

SLRG Research Paper – Nr. 2025/2.



SmartLaw Research Group

**A neurális hálózatok fejlődése és
alkalmazása a modern mesterséges
intelligenciában**

Gaál Márk – Németh Richárd*

*A szerző kutatási tevékenysége a Kulturális és Innovációs Minisztérium EKÖP-24-3-I-SZE-54 kódszámú Egyetemi Kutatói Ösztöndíj Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával valósult meg.

A mesterséges neurális hálózatok az emberi agy működését utánzó matematikai modellek, amelyek a gépi tanulás legfontosabb sarokkövét jelentik. Tanulmányunk célja átfogó, ugyanakkor közérthető betekintést nyújtani e technológiák fejlődésébe és alkalmazásaiba. A történeti áttekintésben bemutatjuk a kezdeti elméleti neuronmodellektől a többrétegű perceptronokon át a mélytanulási hálózatokig vezető utat. Külön kitérünk a konvolúciós hálózatokra, amelyek forradalmasították a számítógépes látást, valamint a rekurrens hálózatokra és ezek továbbfejlesztett változataira (LSTM, GRU), amelyek lehetővé tették a szekvenciális adatok feldolgozását. Végül ismertetjük a transformer-architektúrát és az erre épülő modern nyelvi modelleket (BERT, GPT), melyek a természetes nyelvfeldolgozás új korszakát nyitották meg. Az ismertetett technológiák rámutatnak arra, hogy a neurális hálózatok immár nem pusztán kísérleti kutatási eszközök, hanem a társadalomra is komoly hatással bíró paradigmaváltást képviselnek.

Kulcsszavak: neurális hálózatok; Deep Learning; konvolúciós hálózatok; rekurrens hálózatok; transformer architektúra; NLP-rendszerek

Artificial neural networks are mathematical models that mimic the functioning of the human brain and represent the cornerstone of machine learning. The aim of our study is to provide a comprehensive yet understandable insight into the development and applications of these technologies. In our historical overview, we present the path from the initial theoretical neuron models through multilayer perceptrons to deep learning networks. We focus on convolutional networks, which revolutionized computer vision, as well as recurrent networks and their advanced versions (LSTM, GRU), which enabled the processing of sequential data. Finally, we will introduce the transformer architecture and the modern language models based on it (BERT, GPT), which have ushered in a new era of natural language processing. The technologies described above demonstrate that neural networks are no longer merely experimental research tools, but represent a paradigm shift with a significant impact on society.

Keywords: neural networks; Deep Learning; convolutional networks; recurrent networks; transformer architecture; NLP systems

I. BEVEZETŐ

A mesterséges neurális hálózatok (Artificial Neural Networks – ANN), vagy egyszerűen csak neurális hálózatok, a mesterséges intelligencia egyik legdinamikusabban fejlődő

és talán legmeghatározóbb területe napjainkban. Kialakulásukban az emberi idegrendszer, azon belül is leginkább az agy működése szolgált inspirációul. Ezek a neuronok (azaz idegsejtek) és a köztük lévő kapcsolódási pontok, a szinapsisok működését szimuláló rendszerek képessé



váltak (képessé tehető) a tanulásra és a korrelációk, mintázatok felismerésére, ami forradalmasította a gépi tanulást. Napjainkra végtelen dimenziók nyíltak meg a felhasználási területek előtt, ezért érdemes kicsit megállni és visszatekinteni, mi is történt eddig. A mesterséges intelligencia területén napról napra jelennek meg új novumok, olyannyira, hogy még a területet kutatók sem mindig látják át az aktuális eseményeket, új felfedezéseket.

Tanulmányunk elsődleges célja, hogy a területet kevésbé ismerők számára betekintést nyújtson a gépi tanulási modellek, azon belül is a mesterséges neurális hálózatok világába, részletes és átfogó képet adjunk a neurális hálózatokról, mind elméleti nézőpontból, mind pedig a gyakorlati alkalmazásokat tekintve. Írásunkban – szándékaink szerint közérthető módon – a klasszikus többrétegű perceptrontól (MLP – MultiLayer Perceptron) kezdve egészen a modern, transzformer-alapú modellekig ismertetésre kerülnek az egyes architektúrák.

