

Kutatási projektünkben azt tűztük ki célul, hogy az epizodikus és szemantikus memóriák kölcsönhatásának vizsgálatával megértsük a hatékony tanulás feltételeit. Ez a problémakör mind a mesterséges, mind pedig a biológiai tanulórendszereket érintő kihívást jelent. Kutatásainkat normatív elméletek inspirálták, s a megvalósított eszközöket biológiai rendszerek kontextusában teszteltük.

A tanulás egy inherensen kihívásokkal tűzdelt folyamat, melynek során a megfigyeléseinket szükséges integrálni a meglévő tudással. Munkánkban a tanuló ágensek kihívásait azon keresztül formalizáltuk, hogy miképpen képesek azok a külvilág modelljeit elsajátítani. Ez a megközelítés a Bayes-i inferencia eszköztárához irányít bennünket, melyben a tanulás célját akként azonosítjuk, hogy inferenciát (következtetést) végezzünk arra nézve, hogy megfigyeléseink milyen okokra, milyen okok kölcsönhatására vezethetők vissza. Ezek a belső modellek tükrözhetik a természetes környezet regularitásait, s ez esetben a cél az, hogy a környezet regularitásain keresztül tudjunk következtetni a memóriarendszerek tulajdonságaira. Alternatív módon a modellek tükrözhetik egy új környezet tulajdonságait, s ekkor a tanulórendszer viselkedésére abból lehet következtetni, hogy a tanulás milyen korlátok mellett valósul meg.

A biológiai rendszerekben a tanulást több memóriarendszer támogatja, ezeknek normatív szerepe nem tisztázott. Mi a gépi tanulás elmélete és a tanulási folyamatok természetes jellemzői alapján fogalmazzuk meg azt, hogy milyen normatív érvek szólnak a párhuzamos memóriarendszerek fenntartása mellett és a gépi tanulás ugyanezen elveiből vezetjük le ezen memóriarendszerek tulajdonságait. Az általunk választott megközelítés erős párhuzamot mutat azzal a megközelítéssel, mely az érzékelési folyamatokat terhelő illúziókat nem az érzékelés hibáiként értelmezi, hanem a megkötésekhez történő optimális alkalmazkodás következményeként (cf. bounded rationality, például az adathoz való -limitált hozzáférést teszi felelőssé bizonyos fajta illúziók bekövetkeztéért). A memóriarendszerek közül a szemantikus és epizodikus memória kölcsönhatásait vizsgáltuk. Az epizodikus memória gazdag mintákat tárol el az adatfolyamból és ezeket részletesen, de szisztematikus torzításoktól nem mentesen tudjuk felidézni. A szemantikus memória ellenben a környezeti változók összefüggéseit, a "világ működését" foglalja össze.

A tanúláshoz hozzájáruló memóriarendszereknél három elméleti és praktikus kihívást azonosítottunk be, melyekhez kötődően sikeres fejlesztéseket végeztünk és ehhez kötődő tanulmányokat jelentettünk meg.

1. Veszteséges tömörítés mély generatív modellek segítségével. A helyes modell felfedezése a tapasztalatok időbeli integrálását igényli, és ekképpen szükség van arra, hogy az adatokat el is tudjuk tárolni. Az erőforrás-hatékony tároláshoz a tömörítés elméletére hagyatkozhatunk. Amikor azonban tanulás zajlik, akkor egy egészen delikát kihívást jelent az, hogy a tömörítés elmélete igényli az adatok eloszlásának ismeretét, mely mennyiség megismerése azonban éppen a tanulás célja. A variációs autóenkóderek elméletén keresztül vezettük be a szemantikus tömörítés elméletét. A szemantikus tömörítés alapján a környezetről elsajátított (felügyelet nélküli tanítással tanított) generatív modell rejtett változóit használjuk fel a megfigyelések tömörítésére. Praktikusan, a rejtett változók veszteséges tömörítést valósítanak meg, s ekképpen Shannon Forrás-Kódolási Elmélete (Source Coding Theorem) adja ennek elméleti hátterét. A kutatás vonzerejét az adja, hogy a gépi tanulás egy kurrens modellje segítségével egy formális keretet állítottunk fel ahhoz, hogy a szemantikus memória miképpen tud az adatok tárolásában részt venni. A generatív probabilisztikus modellek egy elméletileg letisztult, s egyszerismind hatékony eszközének, a Variational Autoencodereknek segítségével mutattuk meg, hogy a szemantikus tömörítés változatos komplex adathalmazokon

