



Címlapon: A sárgásbarna alga (*Chrysophyta*) kitartóképlete (Buczkó Krisztina felvétele)

- 931 Első kézből  
• **MÁR A RÓMAIAK IS BÁLNÁRA VADÁSZTAK**  
Kovács Márk  
• **KULCSTECHNOLÓGIA A KVANTUMKOMMUNIKÁCIÓBAN**  
Szilágyi-Nagy Ildikó  
• **MEGFORDULHAT AZ ÁRAMLAT?**  
Ferenc Kata
- 934 Tengerszemek és klímakutatás 3.  
**ŐSKÖRNYEZET-REKONSTRUKCIÓ, SZÁMSZERŰEN**  
Buczkó Krisztina, Korponai János, Magyarai Enikő
- 938 Halo, biometrikuskesztyű, szupersisak  
**A FORMA-1 BIZTONSÁGNÖVELESE**  
Kutasi Csaba
- 941 Neurális hálózatok  
**SÚLYZSONGLÓRKÖDÉS**  
Reizinger Patrik

- 944 Tárgyak történettel  
**DÍSZTÖRÜLKÖZŐ – ÉGI ÉS FÖLDI JELENSÉGEKKEL**  
Katona Edit
- 945 Óramutató



**ÓRAJÁTÉK SZÉKESFEHÉRVÁRON**


- Trupka Zoltán
- 946 Csillagnaptár  
**AUGUSZTUS**  
L.H.
- 948 A Tomory Lajos Múzeum kiállítása  
Szécsi Margitról  
**A LÁTHATÓ EMBER**  
Szabó Zsófia Lilla
- 949 Eredményes matekosok  
**VERSENGŐ VERSENYEK**  
Tegzes Mária
- 950 Élet és tudomány képekben



**ÉT-GALÉRIA**

H.J.

- 952 LogIQs
- 953 Lélektani lelemények  
**EMLEKKÉPEINK**  
Mannhardt András
- 954 A tudomány világa  
• **VALÓBAN KÉPESEK BÚTOROK ÖSSZESZERELÉSÉRE A ROBOTOK?**  
Reichardt Richárd  
• **KAMERA FORMATERVEK MŰVÉSZI FOKON**  
G.Á.  
• **ÉVGYŰRŰK A DINÓCSONTON**  
K.M.  
• **A VÁROSI LÉT ELŐNYEI – POSZMÉHEK SZÁMÁRA**  
Pongrácz Péter



• **ISMÉT ELHALASZTOTTÁK AZ ŰRTELESZKÓP FELLÖVÉSÉT**  
Landy-Gyebnár Mónika

- 957 **REJTVÉNY**  
Schmidt János
- 958 **ÉT-IRÁNYTŰ**  
Bánsághy Nóra
- 959 A hátlapon  
**A PÁLMAGERLE**  
Bankovics Attila

## Kedves Olvasónk!

Testvérlapunk, a Természet Világa idén is meghirdette Diákpályázatát, a korábbi évekhez képest néhány ponton módosított pályázati felhívásával. A pályázaton indulhat bármely közép fokú iskolában a 2018/2019-es tanévben tanuló vagy végző diák, határainkon belülről és túlról. A pályázat terjedelme 8000–20 000 betűhely (karakter-szám, szóközökkel együtt), tetszőleges számú illusztrációval. A kéziratot három nyomtatott példányban kérjük. A nyomtatott változattal együtt a pályázatot CD-n (vagy DVD-n) is kérjük megküldeni, a szöveget Word formátumban, a képeket, ábrákat külön fájlban (JPG vagy TIFF). Alapvető követelmény, hogy a cikkek olvasmányosak, stilisztikai és helyesírási szempontból kifogástalanok legyenek. Kérjük a felkészítő tanárokat, szíveskedjenek e tekintetben is útmutatást adni tanítványaiknak. Ne feledjük, hogy a diákpályázat cikkírói pályázat is, ezért a dolgozatokat úgy kell megírni, hogy annak tartalmát a természettudományok iránt érdeklődő, de a témában nem járatos

olvasók is megértsék. A pályamunkák végén kérjük a felhasznált irodalmat és forrásmunkákat megjelölni. A szó szerinti idézetek forrásának fel nem tüntetése etikai vétség, és a dolgozatnak az értékelésből való kizárásával jár.