II. FELFELDEZÉSEK, ÁTTÖRÉSEK

Az emberi idegsejt működését először Hodgkin és Huxley neuronmodellje írta le.¹ Részben ezt a munkát véve alapul, az első jelentős felfedezés a mesterséges neurális hálózatok felé vezető úton a McCulloch–Pitts féle elméleti neuronmodell volt,² ahol egy

küszöbérték alapján határozták meg a neuron viselkedését (tüzel-e vagy sem), de ez még nem volt képes a tanulásra. A következő jelentős lépést Frank Rosenblatt tette meg az 1950-es években, amikor megalkotta az első Perceptron-modellt. Bár ez a korai modell még jelentős korlátokkal rendelkezett, lefektette a neurális hálózatok alapjait, és utat nyitott a későbbi, sokkal fejlettebb rendszerek fejlődésének,³ amelyekkel jelen írásunkban bővebben kívánunk foglalkozni.

A 21. század első felében a számítási kapacitás drámai növekedése, a hatalmas adathalmazokhoz való hozzáférés, valamint a Deep Learning technikáinak térnyerése új korszakot nyitott a neurális hálózatok történetében. A mély (DNN – Deep Neural Networks), visszacsatolt (RNN – Recurrent Neural Networks) és

konvolúciós neurális hálózatok (CNN – Convolutional Neural Networks), valamint a transzformer-alapú architektúrák – mint amilyen például a BERT (Bidirectional Encoder Representations from Transformers) is – lehetővé tették a gépek számára, hogy korábban elképzelhetetlennek tartott kognitív emberi feladatokat végezzenek el. Ezek a technikák ma már többek között a modern képfelismerés, valamint a természetes nyelv- és hangfelismerés alapját képezik.⁴

„Napjainkra végtelen dimenziók nyíltak meg a felhasználási területek előtt, ezért érdemes kicsit megállni és visszatekinteni, mi is történt eddig. A mesterséges intelligencia területén napról napra jelennek meg új novumok, olyannyira, hogy még a területet kutatók sem mindig látják át az aktuális eseményeket, új felfedezéseket.”

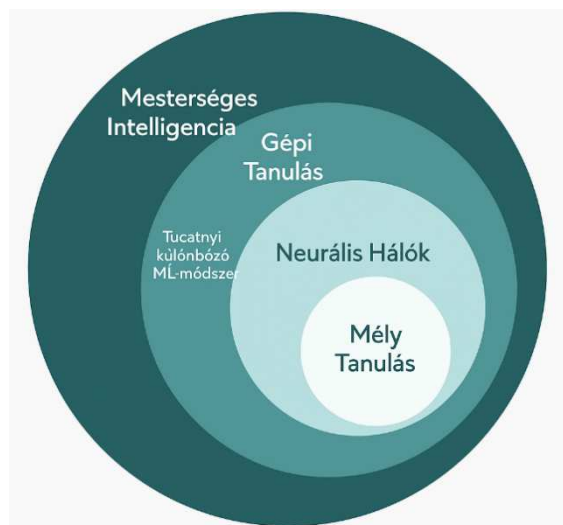
¹ Ld. bővebben: HODGKIN, Alan Lloyd – HUXLEY, Andrew Fielding (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. The Journal of Physiology, 117(4), 500–544. o.

² SCHMIDHUBER, Jürgen (2015). Deep Learning in Neural Networks: An Overview. Neural Networks, 61/2015, 85-117. o.

³ SCHMIDHUBER, i.m.

⁴ LECUN, Yann – BENGIO, Yoshua – HINTON, Geoffrey (2015). Deep learning. Nature, 2015/521(7553), 436–444. o.





1. ábra: -Neurális hálózatok, gépi tanulás és mesterséges intelligencia
(Forrás: A szerzők saját szerkesztése)

A mesterséges intelligencia fejlődésének ezen szakasza nem csupán az elméleti területeken, hanem az iparban és a mindennapi életben is forradalmi áttörést hozott: az önvezető járművek, az intelligens asszisztensek, a gépi fordítóprogramok és a diagnosztikai rendszerek mind ezeknek a hálózatoknak a teljesítményére építenek.⁵ A transzformer hálózatok megjelenése⁶ elsősorban a nyelvi feldolgozás területén jelentett óriási ugrást, hiszen lehetővé tette a szövegben rejlő kontextus mélyebb megértését és a kreatívabb, koherens szöveggenerálást. Schmidhuber már említett összefoglaló munkájából is jól látható, hogy a mély tanulás több évtized alatt óriási fejlődésen ment keresztül. A tanulási (betanítási) technológiákon belül élesen elkülönültek a felügyelt (supervised), felügyelet nélküli (unsupervised), félig felügyelt (semi-supervised) és megerősítéses tanulás (reinforcement learning) részterületei is. Napjainkra a neurális hálózatok immár nem csupán tudományos próbálkozások a gépek

okossá tételére,⁷ hanem a társadalmat formáló technológiák. Képességeik mostanra jóval túlmutatnak a hagyományos osztályozási és regressziós problémák megoldásán, alkalmasak prediktív adatelemzésre és autonóm döntéshozatalra is – ezáltal nem csupán technológiai innovációt, hanem egy valódi paradigmaváltást is képviselnek a mesterséges intelligencia területén.⁸