működőképes: humán kézi rajzok, sakkjátszmák adatbázisa, és természetes nyelv (specifikusan Wikipedia szócikkek) adataira alkalmaztuk a szemantikus tömörítés elméletét. Munkánkban demonstráltuk azt, hogy a szemantikus tömörítés nemcsak hogy egy hatékony elv arra, hogy adatokat hatékonyan eltároljuk, de képes jóslni azt, hogy milyen jellegű hibák következnek be akkor, amikor eltárolunk, majd felidézünk információt. A szemantikus tömörítés a Source Coding Theorem és Mély Generatív Modellek összekötésén túl a kognitív tudomány számára is új eszközt teremt azzal, hogy természeteshoz közeli bonyolultságú stimulusokkal tesz lehetővé lapborkísérletek végzését. A munka gerincét a PLoS Computational Biology D1-es folyóiratban közöltük és számos nemzetközi konferencián mutattuk be, egy referált konferencia kiadványban közöltünk cikket róla.

A kialakított elméleti keretrendszer egy további, elméletileg is rendkívül izgalmas lehetőségét vizsgáltuk, melyet nem volt időnk tökéletesen kifejteni, csak konferenciamegjenítésig jutottunk, ám a jövőre nézve egy igen vonzó irányt jelöl ki. A rejtett változós reprezentációk tanulásának veszteséges tömörítéssel való kapcsolata elméletileg önmagában is vonzó normatív keretet ad a szemantikus és epizodikus memóriarendszerek kölcsönhatásainak megértéséhez, de egy további értékes bepillantást is enged: a Source Coding Theorem nem csupán egy optimális tömörítést definiál, hanem az elérhető erőforrásoktól függően egy kontinuum megoldást kínál. Egy trade-off keletkezik a ráta-torzítási görbe mentén. Azt javasoltuk, hogy a szemantikus memória egy izgalmas lehetőséget kínál az erőforrás optimalizációra: konkrét megfigyelések haszna időben változik. Például, annak a valószínűsége, hogy egy email releváns még időben lecseng, avagy a hűtő tartalmának ismerete is nyilvánvalóan lecsengő értékű. Ennek megfelelően az adott megfigyeléshez rendelt erőforrást is érdemes optimalizálni. Ennek nyomán tehát érdemes megfontolni, hogy amennyiben a szemantikus memóriát használjuk tömörítéshez, akkor a ráta torzítási görbe mentén haladva más és más tömörítést használjunk az idő előrehaladtával. Az, hogy ez a vonzó elv érvényesül-e a humán memória működéséhez egy kísérletben teszteltük. Egy szintetikus nyelvi adathalmazt konstruáltunk, melyet egy memóriakísérletben teszteltünk. Itt megmutattuk azt, hogy késleltetés függvényében az elmélettel összhangban változik a felidézés teljesítménye. Ezt a munkát a Cognitive Science Society konferenciáján prezentáltuk, egy rövid tudományos ismeretterjesztő anyag készült belőle. A javaslat teljes kiaknázása a projekt perióduson túlmutat.