A pályázatnak tartalmaznia kell készítője nevét, lakcímét, e-mail címét, telefonszámát, iskolája pontos címét irányítószámmal együtt, valamint felkészítő tanára nevét és elérhetőségét. A helyi (iskolai) fordulón továbbjutó dolgozatok benyújtásának (postai feladásának) határideje mindegyik kategóriában **2018. december 7.** A pályázat beadható személyesen (1088 Budapest, Bródy Sándor utca 16.), vagy postán (1444 Budapest, 8. Pf. 256.).

Pályázati kategóriák: Természettudományos múltunk felkutatása és a kultúra egysége, Önálló kutatások, elméleti összesszégzések, Matematika és informatika, Egészségtudomány.

Minden kategóriában I. díj, II. díj, III. díj, valamint a zsűri döntésével több, arra érdemes írásnak különdíj is kiadható. A zsűri a díjazott diákok felkészítő tanárainak a munkáját is értékes jutalmakkal ismeri el.

A részletes kiírás megtalálható a folyóirat honlapján, s a nyomtatott Diákmellékletben több alkalommal is.

**A SZERKESZTŐSÉG**

# SÚLYZSONGLÓRKÖDÉS

**A mély neurális hálózatok széleskörű elterjedését az elmúlt évek tudományos és technikai eredményei jelentős mértékben felgyorsították, ennek is köszönhetően például fordítási, képfelismerési feladatok esetében sikerült emberi képességekkel vetekedő eredményeket elérni.**



**A** neurális hálózatok megközelítésmódja eltér a hagyományos, analitikus modellektől: itt ugyanis nem formulák segítségével, explicit módon történik az eredmény kiszámítása, hanem a rendelkezésre álló adatok függvényében kerül sor a kezdeti modell paramétereinek finomhangolására.


A koncepció megértéséhez először tekintsük a neurális hálózatok egy egyszerű modelljét: a hálózat bemenetére táplált adatok egy előre definiált, hálózati struktúrán, gráfon haladnak végig, mely csomópontjaiban nemlineáris matematikai műveleteket végzünk a bemeneti adatokon. Ezt minden rétegre (melyek száma több száz is lehet) elvégezzük, végezetül pedig az eredményt összehasonlítjuk az elvárt értékkel (ezt nevezik felügyelt tanulásnak), majd egy, a problémához illeszkedő hibafüggvény (például euklideszi távolság) segítségével kiszámított hibát a hibavisszaterjesztés (backpropagation) algoritmusa segítségével visszacsatoljuk a hálóba.

Ennek során a gráf csomópontjaiban tárolt információt, a súlymátrixokat hangoljuk a pontosabb eredményt elérése érdekében. A tanítás során kiszámítjuk, hogy a kimeneten mért hibához az adott csomópont súlya milyen mértékben járul hozzá (ennek számszerűsítésére használjuk a *gradienst*).

## Árnyékok Platón barlangjában

A kutatás célja, hogy a tanítási folyamat során olyan új, közvetlenül a súlymátrixokat módosító módszereket dolgozzunk ki, melyek segítségével a modellek általánosítóképessége javítható, vagyis, hogy a hálózat a valóságról minél univerzálisabb leírást legyen képes szolgáltatni

Gyakran hasonlítják a neurális hálózatokat az emberi idegrendszerhez, jelen cikk azonban egy klasszikus



**Neurális hálózat általános felépítése, a kutatás tárgyaként szolgáló súlymátrixok az elemi neuronokhoz vannak hozzárendelve**

analógiát, Platón barlanghasonlatát használja fel a kutatás mögötti intuíciónak, illetve a javasolt módszereknek a bemutatására. Habár elsőre a választott hasonlat merőben furcsának tűnhet, fontos kiemelni, hogy mély hálózatok esetén az analitikus módszerek levezetése roppant bonyolult, még problémáspecifikus esetben is, így az intuitív, illetve empirikus megoldásoknak jelentős szerepe van.