1. A mesterséges neuronok

Ahogy korábban is érintettük, a neurális hálózatok alapját a biológiai idegrendszer struktúrája és működési mechanizmusai adják. Gondoljunk csak arra, hogyan közvetítik és dolgozzák fel agyunk idegsejtjei az információkat komplex összefüggéseken keresztül! A hálók éppen ezt a természetes információfeldolgozást igyekeznek imitálni, méghozzá az úgynevezett mesterséges neuronok segítségével. Ez teszi lehetővé számukra, hogy komplex mintákat ismerjenek fel és tanuljanak meg.⁹ Ezek a rendszerek különösen hatékonyak a nemlineáris összefüggések detektálásában, ahol a klasszikus algoritmusok hatékonysága már korlátokba ütközik.

A neurális hálózatok története egészen az 1950-es évekre nyúlik vissza, amikor (a már említett McCulloch–Pitts modellből kiindulva) Frank Rosenblatt megalkotta az első perceptron modellt, amelynek névuma abban mutatkozott meg, hogy immáron tanulásra is képes volt. A perceptron egy rendkívül egyszerű neurális egység: lényegében egy bemeneti vektort súlyoz, majd egy aktivációs függvényen keresztül meghatároz egy kimeneti értéket, az alábbi formulára alapozva:

⁵ GOODFELLOW, Ian – BENGIO, Yoshua – COURVILLE, Aaron (2016). Deep Learning. MIT Press.

⁶ VASWANI, Arish et al. (2017). Attention Is All You Need, In 31st Conference on Neural Information Processing Systems (NIPS 2017).


⁷ Ld. HASSABIS, Demis (2017). Artificial intelligence: Chess match of the Century. Nature, 544(7651), 413. o.

⁸ GOODFELLOW – BENGIO – COURVILLE, i.m.

⁹ HAYKIN, Simon S. (2009). Neural Networks and Learning Machines (3rd ed.). Pearson Education.

$$y = \begin{cases} 1 & \text{ha } \sum_{i=1}^n w_i x_i + b > 0 \\ 0 & \text{különben} \end{cases}$$

A fenti képlet egy neuronra írja le a perceptron matematikai működését. A formulában az x -ek a bemeneti jellemzők (inputok), a w -k a súlyok (weights), a b a küszöbérték (bias), az y pedig a kimenet (output), ami 0 vagy 1 értéket vehet fel.¹⁰




2. ábra: Az elemi perceptron felépítése
(Forrás: a szerzők saját szerkesztése)

Azonban azt is látni kell, hogy az egyrétegű perceptron nem volt képes a nemlineárisan szétválasztható feladatok, például az XOR logikai művelet megoldására. Ezt a korlátozást a szakirodalomban Minsky és Papert munkája¹¹ is kiemelte, ami sajnálatos módon egy időre lelassította a kutatások ütemét a területen.

2. A többrétegű perceptron

Az igazi áttörést a többrétegű perceptronok, az MLP-k (Multi-layer Perceptron) hozták el. Az MLP már több rejtett réteget tartalmaz, ami már lehetővé tette a komplex, nemlineáris leképezések megtanulását. A neuronok itt az előző réteg kimeneteiből számított súlyozott összeg alapján határozzák meg a saját kimenetüket, amit egy aktivációs függvény – legyen az szigmoid, tanh, ReLU, stb. – transzformál. Ezzel az új struktúrával az MLP univerzális approximátorként

kezdett viselkedni, így képessé vált tetszőleges függvények közelítésére a jobb eredmény elérése érdekében, feltéve persze, hogy elegendő neuron áll rendelkezésre, és a megfelelő tanítási módszert alkalmazzák.¹²



3. ábra: néhány gyakori aktivációs függvény
(Forrás: AIML.com)

3. Visszaterjesztés és a gradiens alapú optimalizálás

A backpropagation (visszaterjesztés) a neurális háló betanításának egyik alapvető algoritmus, ami hatékony súlyoptimalizálást tesz lehetővé. Az algoritmus a kimeneti hiba alapján vezeti vissza az információt a neurális hálózaton keresztül, a kimenettől a bemenet felé. A súlyokat pedig gradiens alapú optimalizálási módszerekkel, jellemzően a gradiens ereszkedés (gradient descent) segítségével módosítja. Ez az iteratív eljárás fokozatosan csökkenti a hibafüggvényt, ezzel folyamatosan javítva a modell prediktív teljesítményét.¹³