2. A szemantikus és epizodikus memória közötti kölcsönhatás nem pusztán egyirányú. Normatív érvek szólnak amellett, hogy az epizodikus memória támogatása szükséges ahhoz, hogy a szemantikus modell struktúráját a tanulás folyamán egy tanuló ágens felfedezni legyen képes. A struktúra tanulása egy, az általában megfogalmazott tanulási paradigmákhoz képest egy nagyobb kihívást jelentő feladat: a struktúra tanulás azt a komputációs feladatot jelenti, mikor nem pusztán egy rögzített modellen belül szükséges a helyes paramétereket (általánosabban ezek poszterior eloszlását) megtalálni, hanem azt is fel kell fedezni a tanulás során, hogy mely változók relevánsak, s melyváltozók hatnak kölcsön a modellen. A gépi tanuláson belül egy alterület, melyen a struktúra tanulás egy inherens probléma az élethosszig tartó tanulás, avagy folytonos tanulás problémája. Rámutattunk, hogy amennyiben a modell nem ismert (például a tanulás kezdeti szakaszában), akkor amennyiben pusztán egy, vagy limitált számú modell paramétereit követjük nyomon a paraméter poszterior(ok) online frissítésével, akkor a poszterior által definiált, a modellre jellemző elégséges statisztika megszorítja azt az információt mely az adatról rendelkezésünkre áll, konkrétan egy más, alkalmasint komplexebb modell számára releváns információt eliminál. Emiatt az adatról a paraméter poszterior formájában tárolt információ elégtelen lesz a tanulás későbbi szakaszában ahhoz, hogy a modellünket hitelesen frissíteni tudjuk. Ez a probléma az online tanulásra jellemző alapvető probléma. Ennek kezelésére javasolta pályázatunk azt, hogy adatpontok szelektív eltárolásával a modell akkurátus frissítése optimálisához közeli módon megvalósítható. A korábbi

terminológiánk alapján tehát az epizodikus memória (az adatpontok verbatim eltárolására képes memória) támogatása kritikus a szemantikus memória (a környezet regularitásait összegző modell) online frissítéséhez. Az intuíciót egy szigorú matematikai környezetben kidolgoztuk és beláttuk, hogy néhány kulcsfontosságú mennyiség eltárolásával megvalósítható a tanulás. Mivel konferenciamegjelenések formájában bár prezentáltuk a munkát ám cikk formájában a teljes elméletet nem publikáltuk a pályázat lezárultáig, ezért röviden kifejthetjük itt az elméletet.

A modell struktúra tanulása során azt mérjük, hogy egyes modellek egymáshoz viszonyított statisztikai ereje mekkora. A releváns mennyiség ebben az esetben a modell poszterior, mely két tagból tevődik össze modell priorból és a marginal likelihoodból. Utóbbi a fontosabb mennyiség, mert ez az adatfüggő komponens ezt szeretnénk nyomon követni és kiértékelni alternatív modellekre. Technikai kitérő: azért nevezzük ezt *marginal* likelihoodnak, mert az adott modell paramétereinek lehetséges értékein marginalizálunk. Amikor kimondjuk, hogy a marginal likelihood adatfüggő mennyiség, rögvest érzékelhetjük is az online tanulás inherens problémáját: online tanulás során az adatot nem tartjuk meg, hanem a modell paraméterek frissítésével őrzünk meg az adatról egy "elégséges statisztikát", ám amennyiben a tényleges modell nem ismert, akkor szükségképpen egy másik, aktuálisan legjobbnak vélt, modellről lesz csupán elérhető statisztikánk, de nem a valódiról, s még kevésbé a tényleges adatról. Ezt az alapvető kihívást kívánjuk áthidalni a következőkben.

