 – 3,13	0,539	0,01	-2,69 – 5,42	0,51
AQ pontszám	-0,03	-20,30 – 6,29	0,302	-0,03	-18,61 – 5,8	0,304
Triplet valószínűségi típusa [alacsony]× Epoch	0,02	0,20 – 6,75	0,037	0,01	-1,45 – 4,75	0,297
Triplet valószínűségi típusa [alacsony] × AQ pontszám	0,00	-3,45 – 3,87	0,910	-0,01	-5,87 – 1,06	0,174
epoch × AQ pontszám	-0,01	-5,97 – 3,15	0,545	0,00	-3,67 – 4,44	0,853
Triplet valószínűségi típusa [alacsony]× epoch × AQ pontszám	0,00	-4,37 – 2,18	0,512	0,00	-4,14 – 2,06	0,509
Margonális R ² /Feltételezett R ²	0,002/0,037					

Az eredeti szekvencia szerinti tanulás-függő hiba valószínűségének bejósolásához rögzített hatásokként az epochokat és a centrált és skálázott AQ pontszámot, random hatásként a személyenként eltérő meredekséget építettem be ebbe a lineáris kevert modellbe. Szignifikáns hatása a 4. epoch és az AQ pontszám közti interakciónak volt ($\beta_{std.} = 0,36$; $p = 0,04$; 95% CI [0,02 – 0,71]). A modellre vonatkozó R^2 értékek arra utalnak, hogy a random hatás jelentősen növeli a modell magyarázó erejét (feltételes $R^2 = 0,355$), mintha csak a rögzített hatásokat használnánk (margonális $R^2 = 0,031$) (ld. 3. Táblázat). A modell elemzésének további adatai a random hatásokról az 6. Mellékletben megtalálhatóak. Az eredményeket ábrázolva látható, hogy míg az alacsonyabb AQ pontszámú személyek az eredeti szekvencia szerinti tanulásfüggő hiba valószínűsége az interferencia szakaszban valamennyivel csökken a az első epoch-hoz képest a negyedik epochban, a magas autizmus pontszámú személyeknél ez nem történik meg (lásd 5. Ábra). A szignifikáns interakció ellenére a post-hoc teszt nem mutatott szignifikáns különbségeket sem az 1. és 4. epochok közt ($t = -0,652$; $p = 0,515$), sem más epochok összehasonlításában, így úgy tűnik, hatása jelen modellemben gyenge. (ld. 7. Melléklet).

5. Ábra

Az eredeti szekvencia szerinti tanulásfüggő hiba valószínűségének összefüggése az AQ pontszámmal epochonként. Az x tengely és a színskála az Autizmus Spektrum Kvóciens (AQ) pontszámot mutatja, az y tengely az eredeti szekvencia szerinti nem-tanulásfüggő hibák valószínűségét mutatja, a négy számozott faztta a négy interferencia epochnak felel meg.



Megjegyzés: A fazetták a 4 epochban jelölik az AQ pontszám és az eredeti szekvenciák szerinti tanulás-függő hiba valószínűségének összefüggését. Az egyes epohok körülbelül 5 perces időszavokat jelölnek az interferencia szekvenciában. A szürke sáv a standard hiba intervallumot jelöli.

3. Táblázat

Eredeti szekvencia szerinti tanulás-függő hiba valószínűsége az interferencia szakaszban (2. modell)

<i>Az eredeti szekvencia szerinti tanulás-függő hiba valószínűségének vizsgált prediktorai</i>	<i>Std. β</i>	<i>95% CI</i>	<i>p-érték</i>
(Metszés)	-0.03	2.43 – 2.64	<0.001
Epoch [2]	-0.01	-0.13 – 0.12	0.938
Epoch [3]	0.04	-0.11 – 0.13	0.836
Epoch [4]	0.11	-0.08 – 0.16	0.516

AQ pontszám	-0.12	-0.15 – 0.06	0.418
Epoch [2] × AQ pontszám	-0.05	-0.14 – 0.10	0.756
Epoch [3] × AQ pontszám	0.00	-0.12 – 0.12	0.991
Epoch [4] × AQ pontszám	0.36	0.01 – 0.25	0.040
Margonális R ² / Feltételes R ²	0,031/0,355		

A frissítések gyakoriságának bejósolásához (3. hipotézis) az előző tripletben előforduló hiba típusa (tanulás-függő/nem-tanulás-függő hiba) mellett az AQ pontszám centrált és skálázott értékét állítottam be rögzített hatásként egy generalizált lineáris modellben (3. modell). Random meredekségként az előző hibatípus személyenként eltérő hatását jelöltem meg. Ebben a modellben sem szignifikáns főhatást, sem interakciót nem találtam. A modell normalitása és heteroszkedaszticitása sérült, multikollinearitása megfelelő volt (ld. 1-3. Mellékletek). Az R² értéke a random hatásokkal javult a modellben (feltételes R² = 0,188), de nem mondható ez az érték erősnek.