Fontos hangsúlyoznunk a perceptronok és MLP-k gyakorlati jelentőségét. Bár a láncszabályra épülő visszaterjesztés már korábban is ismert volt, az algoritmust a gépi tanulásra Rumelhart és társai 1986-os cikkében alkalmazták először.¹⁴ A módszer segítségével a többrétegű neurális hálózatok is hatékonyan taníthatók, így szignifikáns előrelépést jelentettek. Ezek a modellek képezik az alapját a ma ismert, sokkal

¹⁰ ROSENBLATT, Frank (1958). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. Psychological Review. 65(6).

¹¹ MINSKY, Marvin – PAPERT, Seymour A. (1969). Perceptrons: An Introduction to Computational Geometry. MIT Press, Cambridge.

¹² BISHOP, Christopher M. (2006). Pattern Recognition and Machine Learning. Springer.

¹³ Ld. még erről: HAYKIN, i.m.; BISHOP, i.m.

¹⁴ RUMELHART, David E. – HINTON, Geoffrey E. – WILLIAMS, Ronald J. (1986). Learning representations by back-propagating errors. Nature, 323(6088), 533–536. o.



bonyolultabb architektúráknak, mint például a konvolúciós vagy rekurzív hálózatok.

III. KONVOLÚCIÓS HÁLÓZATOK – A SZÁMÍTÓGÉPES LÁTÁS FORRADALMA

A konvolúciós neurális hálózatok (CNN) kétségkívül a mélytanulás egyik legfontosabb és legsikeresebb fajtája. A számítógépes látás (computer vision) területén valódi áttörést hoztak, ami a működésük mögött rejlő biológiai inspirációnak köszönhető. A CNN-ek a humán vizuális kéreg, a cortex mintázatát utánozzák, ahol az idegsejtek csak a látótér egy apró részletére, az ún. receptív mezőre reagálnak. Ezzel a módszerrel a hálózat nem a teljes képet, hanem annak kisebb, egymásra épülő részeit dolgozza fel, ami rendkívül hatékony mintafelismerést tesz lehetővé.¹⁵

1. Felépítés – szűrők, sűrités és döntéshozatal

A CNN-ek alapvetően háromféle rétegtípusból épülnek fel, amelyek együttesen biztosítják a hatékony képfeldolgozást.


- Konvolúciós rétegek: Ezek a rétegek apró szűrőket (kerneleket) alkalmaznak a bemeneti képen. A szűrők feladata, hogy felismerjék a különböző mintákat (élek, textúrák vagy egyszerű formák). Az általuk felismert mintákból pedig egyfajta jellemzőterképet, ún. feature map-et hoznak létre. Ez teszi

lehetővé a modellek számára, hogy alacsony szintű vizuális jegyeket detektáljanak.

- Pooling rétegek: A konvolúciós rétegek után a pooling rétegek feladata az információ sűritése és a reprezentáció méretének csökkentése. Ezt jellemzően olyan eljárásokkal vizik végbe, mint a max-pooling vagy az average-pooling. Ennek köszönhetően a hálózat robusztusabbá válik a pozíció- és méretbeli eltérésekre, ami kulcsfontosságú a valós világban előforduló adatok kezelésében.

- Teljesen összekapcsolt rétegek: A magasabb szintű döntéshozatalért, például a végső osztályozásért, a teljesen összekapcsolt rétegek felelnek.

Ezek a rétegek a korábbi rétegek által kinyert, absztrakt jellemzők alapján hozzák meg a végleges döntést.¹⁶



4. ábra: a CNN felépítése
(Forrás: learnopencv.com)

Bár a CNN-eket eredetileg kézírás-felismeréshez alkalmazták,¹⁷ az igazi áttörést és széles körű elismerést a 2012-es ImageNet versenyen aratott győzelem hozta el. Itt mutatta be Krizhevsky, Sutskever és Hinton az AlexNet nevű mély CNN architektúrát, amely több millió adat augmentációval és paraméterrel dolgozott. Az AlexNet

¹⁵ LECUN, Yann – BOTTOU, Léon – BENGIO, Yoshua – HAFFNER, Patrick (1998). Gradient-based learning applied to document recognition. Proceedings of the IEE, 86(11), 2278-2324.