A marginális eloszlás $p(D | M_i) = \int p(D | \theta, M_i) p(\theta | M_i) d\theta$, ahol M_i a modell struktúrát jelzi, mely alatt az adat likelihood ki van értékelve, θ pedig a paramétereket) egy bonyolult, komputációsán drága mennyiség. Amennyiben azonban a paraméter poszterior $p(\theta | \text{Data}, M_i)$ ismert, akkor iteratíván számolható. Amit át kell azonban hidalnunk, az a poszterior csak az aktuálisan nyilvántartott modellre érhető el, egy újonnan látóképbe került modellre nem (lehetséges egy modell helyett véges sok modellt nyomon követni, ez az érvelést nem változtatja meg, hiszen a nyomonkövetett modellek halmaza nem garantáltan tartalmazza a valós modellt). Ahhoz, hogy ezt a problémát megoldjuk, két normatívan motivált javaslattal élünk. 1, a tényleges adat hiányában, mivel a paraméter poszterior a legvonzóbb lehetőség az adat ismeretére, a poszteriorból szintetizált adatra támaszkodunk, ezt nevezzük generatív visszajátszásnak (generative replay). Ez a megoldás a machine learningben ismert fogalom, a mi megoldásunk a poszterior számoltatása nyomán egy első elvekkel jól támogatott megközelítést jelent. A generatív visszajátszás szenved azonban egy mély ellentmondástól: ez csak a jelenlegi modell számára releváns részleteit tárolja az adatnak. Amit azonban nem tud tükrözni a generatív visszajátszás által szintetizált adat, az éppen az az aspektusa az adatnak, mely motiválná a modellváltást. Ha tehát elérhető a poszteriorból szintetizált adat és a jelenlegi megfigyelésünk, akkor pusztán az utolsó megfigyelésnek kellene elegendő statisztikus erőt biztosítani ahhoz, hogy az új modell marginal likelihoodja a korábbi fölé kerekedjen. Ez általában nem megfelelő megközelítés, hiszen adatpontokon integrálva szerezhet szükséges statisztikus erőt egy bonyolultabb modell, amennyiben a két modell egyébként hasonló (technikailag: a prediktív eloszlásuk $p(x|D, M_i)$, ahol x az utolsó adatpont) erősen átfed). Ezért fogalmazzuk meg a második javaslatunkat: azon adatpontokat, melyek a jelenlegi modellel nem kongruensek (azaz nem jól illeszkednek a jelenlegi modellhez) nem integráljuk a poszteriorba, hanem egy külön memóriabuffert hozunk létre számukra, az epizodikus memóriát. Az epizodikus memória tehát egy véges kapacitású tároló, melyben verbatim el tudunk tárolni adatpontokat. Amit munkánkban beláttunk, az az, hogy a modellel való kongruencia mérésére alkalmas mennyiség a korábban bevezetett prediktív eloszlás: a prediktív eloszlás azt méri, hogy a jelenlegi megfigyelés valószínűsége mekkora a jelenlegi modell alatt a korábbi megfigyelések fényében. Levezettük, hogy egy vonzó tulajdonsága a prediktív eloszlásnak az, hogy a marginal likelihoodból közvetlenül számolható. Ekképpen

tehát arra, hogy ki tudjuk értékelni azt, hogy egy adatpontot integrálni érdemes a jelen modellbe, avagy inkább epizodikus memóriában kellene eltárolni azt meglévő mennyiség segítségével el tudjuk érni: a poszteriorból származtatható marginal likelihoodot kell csupán kiértékelnünk. Illetéknéppen a két pontban megfogalmazott javaslatunk mindkét eleme ismert mennyiségekből elérhető: a generatív visszajátszás azokra az adatpontokra, melyek kongruensek a jelen modellel megvalósítható a modell poszterior segítségével, ám amikor alternatív modelleket értékelünk ki, akkor nem pusztán ezekre a szintetizált adatokra és a legutolsó megfigyelésre számíthatunk, hanem a szintén a poszterior áttételes segítségével beazonosított epizodikus memóriában tárolt adatpontokra is.