4. Táblázat

Frissítések gyakoriságának bejósolásához alkotott generalizált lineáris kevert modell (3. modell) főbb eredményei.

<i>A frissítések gyakoriságának vizsgált lehetséges prediktorai</i>	<i>Std. β</i>	<i>95% CI</i>	<i>p-érték</i>	<i>Std. p- érték</i>
(Metszés)	0.31	0.25 – 0.38	<0.001	<0.001
előző hiba típus	1	0.91 – 1.09	0.982	0.978
AQ pontszám	0.96	0.77 – 1.20	0.734	0.734
Hiba típus $\times$ AQ pontszám	0.99	0.90 – 1.08	0.81	0.81
Margonális R ² / Feltételes R ²	0,001/0,188			

Diszkusszió

Kutatásomban azt szerettem volna feltárni, hogy a predikciós feldolgozás milyen sajátosságokat mutat az autizmus spektrumon. Azt találtam, hogy (1) hasonlóan megtörténik az implicit statisztikai tanulás az autizmus spektrumon, (2) korábban megtanult szabály ismétlésének magasabb a valószínűsége a feladat utolsó negyedében az erősebb autisztikus vonással (magasabb az AQ pontszám) rendelkező személyeknél, és (3) hasonló a frissítések gyakorisága és mintázata az autizmus spektrumon. A hipotéziseim megalkotásában a lassú frissítés és a rugalmatlanul magas predikciós hibasúlyozás elméletekre támaszkodtam: egyik elméletet sem sikerült alátámasztanom eredményeimmel hiánytalanul, ugyanakkor a korábban megtanult szabály hosszan fennmaradó ismétlése szabályváltozás után (lásd 2. hipotézis) utal a lassú frissítés elmélet lehetséges jelenlétére.

Az első hipotézisben az implicit tanulás mértékét vizsgáltam, azzal a feltételezéssel, hogy a magas valószínűségű tripletekre gyorsabb reakcióidő társul, mint az alacsony valószínűségű tripletekre. Emellett arra is kerestem a választ, hogy ez a különbség az idő előrehaladtával növekszik-e. Az eredmények alapján a tanulási fázisban (eredeti szekvencia szakasza) idő előrehaladtával nőtt a tanulás mértéke, mely azonban csak tendenciaként volt jelen az interferencia szakaszban. A tanulás mértékének növekedése a feladat során azonban nem függött össze az autisztikus vonások mértékével, a résztvevők ettől függetlenül fejlődtek a statisztikai tanuláson. A feladat probabilisztikus jellegét implicit módon sikerült elsajátítaniuk: a szabályszerűségről nem tudtak a feladat előtt, és utólag rákérdezve, hogy észrevettek-e szabályszerűséget, senki sem tudott beszámolni a szabályról vagy a szabály jellegéről. Habár a lineáris kevert modellek meglepő robosztusságot mutatnak az előfeltételek sérülésére (Schielzeth és mtsai, 2020), az eredményeim általánosíthatóságát limitálja a heteroszkedaszticitás és a reziduálisok normalitásának sérülése. A jövőben mindenképp törekszünk ezen előfeltételek megoldására. A szakirodalom emellett támogatja azt az eredményt, miszerint a tanulás megtörténik ASRT feladatban, amit az erős autisztikus vonások nem befolyásolnak (Zolnai és mtsai., 2022; Pesthy, 2023; Nagy és mtsai., 2025). Többféle kutatási elrendezésben vizsgált metaelemzésekben sem találtak különbséget a prediktív feldolgozásban autisztikus és kevésbé autisztikus személyek közt (Foti és munkatársai, 2015; Obeid és mtsai., 2016).

A második hipotézisemben azt vizsgáltam, hogy az eredeti szekvenciában tanult szabály hibás alkalmazása az interferencia szakaszban összefügg-e az autisztikus vonásokkal. Az eredmények alapján a több autisztikus vonás jelenléte együttjárt az eredeti szabály gyakoribb hibás alkalmazásával az új szabály jelenlétében, de csak a feladat legkésőbbi szakaszában. Ez az eredmény a lassú frissítés elméletére utal, pontosabban: erősebb autisztikus vonásokkal a régebbi tanult szabályt tovább alkalmazzák a személyek, mint az alacsonyabb autisztikus vonásokkal rendelkező személyek. Azonban jelen kutatásban ez a hatás igen gyengének bizonyult. A predikciós feldolgozásban lassú frissítés elméletének alátámasztására más kutatásokban is születtek hasonló eredmények (Lieder és mtsai., 2019; Sapey-Triomphe, 2022). Bár a rugalmatlanul magas hibasúlyozás elmélete ezen eredményem alapján nem tűnik megalapozottnak, a lassú frissítés elméletére sem jelent jelen vizsgálatom konklúzív bizonyítékot.