¹⁶ KRIZHEVSKY, Alex – SUTSKEVER, Ilya – HINTON, Geoffrey E. (2012). ImageNet Classification with

Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems, 25, 1097–1105., továbbá SIMONYAN, Karen – ZISSERMAN, Andrew (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint arXiv:1409.1556.

¹⁷ LECUN et al. (1998), i.m.

eredményei messze felülmúlták az addigi algoritmusok teljesítményét, és ezzel egyértelműen megmutatták a mély konvolúciós hálózatokban rejlő potenciált.¹⁸

2. Előnyök és hátrányok

A CNN-ek kiemelkedő előnye a paraméterszám jelentős csökkenése az MLP-hez képest, ami jó hatással van a teljesítményre, kevesebb adattal kell dolgozni, ami hatékonyabbá teszi őket a komplex képadatok kezelésében. Ezen kívül lehetővé teszik a hierarchikusreprezentáció-tanulást, ami azt jelenti, hogy a modell képes egyre komplexebb és absztraktabb jegyeket felismerni a bemeneti adatokból. Ezek a tulajdonságok teszik a CNN-eket kifejezetten alkalmassá nem csupán statikus képek, hanem videók vagy egyéb vizuális tartalmak elemzésére is.¹⁹

Minden technológiának megvannak a maga gyengeségei, és ez alól a CNN-ek sem kivételek. Az egyik legnagyobb kihívás, hogy ezek a hálózatok kifejezetten „adatokra éhesek”. Ahhoz, hogy jól teljesítsenek, hatalmas mennyiségű címkézett adatra van szükségük, ami a gyakorlatban nem mindig áll rendelkezésre. Emellett a CNN-ek alapvetően nem tolerálják a képek méretezését vagy elforgatását. Ha a hálózat egy adott nézetből tanult meg felismerni valamit, egy másik szemszögből, vagy más méretben látva a tárgyat, könnyen zavarba jöhet. Ezt a problémát persze ki lehet védeni adattágítással (data augmentation) vagy különleges hálózati struktúrákkal, de a probléma attól még létezik.²⁰

¹⁸ KRIZHEVSKY – SUTSKEVER – HINTON, i.m.

¹⁹ RAWAT, Waseem – WANG, Zenghui (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, 29(9), 2352–2449.

²⁰ Ld. bővebben: KRIZHEVSKY – SUTSKEVER – HINTON, i.m.

²¹ GREFF, Klaus – SRIVASTAVA, Rupesh K. – KOUTNÍK, Jan – STEUNEBRINK, Bas R. –

IV. IDŐSOROS ADATOK FELDOLGOZÁSA – AVAGY A MEMÓRIA, „AMI VISSZANÉZ”

A rekurrens neurális hálózatok (RNN-ek) a mesterséges neurális hálózatok egy olyan speciális osztályát képviselik, amelyeket kifejezetten időbeli vagy sorozatos adatok feldolgozására terveztek. Abban különböznek a többi hálótól, hogy rendelkeznek egyfajta belső "memóriával". Ez a képesség teszi lehetővé számukra, hogy az aktuális kimenet meghatározásakor figyelembe vegyék a korábbi bemenetek hatásait.²¹ Gondoljunk csak a szövegek feldolgozására, ahol egy szó jelentése a megelőző szavaktól függ – pontosan erre a problémára kínálnak megoldást az RNN-ek.

1. Homokszemek a gépezetben: gradiens-eltűnés és -robbanás

Az RNN-ek egyik legnagyobb korlátja azonban a hosszútávú függőségek kezelésének nehézsége. A tanítási folyamat során gyakran felmerül a gradiens eltűnésének vagy robbanásának problémája. Mivel az RNN-ekben a visszacsatolások miatt a gradiens exponenciálisan csökkenhetnek vagy növekedhetnek, a hálózat instabillá válik, különösen hosszú adatsorozatok esetén.²² Ez lényegében azt jelenti, hogy a modell "elfelejti", mi történt az adatsor elején, így túl nagy mennyiségű adattal nem képes megbízhatóan dolgozni.

2. A megoldások: LSTM és GRU

A fent említett problémák orvoslására alkották meg a forradalmi Hosszú távú memória (Long Short-Term Memory – LSTM) architektúrát, amelyet Hochreiter és Schmidhuber fejlesztett ki 1997-ben. Az

SCHMIDHUBER, Jürgen (2017). LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222–2232.


²² CHO, Kyunghyun et al., (2014). Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. *EMNLP 2014 (Conference on Empirical Methods in Natural Language Processing)*, 1724–1734.