Tekintsünk tehát egy sötét barlangot, melyben kora gyermekkoruktól leláncolt emberek élnek, a valóságról pedig pusztán a dolgok árnyékai alapján tudnak következtetéseket levonni. Ezen emberek célja ismereti szempontból az, hogy a rendelkezésre álló szűkös mennyiségű, torzított információ alapján a lehető legpontosabb képet alkossák a világról – pontosan ez a célja a neurális hálózatoknak is, korlátozott mennyiségű adatból következtetni a dolgok lényegét reprezentáló látens tulajdonságokra.

Adódik a kérdés, hogy milyen lehetősége van a barlangban élő embereknek arra, hogy céljukat elérjék. Amennyiben egyénileg elhatározzák, hogy képességeiknek megfelelően minden megtesznek annak érdekében,

hogy megjegyezzék a számukra elérhető információkat, akkor ezen törekvésük kezdetben látványos előrehaladást fog produkálni, egyéni korlátjukat megközelítve azonban a folyamat lelassul, majd teljesen megáll. Vagyis az adott személyek kognitív kapacitása, csakúgy, mint a neurális hálózatok reprezentációs képessége, határok közé van szorítva.

Ez azonban első megközelítésben nem tűnik leküzdhetetlen problémának: hiszen nem kell mást tenni, csak több embert kell bevonni az árnyékok kategorizálásába – vagyis nagyobb és több rejtett rétegre van szükségünk a hálózatban (rejtett réteg alatt a be- és kimeneti réteg között elhelyezkedő rétegeket értjük).

Azonban ez a megközelítés csak a rendelkezésre álló ismeretekre történő minél jobb modell illesztését veszi figyelembe, nem célja az általánosítás. Gondoljunk csak bele a következőbe: hőmérsékletet szeretnénk előrejelezni korábbi mért értékek alapján. Az egyik megoldás, hogy elvégezzünk  $n$  darab megfigyelést, majd az így kapott mintapontokra valamilyen görbét illesztünk. Amennyiben a polinom fokszámát



A túltanulás jelenségének szemléltetése hőmérséklet-előrejelzés példáján

( $n-1$ )-re, azaz maximálisra választjuk, akkor a görbe minden mintapontra biztosan tökéletesen illeszkedni fog, azonban ennek megvannak a maga hátrányai is.

Ugyanis a görbe igencsak „kanyargós” lesz a minél jobb illeszkedés érdekében, és szinte biztosra vehetjük, hogy az újonnan mért értékek nem fognak illeszkedni, tehát a modellünk általánosítóképessége rendkívül alacsony – annak ellenére, hogy a rendelkezésre álló, a priori adatokat tökéletesen leírja.

Ezt a jelenséget nevezzük túltanulásnak, detektálását pedig általában a gépi tanuló algoritmusok, mint például neurális hálózatok tanításának leállítására alkalmazzuk. Ezt úgy valósítjuk meg, hogy kétféle hibát mérünk, a tanítóadatokon mért tanítási, valamint a csupán ellenőrzés során használt mintapontokra definiált validációs hibát. Utóbbinak az a lényege, hogy a predikciót szimulálja, ugyanis azt tudjuk vele meghatározni, hogy milyen pontos a modellünk, ha a tanítás során nem ismert, a posteriori adatpontokon mérjük vissza annak teljesítményét.

Ezen megfontolások alapján a következő eljárás körvonalazódik: tanítsuk addig a modellt, amíg a validációs hiba csökken, majd ha az elkezd növekedni (ami jelentheti azt, hogy a tanító adatokon mért hiba továbbra is csökken, vagyis bekövetkezik a túltanulás), akkor álljunk le a tanítással – kis egyszerűsítéssel ez az *early stopping* technika. Itt az angol

terminológia kissé félrevezető, ugyanis korántsem arról van szó, hogy túl korán állítanánk le a háló tanítását, hanem az adott körülmények között elérhető optimumban. A technika lényegét kifejező magyar megnevezés hangozhatna akár „felügyelt megállítást”-ként, azonban a fogalmak magyar nyelvre történő átültetése nem jellemző.