A predikciós hibák alapján történő frissítésben nem találtam összefüggést az autisztikus vonások mértékével az interferencia szakaszban (3. hipotézis). Ebből úgy tűnik, az erősebb autisztikus vonásokkal rendelkező résztvevők hasonlóan frissítik a prior tudásukat a különböző hibáik alapján. Mindkét elméleti keretben, a lassú frissítés és a rugalmatlanul magas hibasúllyal történő frissítés elméleti keretében a frissítés mikéntje egy lényeges eleme az autisztikus prediktív feldolgozásnak (Van de Cruys és mtsai., 2014; Lieder és mtsai., 2019). A predikciós hibák utáni frissítés szempontja alapján tehát egyik általam vizsgált elméleti kerethez sem tudtam konklúzív bizonyítékot hozzátenni. Ugyanakkor azt, hogy a predikciós frissítés gyakorisága nem függ az autisztikus vonások erősségétől, bizonyos hasonló módszertannal dolgozó kutatások is támogatják (Pesthy és mtsai., 2023).

Kutatásom egyik elsődleges limitációja, hogy nem reprezentatív mintával dolgoztam. A toborzás kényelmi mintavétellel történt, amire főként egyetemisták jelentkeztek, így az eredményeim nem általánosíthatóak a teljes ép intellektusú felnőtt populációra. Továbbá, bár az Autizmus Spektrum Kvóciens lehetővé teszi a teljes populáció vizsgálatát a spektrumszemlélet keretein belül (Baron-Cohen és mtsai., 2001; Hoekstra és mtsai., 2008, Ruzich és mtsai., 2015) érdemes lehet megfontolni a kategorikus összehasonlítást az AQ pontszám alapján (Wheelwright és mtsai., 2010). Emellett több magas AQ pontszámú személy bevonása a vizsgálatba pontosabb képet adhat az autisztikus sajátosságokról (Abu-Akel és mtsai., 2019). Az Autizmus Kvóciens skála az utóbbi években kritikákat is kapott megbízhatóságát illetően (Ashwood és mtsai., 2016). A jövőben érdemes lehet más elérhető

skálákat is használni az autisztikus vonások mértékének megállapítására. Jól használható általános vonások mérésére ép intellektusú felnőtteknél a Ritvo Autizmus Asperger Diagnózis Skála (RAADS-R; Ritvo és mtsai., 2011), illetve más mérőeszközök az autizmus egy-egy releváns vonását megragadva (pl. Mentalizációs kérdőív (MZQ; Hausberg és mtsai., 2019) és a Felnőtt Repetatív Viselkedés Kérdőív (RBQ-2A; Barrett és mtsai., 2018)).

További lehetőséget kínál más elméleti keretek vizsgálata a jövőben. Kutatási elrendezésünk, és a benne található többféle bizonytalanságot jelentő tényező (zajos ingerek, szabályváltozás az interferencia szakaszban) lehetőséget adnak a volatilitás (a világ változékonyságának érzékelése) hatásának vizsgálatára, ami egy fontos tényező lehet az autisztikus prediktív feldolgozásra. Kutatások szerint az erős autisztikus vonásokkal rendelkező személyekre a túlbecsült volatilitás lehet jellemző, ami az általam vizsgált elméleti keretektől abban különbözik, hogy az észlelt volatilitás mértéke az idő előrehaladtával befolyásolhatja a teljesítményt (Lawson és mtsai., 2017; Palmer és mtsai., 2017; Pálffy és mtsai., 2022). További lehetőség még az alacsony precizitású prior elmélete, amely szerint a predikcióalkotás megnyilvánulásában is lehet különbség: az erősebb autisztikus vonásokkal rendelkező személyek kevesebb (anticipációs szemmozgásban megnyilvánuló) predikciót alkothatnak, és jobban támaszkodhatnak a bejövő szenzoros ingerekre (Pellicano & Burr, 2012). Az elméletek tesztelésére a terjedelmi korlátok miatt jelenleg nem volt lehetőség, azonban a jövőben tervezzük a kutatást ezek vizsgálatával kibővíteni.