LSTM hálózatok bevezették a "cell state" nevű struktúrát, ami képes minimális módosítással információt továbbítani a hálózaton keresztül. A működését speciális kapumechanizmusok szabályozzák: a bemeneti, a kimeneti és a felejtőkapu. Ezek a kapuk döntenek arról, hogy mely információkat tartsák meg, és melyeket felejtsék el, ezzel hatékonyan kezelve a hosszú távú függőségeket.²³ Az LSTM-et elsősorban nyelvi feldolgozási feladatoknál: szövegek elemzésére, szöveg tanulására használjuk, jellemző feladatok például a speciális karakterek levágása, a tokenizálás, a vektorizálás vagy hasonlósági mátrix felépítése.

Az LSTM alternatívájaként megjelent a Gated Recurrent Unit (GRU) modell is. A GRU egy egyszerűbb architektúrát kínál, miközben sok esetben hasonló teljesítményt nyújt (ami persze függ az adathalmaz méretétől). A GRU egyetlen frissítőkaput hoz létre a bemeneti és felejtőkapukból, és egy különálló "reset gate"-et használ az előző állapot hatásának szabályozására. A kevesebb paraméternek köszönhetően a GRU gyorsabban tanul, mint az LSTM, de előfordulhat, hogy komplexebb feladatok esetén nem éri el annak robusztusságát – ugyanakkor kisebb adathalmazokon, kevesebb bemeneten látványosan nagyobb teljesítmény érhető el a használatával.²⁴ A leggyakoribb felhasználási terület a szentiment-analízis vagy a képcímkezés.

„A rekurrens hálózatokat (RNN-eket) sokáig az NLP (természetes nyelvfeldolgozás) és más szekvenciális feladatok uralkodó megoldásának tekintették. Azonban sajátos feldolgozási természetük miatt nehezen voltak párhuzamosíthatók, és gyakran meggyűlt a bajuk a hosszú távú függőségek kezelésével. A forradalmi választ a további párhuzamosítások bevezetése jelentette, azaz a Transformer-architektúra.”



5. ábra. LSTM és GRU összehasonlítása
(Forrás: Sujatna et al, 2023)

V. A NYELVI FELDOLGOZÁSTÓL AZ ÖSSZETETT MODELLEKIG: A TRANSFORMER-ARCHITEKTÚRA

A rekurrens hálózatokat (RNN-eket) sokáig az NLP (természetes nyelvfeldolgozás) és más szekvenciális feladatok uralkodó megoldásának tekintették. Azonban sajátos feldolgozási természetük miatt nehezen voltak párhuzamosíthatók, és gyakran meggyűlt a bajuk a hosszú távú függőségek kezelésével. A forradalmi választ a további párhuzamosítások bevezetése jelentette, azaz a Transformer-architektúra, amelyet Vaswani és kollégái mutattak be a 2017-es, sokatmondóan az "Attention is All You Need" címre keresztelt publikációjukban.²⁵

A Transformer architektúra lényege az LSTM egyfajta kibővítése egy összpontosító vagy figyelem-mechanizmussal (self-attention mechanism), valamint pozicionális kódolás bevezetésével,²⁶ amely lehetővé teszi, hogy a modell minden egyes bemeneti elemre

²³ HOCHREITER, Sepp – SCHMIDHUBER, Jürgen (1997). Long Short-Term Memory. Neural Computation, 9(8), 1735–1780.

²⁴ GREFF et al., i.m.

²⁵ Ld. VASWANI et al., i.m.

²⁶ LU, Siyuan – WANG, Meiqi – LIANG, Shuang – LIN, Jun – WANG, Zhongfeng (2020). Hardware Accelerator for Multi-Head Attention and Position-



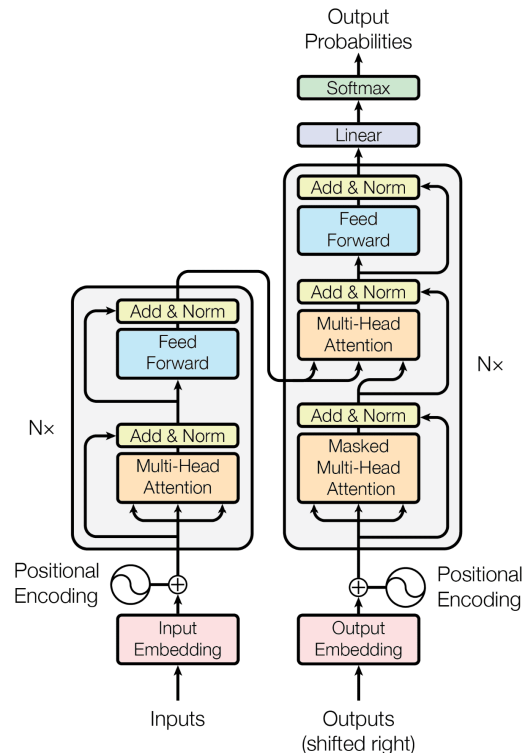
vonatkozóan figyelembe vegye az összes többi elem jelentőségét a reprezentáció kialakítása során, azaz: lehetővé teszi, hogy a modell dinamikusan súlyozza a bemeneti szekvencia különböző részeit. Ez a módszer kimagaslóan jó kontextus-megértést biztosít, segítve az összefüggések megértését, ráadásul kiválóan skálázható, mivel a feldolgozás párhuzamosan végezhető.