A fenti elméletet teszteltük egy folytonos tanulási paradigmában, melyben egy mérsékelt komplexitású természetes stimulushalmazon kellett döntéseket meghozni két különböző szabály szerint. A döntések alapján kapott visszajelzést az ágens, égy a stimulus—visszajelzés kontingenciák segítségével tudta a szabályokat elsajátítani. A stimulus egy absztrakt két dimenziós tulajdonságtéren volt értelmezve, ezen két dimenzió szerint változtatva lehetett szintetizálni természetes stimulusokat. A tanulmány fókuszában az állt, hogy megértsük azt, hogy mi befolyásolja azt, hogy a gépi tanulásban elérhető, a folytonos tanulás megoldására javasolt megoldások markánsan különböznek az emberi tanulástól abban, hogy mely tréning stratégiák hatékonyak, s melyek olyanok, hogy a hatékony tanulást meggátolják. Ezen túl szerettük volna megérteni azt, hogy az emberi tanulásban megfigyelhető limitációk azok hibák, avagy a stimulus + feladat kombinációjából adódó természetes korlátok, azaz az emberi tanulás hogyan viszonyul optimalitási kritériumokhoz. Specifikusan, azt vizsgáltuk, hogy az epizodikus memóriával támogatott modelltanulás elmélete hozzá tud-e segíteni egy mesterésges ágenst ahhoz, hogy ne csupán a két feladat próbáinak összefésülésével nyert adathalmazon lehessen hatékony tanulást biztosítani, hanem blokkosított tréninggel is. Ez a probléma kritikus, hiszen a folytonos tanulásban a legfőbb jellemző éppen az, hogy feladatok egymásutánjával szembeül a tanulórendszer, s nem hagyatkozhat arra, hogy időben közel megközelítőleg a stimulus statisztikát jól modellező adathalmazhoz tud hozzáférni. Az elméletileg jól megalapozott és a gépi tanulás eszközei t hatékonyan integráló folytonos tanulórendszerünk képes a blokkosított tanulás során helytállni, bemutattuk, hogy az összefésült tanulás során az emberek esetében tapasztalt limitációk érzékeléshez köthető kihívásokhoz köthető. Végül megvizsgáltuk annak okát, hogy az emberek esetében megfigyelt konstraintív mintázat, nevezetesen, hogy egyértelmű instrukciók és vizuális jelzések ellenére is a feladat komplexitásának növelésével drasztikusan növekszik annak valószínűsége, hogy két feladat elsajátítása helyett a két feladat közötti interpolációt tanulnak. Analízisünk megmutatta, hogy a feladatban rejlő perceptuális kihívások hasonló konstraintív viselkedéshez vezetnek. A munkát a NAISys (From Neuroscience to Artificially Intelligent Systems, Cold Spring Harbor, NY, US) konferencián mutattuk be, és teljes publikációját a pályázat időtartamán túl valószínűsítjük meg.

Ugyanezen folytonos tanulási probléma nem probalisztikus, hanem az ANN-hez (artificial neural network) közelebb eső megoldást kerestünk. Itt munkánkkal bebizonyítottuk, hogy a biológiailag inspirált Hebbi jellegű tanulási szabály hozzá tud járulni ahhoz, hogy blokkosított adat esetén is hatékonyan lehessen tanulni. A munkát a PLoS Computational Biology D1-es szaklapban prezentáltuk.

3. A kutatási projekt utolsó eleme azt tűzte ki célul, hogy a szemantikus memória tényleges struktúrájának visszafejtéséhez fejlesszünk eszközöket. Az ember gép interakciók fejlesztéséhez kritikus az, hogy érteni lehessen azt, hogy a humán partner milyen tudással rendelkezik a környezetéről. Tradicionálisan egy ideális megfigyelőt feltételezve lehet jóslatokat tenni arra, hogy milyen döntéseket fog hozni. Ez azt feltételezi, hogy a humán ágens a környezettel kölcsönhatva arról hatékonyan szerez információt és tanul. Ez a feltételezés