A autisztikus prediktív feldolgozás jellemzőinek meghatározására törekvő kutatások rendkívül heterogén módszertannal dolgoznak, amit a különböző eredmények és elméleti keretek is tükröznek. ASRT feladat gyakran használt módszer a prediktív feldolgozás vizsgálatára az autizmus spektrumon (Foti és munkatársai, 2015; Obeid és mtsai., 2016), viszont a teljesítmény szemmozgáskövető eszközzel való mérése egy új elrendezés a területen (Zolnai és munkatársai, 2022). Emellett az elrendezés mellett szól többek közt, hogy kifejezetten az implicit prediktív feldolgozás mérésére megfelelőnek tűnik (ld. Bevezetés fejezet), illetve kutatásom eredményein is látszik (1. hipotézis), hogy úgy tanultak, hogy nem ismerték a feladat szabályszerű jellegét, és nem is tudtak beszámolni róla utólag, hogy észrevettek volna ilyet. Ugyanakkor további vizsgálatokra lenne szükség annak az alátámasztásához, hogy az ASRT feladatban nyújtott teljesítményt szemmozgáskövető eszközzel mérve megbízható eszköznek tudjuk nevezni az autisztizmusra jellemző prediktív feldolgozás vizsgálatához.

A prediktív feldolgozás autisztikus fenotípusra jellemző mintázatának vizsgálati eredményeit érdemes lehet a gyakorlatba átültetni, és klinikai implikációként az autizmus-specifikus támogatást eszerint alakítani. Az eredményeim abba az irányba mutatnak, hogy az erős autisztikus vonásokkal rendelkező személyekre a lassú frissítés elmélete lehet jellemző. Ez esetben érdemes lehet az erős autisztikus vonásokkal rendelkező személyeknek a változásokat minél előbb, többször jelezni, hogy a változás bekövetkezésekor felkészültek legyenek. Eredményeim alapján ajánlott lenne több időt hagyni tanulásukra, amely megtörténhet akár visszajelzés és tudatosság nélkül is. Ha elég időt kapnak az információk beépítésére, tovább is alkalmazzák azokat, ami egy kihasználható erősség lehet a fejlesztésben (pl. gyakori szociális forgatókönyvek gyakorlásával).

Összefoglalva, vizsgálatom eredményei a lassú frissítés elmélet sajátosságára utalhatnak autizmus spektrumon. További kutatásokat tervezünk a jövőben. Egyrészt szeretnénk kiküszöbölni a módszertani korlátokat, amik a modelljeinket érintették (ld. 1. hipotézis). Másrészt nagyobb mintát is szeretnénk vizsgálni több erős autisztikus vonásokkal rendelkező személy bevonásával. Harmadrészt érdemes lehet még más eszközökkel mérni az autisztikus vonásokat, illetve a prediktív feldolgozást. A prediktív feldolgozás autisztikus jellemzőinek feltárása hozzásegíthet a jövőben a támogatási módszerek fejlesztéséhez.

Személyes hozzájárulás

Kutatásom az ELTE Nyelv, Emlékezet és Idegtudomány kutatócsoport segítségével készült. Jelen kutatásukhoz egy egyetemi terepgyakorlat keretén belül csatlakoztam, vizsgálatvezetőként az adatfelvételt segítettem több személynél. Személyes érdeklődésem az autizmus spektrumzavar megismerése iránt vezetett a téma mélyebb megértése felé. Témavezetőimmel (Hann Flórával és Pesthy Orsolyával) való konzultációk kiindulópontot adtak a jelenlegi elméletekhez és a kutatási elrendezés adta lehetőségekhez. Ezeket a kiindulópontokat további szakirodalmakkal tágitva foglaltam össze a kutatásom elméleti háttérét, és alkottam meg a kutatási hipotéziseimet. A statisztikai eljárásokat megismerve és elvégezve (témavezetőim ellenőrzésével) kaptam meg a vizsgálatom eredményeit, amiket dolgozatomban értelmeztem. Témavezetőimmel a dolgozatom készítése alatt többször konzultáltam, javaslataikkal segítettek elakadásaimban, kérdéseimben.

Nyilatkozat a mesterséges intelligencia használatáról

Kijelentem, hogy semmilyen MI-technológiával előállított tartalom nem került bemutatásra saját munkaként.