Tehát egy bizonyos, feladatfüggő szintet elérve a hálózat méretének, s így reprezentációs kapacitásának növelése több kárt okozhat, mint hasznot.

### Trükközés az adatokkal


A probléma aktívan foglalkoztatja a kutatókat, így számos technika létezik annak csökkentésére. Az egyik etalonnak számító (heurisztikus) technika a Torontói Egyetem kutatóinak

névéhez (Geoffrey Hinton, Nitish Srivastava) köthető Dropout, melynek lényege, hogy a neuronháló összeköttetéseinek egy részét a gráfban minden egyes iterációban bizonyos valószínűséggel deaktiváljuk. Így tehát lényegében olyan eredményt érünk el, mintha több hálózatot tanítanánk, majd az eredményt aggregálnánk – viszont nincs szükség több háló implementálására.

Máskor az adatok kiterjesztéséről (*data augmentation*) várunk jobb eredményeket, szemléletes példával élve képfelismerési feladat esetében a rendelkezésre álló képeket elforgathatjuk, skálázhatjuk, zajt adhatunk hozzájuk, ezzel pedig jobban közelíthetjük a látens eloszlást. A módszer azonban nyilvánvalóan csak kis mértékben képes javítani az eredményeinket, ugyanis az adatok alapját ugyanazok a képek jelentik – nem említve az így felmerülő tárhelyet, illetve tanítási időt (hiszen több mintánk van) érintő pluszköltségeket.

Az eddig ismertetett megoldások alapvetően egyféle megközelítésmódot alkalmaztak: közvetlenül az adatokon, illetve az adatfolyamon eszközölt módosításokat a jobb eredmény elérése érdekében. Ezzel szemben létezik a megerősítéses tanulás (*reinforcement learning*, az emberi tanulás folyamatához közeli, a tanulási/tanítási folyamatot valamilyen jutalom/büntetés mértékétől függővé tevő megközelítés) terén alkalmazott technika is, mely közvetlenül a súlymátrixokat helyezte fókuszába. Mégpedig zaj hozzákeverésével látványosan javítottak a kutatók a modell képességein.

A túltanulás detektálása, az *early stopping* lényegi bemutatása



## Rázva és felejtve

A korábbiakban állítottuk, hogy a súlymátrixok alkotják a modell magját, hiszen ezek a struktúrák tartalmazzák a megszerzett ismereteket (például a beágyazási technika kifejezetten csak a súlyokban érdekelt, a tanulási folyamat végén a kimeneti réteget el is hagyja, csak a súlymátrixokat nyeri ki a modelltől).


A kutatás során megvizsgált két módszer mögött rejlő intuíció megértéséhez térjünk vissza egy pillanatra Platón hasonlatának hányattatott sorsú elszenvédőire.

Tételezzük fel, hogy példánkban az örök nem annyira engedékenyek, mint Platón esetében, így a rabok közül senkit nem vezetnek fel a napfényre, azonban alkalomadtán lehetővé teszik a szomszédok számára a helycserét. Az ezáltal megnyíló új nézőpont hozzá fogja segíteni a leláncolt embereket, hogy jobban megismerjék a valóságot, de mindösszesen inkrementális lépésekről van szó.

Ezt mi is megtehetjük a tanítás során, ha a súlymátrixok elemeit lokálisan megkeverjük, felcseréljük. A művelet lokális volta annak következtében hangsúlyozandó, hogy amennyiben ilyen korlátot nem vezetünk be, az olyan mértékben megnövelheti a kimeneten mért hibákat, hogy a hálózaton nem lesz lehetősége konvergálni, mert az early stopping következtében leállítjuk a tanítást.

A súlyok megkeverése abból fakadón is segítheti egyrészt a tanulási folyamat felgyorsítását, másrészt pedig a túltanulás hatásának mérséklését, hogy általában a hálózatba betáplált adatok között lokálisan erős a korreláció. Gondoljunk például képekre, ahol a szomszédos pixelek általában egy objektumhoz köthetők.