legtöbbször ambiciózus: a tanulás tökéletlen és az elsajátított reprezentációk egyénről egyénre változnak. Emiatt viszont szükség van olyan eszközökre, melyekkel karakterizálni lehetséges az egyedileg tanult reprezentációkat. Ehhez mi a viselkedésből szereshető adatokra támaszkodunk, és egy olyan, a gépi tanulás fejlett eszközeire támaszkodó eszközt fejlesztettünk, mely relatív kevés adatból komplex reprezentációk kikövetkeztetésére volt képes. A módszer egyénre szabott reprezentációkat képes felfedni reakcióidő adatok méréséből. Ezen a reprezentációkról bebizonyítottuk, hogy feladatokon átívelően képesek generalizálni az egyének tudásáról megszerzett információkat, hiszen azt is lehetett jóslni a kizárólag a helyes döntések reakcióidő adatait felhasználó módszerrel, hogy a kísérleti résztvevők mikor követnek el hibákat. A kifejlesztett módszer, mely a korábban általunk fejlesztett Kognitív Tomográfia módszernek jelenti általánosítását kiemelkedő módon szubjektív, egyedi, próba-szintű jóslatokat képes tenni reakcióidők mérésével, mely alapot ad ahhoz, hogy előrelépéseket tenni általánosabb ember gép interfészekhez.

A fejlesztett módszert felhasználtuk arra, hogy feltérképezzük, hogy hogyan járul hozzá a korábban elsajátított tapasztalat egy új, laboratóriumi környezetben tanult feladat elsajátításához. Egyéni szinten fel tudtuk fedni azt, hogy egy, kísérleti populáción homogén kezdeti inductive bias miképpen formálódik az új tapasztalat által. A kezdeti inductive bias-ról megállapítottuk, hogy ez a környezet dinamikus viszonyait jellemző általános torzítás, mely bár képes segíteni a környezet felfedezését természetes körülmények között, ám éppen az általunk kialakított laboratóriumi körülmények között hátráltatta a tanulást. Ez az analízis lehetőséget termet arra, hogy a magas szintű generalizáció tulajdonságait tudjuk vizsgálni.

A kutatás eredményeit a D1-es besorolású PLoS Computational Biology folyóiratban közzöltük, referált konferenciaközleményt jelentettünk meg róla és több nemzetközi konferencián prezentáltuk előadás és poszter formájában.

Összefoglalva, a pályázati időszakban az epizodikus és szemantikus memória kölcsönhatásait normatív eszközökkel tudtuk vizsgálni. A mély generatív modellek használatával a veszteséges tömörítés elmélete és a rejtett változós felügyelet nélküli tanulás közötti kapcsolatot teremtettünk meg. Rámutattunk ,hogy a generatív modellek akkor tudnak támogatást jelenteni a hatékony tömörítéshez, amikor a klasszikus elméletek alapfeltételei nem teljesülnek. Az emberi memóriára kontextusában az "optimális felejtés" matematikai háttérét adtuk meg. Ennek a kutatásnak a szélesebb körű relevanciája az out-of-distribution adatok tárolásában azonosítható be. A folytonos tanulás témakörében mind ANN, mind probalisztikus tanulási kontribúciókat tettünk. Végül pedig módszert fejlesztettünk arra, hogy humán kísérletekben egyedi szemantikus modelleket vissza tudjunk fejteni viselkedési adatokból. A kutatások során a gépi tanulás eszköztárát (mély generatív modellek és nemparemetrikus dinamikus rejtett változós modellek) fejlesztettük és alkalmaztuk humán adatokra, ezzel bővítve a diszciplína eszköztárát és új távlatokat nyitva meg azelőtt, hogy komplex környezetben elsajátított tudást karakterizáljuk. Ezek az eredmények lehetőséget teremtenek az elsajátított tudás karakterizálásának formalizálásához, mely minden képzési szituációban egy kritikus kérdés tud lenni, valamint hozzájárul az élethosszig tartó tanulás, tudástraszfer elméletének megértéséhez.