Felhasznált irodalom:

- Abu-Akel, A., Allison, C., Baron-Cohen, S., & Heinke, D. (2019). The distribution of autistic traits across the autism spectrum: Evidence for discontinuous dimensional subpopulations underlying the autism continuum. *Molecular Autism*, 10(1), 24. <https://doi.org/10.1186/s13229-019-0275-3>
- American Psychiatric Association. (1994). Diagnostic and statistical manual of mental disorders (4th ed.). American Psychiatric Publishing.
- American Psychiatric Association. (2013). Diagnostic and statistical manual of mental disorders (5th ed.). American Psychiatric Publishing. <https://doi.org/10.1176/appi.books.9780890425596>
- Ashwood, K. L., Gillan, N., Horder, J., Hayward, H., Woodhouse, E., McEwen, F. S., Findon, J., Eklund, H., Spain, D., Wilson, C. E., Cadman, T., Young, S., Stoencheva, V., Murphy, C. M., Robertson, D., Charman, T., Bolton, P., Glaser, K., Asherson, P., ... Murphy, D. G. (2016). Predicting the diagnosis of autism in adults using the Autism-Spectrum Quotient (AQ) questionnaire. *Psychological Medicine*, 46(12), 2595–2604. <https://doi.org/10.1017/S0033291716001082>
- Baron-Cohen, S. (2000). Theory of mind and autism: A review. In *International Review of Research in Mental Retardation* (Köt. 23, o. 169–184). Academic Press. [https://doi.org/10.1016/S0074-7750\(00\)80010-5](https://doi.org/10.1016/S0074-7750(00)80010-5)
- Baron-Cohen, S., Wheelwright, S., Skinner, R., Martin, J., & Clubley, E. (2001). The Autism-Spectrum Quotient (AQ): Evidence from Asperger Syndrome/High-Functioning Autism, Males and Females, Scientists and Mathematicians. *Journal of Autism and Developmental Disorders*, 31(1), 5–17. <https://doi.org/10.1023/A:1005653411471>
- Barrett, S. L., Uljarević, M., Jones, C. R. G., & Leekam, S. R. (2018). Assessing subtypes of restricted and repetitive behaviour using the Adult Repetitive Behaviour Questionnaire-2 in autistic adults. *Molecular Autism*, 9(1), 58. <https://doi.org/10.1186/s13229-018-0242-4>

- Bralten, J., van Hulzen, K. J., Martens, M. B., Galesloot, T. E., Arias Vasquez, A., Kiemeney, L. A., Buitelaar, J. K., Muntjewerff, J. W., Franke, B., & Poelmans, G. (2018). Autism spectrum disorders and autistic traits share genetics and biology. *Molecular Psychiatry*, 23(5), 1205–1212. <https://doi.org/10.1038/mp.2017.98>
- Csepregi A., & Stefanik K. (2019). Javaslatok az autizmus spektrum-zavar kisgyermekkorai figyelmeztető jeleinek azonosításához. In Csepregi A. (szerk.) *Ajánlások a fejlődési zavarok és az érzékszervi fogyatékoságok szűréséhez, állapot-megismeréséhez*. Budapest: Családbarát Ország Nonprofit Kft.
- De Groot, K., & Van Strien, J. W. (2017). Evidence for a Broad Autism Phenotype. *Advances in Neurodevelopmental Disorders*, 1(3), 129–140. <https://doi.org/10.1007/s41252-017-0021-9>
- Farkas, B. C., Krajcsi, A., Janacsek, K., & Nemeth, D. (2022). *The complexity of measuring reliability in learning tasks: An illustration using the Alternating Serial Reaction Time task*. OSF. <https://doi.org/10.31234/osf.io/5nw4y>
- Foti, F., Crescenzo, F. D., Vivanti, G., Menghini, D., & Vicari, S. (2015). Implicit learning in individuals with autism spectrum disorders: A meta-analysis. *Psychological Medicine*, 45(5), 897–910. <https://doi.org/10.1017/S0033291714001950>
- Friston, K. (2010). The free-energy principle: A unified brain theory? *Nature Reviews Neuroscience*, 11(2), 127–138. <https://doi.org/10.1038/nrn2787>
- Frith, U., & Happé, F. (1994). Autism: Beyond „theory of mind”. *Cognition*, 50(1–3). [https://doi.org/10.1016/0010-0277\(94\)90024-8](https://doi.org/10.1016/0010-0277(94)90024-8)
- Happé, F., & Frith, U. (2006). The Weak Coherence Account: Detail-focused Cognitive Style in Autism Spectrum Disorders. *Journal of Autism and Developmental Disorders*, 36(1), 5–25. <https://doi.org/10.1007/s10803-005-0039-0>
- Happé, F. (2011, március 29). Why fold Asperger syndrome into autism spectrum disorder in the DSM-5? The Transmitter: Neuroscience News and Perspectives. <https://www.thetransmitter.org/spectrum/why-fold-asperger-syndrome-into-autism-spectrum-disorder-in-the-dsm-5/>
- Hausberg, M. C., Schulz, H., Pieglér, T., Happach, C. G., Klöpper, M., Brütt, A. L., Sammet, I., & Andreas, S. (2012). Is a self-rated instrument appropriate to assess mentalization in patients with mental disorders? Development and first validation of