Összességében a Transformer-típusú hálózatok nagyban csökkentik a tanítási időt és lehetővé teszik a párhuzamosítást, ami által minden eddiginél nagyobb teljesítményre képesek. Gyorsabban taníthatók és működtethetők szekvenciális adatokon,²⁷ mivel nem igényelnek hagyományos szekvenciális feldolgozást, ami jelentősen csökkenti a tanulási időt.

1. A Transformer új szintje: A BERT és a bidirekcionális kontextus forradalma

A Transformer-modellre épülő BERT (Bidirectional Encoder Representations from Transformers) jelentős áttörést hozott az NLP világában. Fő újítása, hogy a tanulási folyamat során bidirekcionálisan veszi figyelembe a nyelvi kontextusokat. Ez azt jelenti, hogy a szavak jelentését egyszerre értelmezi az előtte és az utána következő szavak alapján is. A modell kétfázisú megközelítést alkalmaz: először egy hatalmas szövegtörzset előtanítják (pre-train) az általános nyelvi minták felismerésére, majd ezt követi a finomhangolás (fine-tuning), amivel egyedi feladatokra, például kérdés-válasz rendszerekre szabják.²⁸ Ugyanakkor érdemes megjegyezni, hogy a BERT csak

kódozó architektúrán alapul, főként Transformer kódozó rétegek halmazából áll, amelyek sok, többszörösen párhuzamosított összpontosítási fejt tartalmaznak.²⁹



7. ábra: A BERT-modell felépítése:
(Forrás: quantpedia.com)

2. Generatív modellek, chatbotok és az új benchmarkok

A BERT sikere után számos más, Transformer-alapú modell született, melyek közül a GPT másnéven „Generative Pre-trained Transformer” sorozat a legismertebb. A GPT-hez hasonló modellek mára új teljesítménycsúcsokat állítottak fel számtalan NLP benchmark teszten, és a generatív nyelvi modellek korszakát nyitották meg. Az ún. generatív nyelvi modelleknek mostanra

Wise Feed-Forward in the Transformer. 2020 IEE 33rd International System-on-Chip Conference (COCC), Las Vegas, USA.

²⁷ YE, Joel – PANDARINATH, Chethan (2021). Representation learning for neural population activity with Neural Data Transformers. *Neurons, Behavior, Data analysis, and Theory*, 5(3).

²⁸ DEVLIN, Jacob – CHANG, Ming-Wei – LEE, Kenton – TOUTANOVA, Kristina (2018). BERT: Pre-

training of Deep Bidirectional Transformers for Language Understanding. arXiv preprint arXiv:1810.04805.

²⁹ ROGERS, Anna – KOVALEVA, Olga – RUMSHISKY, Anna (2020). A Primer in BERTology: What We Know About How BERT Works. *Transactions of the Association for Computational Linguistics*, 8, 842–866.



számtalan képviselője van, az általános célútól (pl. ChatGPT, Grok, DeepSeek, Copilot, Gemini, Perplexity) a valamilyen célfeladatra kihegyezett reprezentánsig (MidJourney, ConversationalAI, Firefly stb.).

VI. A JELEN ÉS A JÖVŐ

Az elmúlt évtizedben a neurális hálózatok számtalan területen bizonyították hatékonyságukat. Képességük, hogy nagy mennyiségű strukturált és strukturálatlan adatot is képesek feldolgozni és azokból prediktív modelleket alkotni, valóban lenyűgöző. Ugyanakkor fontos megemlíteni, hogy a technológia széleskörű alkalmazása számos komoly akadályba ütközhet, főleg a jövőben. Itt elsősorban a számítási erőforrásigény megnövekedésére kell gondolni.