A projekt nem csak számos D1-es cikk, nemzetközi konferencia előadás és poszter formájában hasznosult, de tutorialokon keresztül a helyi közösségben és nemzetközi nyári iskolákban is a metodológiai tudást továbbadtuk, ezzel is szélesítve a fejlesztések hatását.

A kutáshoz tartozó közlemények publikációk

Hazai: aime 2018: learning from reverse engineering human intelligence and engineering artificial intelligence

Inference of individual internal dynamical models, Torok, BME Phd konferencia

CEU Dept Cog Sci Seminar David G Nagy, Interactions of Episodic and Semantic Memory

ELTE Pszichológiai Tanszék Szeminárium, 2022 Episodic memory for hypothesis testing

ELTE Pszichológiai Tanszék Szeminárium, 2019 Interactions of Episodic and

Semantic Memory David G. Nagy, Balázs Török, Gergő Orbán

Eötvös kollegium 2022, Physics of the Mind

Látás szimpózium 2018, Kognitív tomográfia reakcióidőadatok felhasználásával

Magyar Pszichológiai Társaság konferenciája, Kognitív tomográfia Reakcióidőadatok felhasználásával

SZTAKI szeminárium Semantic compression and rate distortion theory for memory representations David G. Nagy, Balázs Török, Gergő Orbán

Nemzetközi

Poster: Cosyne 2021 Modelling continual learning in humans with Hebbian context gating Timo Flesch, David Nagy, Andrew Saxe, Christopher Summerfield

Poster: DuCog18 Cognitive Tomography with Reaction Times, Balázs Török, Dávid G. Nagy, Karolina Janacsek, Dezső Németh, Gergő Orbán

Poster: DuCog18 Semantic compression of episodic memories David Nagy, Balázs Török, Gergő Orbán

MPI for Biological Cybernetics, Tübingen, A normative account of episodic memory, Dávid G. Nagy

Poster: NaiSys 2022 Episodic memory and generative replay for online structure learning, David G. Nagy, Mate Buki, Gergő Orbán

Poster: CogSci 2022 Forgetting in delayed recall as generative compression with decreasing capacity, Csenge Fráter, Dávid G. Nagy, Gergő Orbán

Talk: Bernstein 2020 Tracking the trade-off between inductive biases and evidence

Referált cikkek

Flesch T, Nagy DG, Saxe A, Summerfield C (2023) Modelling continual learning in humans with Hebbian context gating and exponentially decaying task signals. PLoS Comput Biol 19(1): e1010808. <https://doi.org/10.1371/journal.pcbi.1010808>

Török B, Nagy DG, Kiss M, Janacsek K, Németh D, Orbán G (2022) Tracking the contribution of inductive bias to individualised internal models. PLoS Comput Biol 18(6): e1010182. <https://doi.org/10.1371/journal.pcbi.1010182>

Nagy D, Török B, Orbán G (2020) Optimal forgetting: Semantic compression of episodic memories. PLoS Computational Biology, 16(10): e1008367

Referált nemzetközi proceedings

CCN18 Semantic Compression of Episodic Memories, David G. Nagy, Balázs Török, Gergő Orbán

CCN18 Inference of dynamic probabilistic internal representations from reaction time data. Balázs Török, David G. Nagy, Janacsek Karolina, Dezső Németh, Gergő Orbán

CCN19, Rate distortion trade-off in human memory, David G. Nagy, Balázs Török, Gergő Orbán

CCN19 Hierarchical semantic compression predicts texture selectivity in early vision, Mihály Bányai, Dávid G. Nagy, Gergő Orbán

CogSci18 Semantic Compression of Episodic Memories, David G. Nagy, Balázs Török, Gergő Orbán, DOI:10.32470/ccn.2018.1050-0, also at arXiv:1806.07990

Tudományos ismeretterjesztés

ERCIM News

Képzés (nemzetközi)

Tutorial: Dávid Nagy, Variational Autoencoders, Eastern European Machine Learning Summer School, EEML, Budapest

Tutorial: Gergő Orban , Dávid Nagy, CEU