- the Mentalization Questionnaire (MZQ). *Psychotherapy Research*, 22(6), 699–709.
<https://doi.org/10.1080/10503307.2012.709325>
- Hoekstra, R. A., Bartels, M., Verweij, C. J. H., & Boomsma, D. I. (2007). Heritability of Autistic Traits in the General Population. *Archives of Pediatrics & Adolescent Medicine*, 161(4), 372. <https://doi.org/10.1001/archpedi.161.4.372>
- Hoekstra, R. A., Bartels, M., Cath, D. C., & Boomsma, D. I. (2008). Factor Structure, Reliability and Criterion Validity of the Autism-Spectrum Quotient (AQ): A Study in Dutch Population and Patient Groups. *Journal of Autism and Developmental Disorders*, 38(8), 1555–1566. <https://doi.org/10.1007/s10803-008-0538-x>
- Howard, J. H., & Howard, D. V. (1997). Age differences in implicit learning of higher order dependencies in serial patterns. *Psychology and Aging*, 12(4), 634–656.
<https://doi.org/10.1037//0882-7974.12.4.634>
- Horváth, K., Nemeth, D., & Janacsek, K. (2022). Inhibitory control hinders habit change. *Scientific Reports*, 12(1), 8338. <https://doi.org/10.1038/s41598-022-11971-6>
- Jankowska, D. M., Omelańczuk, I., Czerwonka, M., & Karwowski, M. (2019). Exploring links between creative abilities, creative personality and subclinical autistic traits. *Personality and Individual Differences*, 142, 226–231.
<https://doi.org/10.1016/j.paid.2018.05.008>
- Kunihira, Y., Senju, A., Dairoku, H., Wakabayashi, A., & Hasegawa, T. (2006). ‘Autistic’ Traits in Non-Autistic Japanese Populations: Relationships with Personality Traits and Cognitive Ability. *Journal of Autism and Developmental Disorders*, 36(4), 553–566.
<https://doi.org/10.1007/s10803-006-0094-1>
- Lawson, R. P., Mathys, C., & Rees, G. (2017). Adults with autism overestimate the volatility of the sensory environment. *Nature Neuroscience*, 20(9), 1293–1299.
<https://doi.org/10.1038/nn.4615>
- Lieder, I., Adam, V., Frenkel, O., Jaffe-Dax, S., Sahani, M., & Ahissar, M. (2019). Perceptual bias reveals slow-updating in autism and fast-forgetting in dyslexia. *Nature Neuroscience*, 22(2), 256–264. <https://doi.org/10.1038/s41593-018-0308-9>
- Montague, P. R., Dolan, R. J., Friston, K. J., & Dayan, P. (2012). Computational psychiatry. *Trends in Cognitive Sciences*, 16(1), 72–80.
<https://doi.org/10.1016/j.tics.2011.11.018>
- Nayar, K., Sealock, J. M., Maltman, N., Bush, L., Cook, E. H., Davis, L. K., & Losh, M. (2021). Elevated Polygenic Burden for Autism Spectrum Disorder Is Associated With

- the Broad Autism Phenotype in Mothers of Individuals With Autism Spectrum Disorder. *Biological Psychiatry*, 89(5), 476–485. <https://doi.org/10.1016/j.biopsych.2020.08.029>
- Ozonoff, S. (1995). Executive functions in autism. In *Learning and cognition in autism* (o. 199–219). Plenum Press. https://doi.org/10.1007/978-1-4899-1286-2_11
- Pálffy Z., Farkas K., & Polner B. (2022). Mi köze a Bayes-szabálynak az elmegyógyászatához? *NEUROPSYCHOPHARMACOLOGIA HUNGARICA*, XXIV.(1.), 4–16. <https://doi.org/10.13140/RG.2.2.13414.50242>
- Palmer, C. J., Lawson, R. P., & Hohwy, J. (2017). Bayesian approaches to autism: Towards volatility, action, and behavior. *Psychological Bulletin*, 143(5), 521–542. <https://doi.org/10.1037/bul0000097>
- Pellicano, E., & Burr, D. (2012). When the world becomes ‘too real’: A Bayesian explanation of autistic perception. *Trends in Cognitive Sciences*, 16(10), 504–510. <https://doi.org/10.1016/j.tics.2012.08.009>
- Pesthy, O., Farkas, K., Sapey-Triomphe, L.-A., Guttengéber, A., Komoróczy, E., Janacsek, K., Réthelyi, J. M., & Németh, D. (2023). Intact predictive processing in autistic adults: Evidence from statistical learning. *Scientific Reports*, 13(1), 11873. <https://doi.org/10.1038/s41598-023-38708-3>
- Pesthy O. N. (2023). *METHODOLOGICAL AND THEORETICAL ADVANCES IN AUTISM RESEARCH*. Doktori disszertáció. Eötvös Lóránd Tudományegyetem.
- Posit team. (2024). *RStudio: Integrated development environment for R*. (2024.09.0. verzió, "Cranberry Hibiscus") [Szoftver] Posit Software, PBC. <https://www.posit.co/>
- Project Jupyter. (2024). *Jupyter Notebook* (7.2.2 verzió) [Szoftver]. <https://jupyter.org>
- R Core Team. (2021). *R: A language and environment for statistical computing* (4.4.2. verzió) [Szoftver]. R Foundation for Statistical Computing. <https://www.R-project.org/>
- Ritvo, R. A., Ritvo, E. R., Guthrie, D., Ritvo, M. J., Hufnagel, D. H., McMahon, W., Tonge, B., Mataix-Cols, D., Jassi, A., Attwood, T., & Eloff, J. (2011). The Ritvo Autism Asperger Diagnostic Scale-Revised (RAADS-R): A Scale to Assist the Diagnosis of Autism Spectrum Disorder in Adults: An International Validation Study. *Journal of Autism and Developmental Disorders*, 41(8), 1076–1089. <https://doi.org/10.1007/s10803-010-1133-5>