A módszer eredményességét mutatja, hogy a kísérletek során használt adatbázisok mindegyike esetében – melyek a kézzel írt számjegyeket tartalmazó MNIST, valamint a 10 kategóriába tartozó képekből összeállított CIFAR-10 voltak – a súlyok megkeverésének alkalmazásával (illetve azt különböző egyéb technikákkal kombinálva) sikerült a legkisebb validációs hibát elérni, valamint a definiált pontossági metrikák esetében is a legjobb három eredményen belül voltak a kapott értékek a vizsgált technikákat tekintve.



7-es számjegy az MNIST adatbázisból, jól látható, hogy egy kis környezetben belül a pixelek összetartoznak

A cikk végéhez közelítve vessünk egy utolsó pillantást a barlang falához láncolt rabokra. Ők is, mint minden ember, felejtene, miért ne vezessük ezt be a neurális hálók területére is?

Aktuális kutatások az emberi idegrendszer területéről ugyanis bizonyítékot találtak a tanulás és felejtés folyamata között fennálló kapcsolatról – intuitívan megközelítve tudjuk (a jelenséget jelentősen egyszerűsítve), hogy kognitív képességeink végesek, így ahhoz, hogy valami újat megtanuljunk, szükségszerű valamilyen korábbi ismeret elfelejtése.

Ha a súlymátrixok tekintetében szeretnénk valószínűségi alapon megvalósítani ezt a technikát, akkor két dolgot kell meghatároznunk. Először is azt, hogy mit értünk neurális hálók tekintetében a felejtés fogalmán, másodszor pedig, hogy milyen szelekciós módszert alkalmazunk az elfelejteni kívánt együtthatók kiválasztására.

Az első kérdésre kézenfekvőnek tűnik a súlyok nullázása, ez azonban nem járható út, a probléma ugyanis az, hogy a hiba visszaterjesztése során a 0 vagy nagyon kicsi értékű súlyokkal szorozva a gradiens az alsóbb rétegek tanítása megakad. Ez az eltűnő gradiens (*vanishing gradient*) problémája. Tehát más megoldást kell választanunk, szerencsére a szakirodalom számos módszert ismer a súlyok inicializálására (amit az eddigiek során elhallgattunk, pedig a tanítás kezdetén is szükséges a megfelelő kezdeti értékek beállítása).

A második kérdéskört tekintve próbálkozhatunk a súlyok megkeverésénél használt lokális ablakozással, vagy akár megvizsgálhatjuk a gradiens értéke alapján történő kiválasztást is. Mint azt korábban említettük, a gradiens abszolútértéke arányos az adott súlyegyüttható hibához való hozzájárulásával, tehát ennek kihasználása célravezető lehet.

Eredményeket tekintve ez a módszer is ígéretesnek bizonyult, MNIST esetében a háló visszaemlékező-képességét (mely megadja, hogy az eredetileg egy kategóriába tartozó adatok hány százalékát sikerült helyesen besorolni) mérő metrika tekintetében a legjobb eredményt ez a megoldás szolgáltatta az összehasonlítás során, valamint az előző módszerhez hasonlóan a validációs hibát is sikerült alacsonyan tartani a többi vizsgált módszerhez képest.

A jövőre tekintve az online (vagyis a tanítást és a futtatást azonos eszközön megvalósító) rendszerek esetében történő alkalmazás részletes vizsgálata következik, melynek relevanciáját tovább növeli az a tény is, hogy a különböző módszerek kombinálásával kapott eredmények tanítási idejét összehasonlítva (iterációra vetítve) kategóriájukban a javasolt módszerek akár 40 százalékos csökkenést is eredményeztek a vizsgált modellek esetében.

Az elvégzett vizsgálatok alapján levonhatjuk azt a következtetést, hogy a közvetlenül súlymátrixokat célzó eljárások fényes kilátásokkal rendelkeznek – és nemcsak egy sötét barlanghoz viszonyítva.

REIZINGER PATRIK