- Rubenstein, E., & Chawla, D. (2018). Broader Autism Phenotype in Parents of Children with Autism: A Systematic Review of Percentage Estimates. *Journal of Child and Family Studies*, 27(6), 1705–1720. <https://doi.org/10.1007/s10826-018-1026-3>
- Sapey-Triomphe, L.-A., Weilhhammer, V. A., & Wagemans, J. (2022). Associative learning under uncertainty in adults with autism: Intact learning of the cue-outcome contingency, but slower updating of priors. *Autism: The International Journal of Research and Practice*, 26(5), 1216–1228. <https://doi.org/10.1177/13623613211045026>
- Stewart, M. E., Watson, J., Allcock, A.-J., & Yaqoob, T. (2009). Autistic traits predict performance on the block design. *Autism*, 13(2), 133–142. <https://doi.org/10.1177/1362361308098515>
- Sucksmith, E., Roth, I., & Hoekstra, R. A. (2011). Autistic Traits Below the Clinical Threshold: Re-examining the Broader Autism Phenotype in the 21st Century. *Neuropsychology Review*, 21(4), 360–389. <https://doi.org/10.1007/s11065-011-9183-9>
- Szegedi-Hallgató, E., Janacsek, K., Vékony, T., Tasi, L. A., Kerepes, L., Hompoth, E. A., Bálint, A., & Németh, D. (2017). Explicit instructions and consolidation promote rewiring of automatic behaviors in the human mind. *Scientific Reports*, 7(1), 4365. <https://doi.org/10.1038/s41598-017-04500-3>
- Tal, A., & Vakil, E. (2020). How sequence learning unfolds: Insights from anticipatory eye movements. *Cognition*, 201. <https://doi.org/10.1016/j.cognition.2020.104291>
- Tobii Pro. (2019) Fusion eye tracker [eszköz és szoftver]. <https://www.tobii.com/products/eye-trackers/screen-based/tobii-pro-fusion>
- Van de Cruys, S., Evers, K., Hallen, R., Van Eylen, L., Boets, B., de-Wit, L., & Wagemans, J. (2014). Precise Minds in Uncertain Worlds: Predictive Coding in Autism. *Psychological Review*, 121, 649–675. <https://doi.org/10.1037/a0037665>
- Volkmar, F. R. (Szerk.). (2021). Encyclopedia of Autism Spectrum Disorders. *Springer International Publishing*. <https://doi.org/10.1007/978-3-319-91280-6>
- Volkmar, F. R., & Reichow, B. (2013). Autism in DSM-5: Progress and challenges. *Molecular Autism*, 4(1), 13. <https://doi.org/10.1186/2040-2392-4-13>
- Wallace, G. L., Budgett, J., & Charlton, R. A. (2016). Aging and autism spectrum disorder: Evidence from the broad autism phenotype. *Autism Research*, 9(12), 1294–1303. <https://doi.org/10.1002/aur.1620>

- Wheelwright, S., Auyeung, B., Allison, C., & Baron-Cohen, S. (2010). Defining the broader, medium and narrow autism phenotype among parents using the Autism Spectrum Quotient (AQ). *Molecular Autism*, 1(1), Article 1. <https://doi.org/10.1186/2040-2392-1-10>
- Woodbury-Smith, M. R., Robinson, J., Wheelwright, S., & Baron-Cohen, S. (2005). Screening Adults for Asperger Syndrome Using the AQ: A Preliminary Study of its Diagnostic Validity in Clinical Practice. *Journal of Autism and Developmental Disorders*, 35(3), 331–335. <https://doi.org/10.1007/s10803-005-3300-7>
- World Health Organization. (1992). International statistical classification of diseases and related health problems (10th revision). <https://icd.who.int/browse10/2019/en>
- World Health Organization. (2019). International classification of diseases for mortality and morbidity statistics (11th Revision). <https://icd.who.int/>
- Zolnai, T., Dávid, D. R., Pesthy, O., Nemeth, M., Kiss, M., Nagy, M., Nemeth, D., & Ergul, A. (2022). Measuring statistical learning by eye-tracking. *Experimental Results*, 3, e10.

Mellékletek

1. Melléklet

1. Melléklet

Lineáris modellek reziduálisainak normalitás tesztelése Shapiro-Wilk teszttel

Lineáris modellek	W-érték	p-érték
Reakcióidő – Eredeti szekvencia	0.79739	< 2.2e-16
Reakcióidő – Interferencia szekvencia	0,68585	< 2.2e-16
Eredeti szekvencia tanulás-függő hiba valószínűség	0,99419	0,7188

Frissítés	0,78002	< 2.2e-16
-----------	---------	-----------

2. Melléklet

Heteroszkedaszticitás tesztelése Breusch-Pagan teszttel

Lineáris modell	<i>p-érték</i> (eltérés a heteroszkedaszticitástól)
Reakcióidő – Eredeti szekvencia	<0,001
Reakcióidő – Interferencia szekvencia	<0,001
Eredeti szekvenciában tanult hiba	0,936
Frissítés	-

3. Melléklet

Multikollinearitás vizsgálatának eredményei varianciainflációs faktoral az egyes modellek rögzített hatásaira

Lineáris modellek	Rögzített hatások az egyes modellekben	<i>GVIF</i>	<i>df</i>
1. Reakcióidő	Triplet valószínűség típusa	1	7
	Epoch	1	7
	AQ-pontszám	1	7
2. Eredeti szekvencia szerinti tanulás-függő hiba az interferencia szakaszban	Epoch	1	3
	AQ pontszám	1	3
3. Frissítés az előző predikciós hiba alapján	Előző hiba típusa	1	3
	AQ pontszám	1	3

4. Melléklet

Random hatások adatai az "1. Reakcióidő" modellben az eredeti szekvencia szakaszában

σ^2	60413,72
τ_{00} vizsgálati személy	1965,61
τ_{11} vizsgálati személy.epoch	190,46

ρ_{01} vizsgálati személy	0,25
ICC	0,04
N vizsgálati személy	44

5. Melléklet

Random hatások adatai az “1. Reakcióidő” modellben az interferencia szekvencia szakaszában

σ^2	53536.80
τ_{00} vizsgálati személy	1715.86
τ_{11} vizsgálati személy.epoch	141.96
ρ_{01} vizsgálati személy	0.18
ICC	0.03
N vizsgálati személy	44

6. Melléklet

Random hatások adatai az “2. Eredeti szekvencia szerinti tanulás-függő hiba az interferencia szakaszban” modellben

σ^2	0.08
τ_{00} vizsgálati személy	0.04
ICC	0.33
N vizsgálati személy	44
Megfigyelések	176

7. Melléklet

Post-hoc teszt eredménye a “2. Eredeti szekvencia szerinti tanulás-függő hiba az interferencia szakaszban” modell alapján

Epochok összehasonlítása a modellben	Becslés	Standard hiba	Szabadságfok	t-arány	p-érték
1. Epoch – 2. Epoch	0.00478	0.0611	126	0.078	0.9377
1. Epoch – 3. Epoch	-0.01265	0.0611	126	-0.207	0.8363
1. Epoch – 4. Epoch	-0.03980	0.0611	126	-0.652	0.5158
2. Epoch – 3. Epoch	-0.01743	0.0611	126	-0.285	0.7759
2. Epoch – 4. Epoch	-0.04459	0.0611	126	-0.730	0.4668
3. Epoch – 4. Epoch	-0.02716	0.0611	126	-0.445	0.6574

8. Melléklet

Random hatások adatai a “3. Frissítés az előző predikciós hiba alapján” modellben

σ^2	3.29
τ_{00} vizsgálati személy	0.53
τ_{11} vizsgálati személy.epoch	0.05
ρ_{01} vizsgálati személy	0.73
ICC	0.19
N vizsgálati személy	44
Megfigyelések	52052