A mesterséges neurális hálózatok egyik legnagyobb előnye az automatizált tanulási képesség. Ez azt jelenti, hogy ahelyett, hogy manuálisan íránk meg a szabályokat, a hálózat képes önállóan, a bemeneti adatok alapján megtanulni az összefüggéseket. Ez a képesség teszi lehetővé, hogy komplex, sokdimenziós adatokat dolgozzon fel, és olyan mintázatokot ismerjen fel, amelyek más

módszerekkel szinte lehetetlenek. A mély hálózatok predikciós pontossága és precizitása gyakran felülmúlja a többi algoritmusét, különösen nagyméretű tanítóhalmazok esetén.³⁰ Ugyanakkor bizonyos hátrányokat is meg kell említenünk. Az informatikára jellemző rapid teljesítménynövekedés ellenére a legnagyobb korlát még mindig a magas számítási igény, főként a tanítási fázisban. A mélytanulási modellek tanítása jelentős GPU-kapacitást, nagy mennyiségű adatot és hosszú időt igényel.³¹ Ezen túlmenően a neurális hálózatok egyik fő hátránya, hogy nehezen magyarázhatók. A „fekete doboz” jelleg miatt szinte lehetetlen emberi szemmel követni, milyen logika mentén jutott a hálózat egy-egy döntésre. Ez a probléma különösen kritikus olyan területeken, mint az egészségügy vagy az igazságszolgáltatás, ahol az átláthatóság alapvető követelmény. A döntések ellenőrzése és felülvizsgálata ezért komoly kihívást jelent.

Fontos megemlíteni az etikai és társadalmi felelősség kérdését is. Az adatok érzékenysége, a transzparencia hiánya és a bizalom megteremtése mind olyan tényezők, amelyek megkövetelik a technológia felelős használatát. Ennek a problémának a kezelésére nyújt megoldást a magyarázható mesterséges intelligencia (XAI), amely egyre nagyobb hangsúlyt kap a kutatásokban.

A neurális hálózatok fejlődése folyamatos, és a jövőbeni kutatási irányok célja a jelenlegi

„A neurális hálózatok fejlődése folyamatos, és a jövőbeni kutatási irányok célja a jelenlegi korlátok leküzdése, valamint hatékonyabb, megbízhatóbb és általánosabban alkalmazható MI-rendszerek létrehozása. A magas számítási és memóriaigény komoly akadályt jelent a valós idejű vagy erőforrás-szegény környezetekben, ezért a modelltömörítési technikák komoly lehetőségeket kínálnak a modellek méretének és energiaigényének csökkentésére, a teljesítmény megtartása mellett.

³⁰ RUDIN, Cynthia (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206–215.

³¹ STRUBELL, Emma – GANESH, Ananya – MCCALLUM, Andrew (2019). *Energy and Policy*

Considerations for Deep Learning in NLP. Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics (ACL), 3645–3650.



korlátok leküzdése, valamint hatékonyabb, megbízhatóbb és általánosabban alkalmazható MI-rendszerek létrehozása. A magas számítási és memóriaigény komoly akadályt jelent a valós idejű vagy erőforrás-szegény környezetekben, ezért a modelltömörítési technikák komoly lehetőségeket kínálnak a modellek méretének és energiaigényének csökkentésére, a teljesítmény megtartása mellett.

A jövő fejlesztései a kevésbé adatfüggő modellek felé mutatnak. Jelenlegi modelljeink rendkívül nagy, jól annotált adathalmazokra támaszkodnak, de a kutatások a few-shot, zero-shot és self-supervised learning elveit követve igyekeznek csökkenteni ezt a követelményt. Ahogy a mesterséges intelligencia egyre nagyobb szerepet játszik az életünk kritikus területein, egyre nagyobb lesz az igény a megmagyarázható és megbízható rendszerek iránt.

ÖSSZEGZÉS

A neurális hálózatok fejlődése radikálisan átformálta az MI világot, olyan lehetőségeket nyitva meg, melyek korábban elképzelhetetlenek voltak. Az MLP, CNN, RNN, LSTM, GRU és a Transformer architektúrák forradalmasították az automatizált tanulást, a vizuális megértést és a nyelvi feldolgozást.

Ahhoz azonban, hogy ezek a rendszerek valóban emberközpontú és igazságos módon szolgálják a közösséget, a kutatásoknak az átláthatóság és a megbízhatóság biztosítására kell fókuszálniuk. A tudományos közösség felelőssége, hogy a technológia fejlesztését körültekintéssel és etikusan irányítsa. A mesterséges intelligencia jövője ugyanis nem csupán az algoritmusokban, hanem a felelős döntésekben és az emberekre gyakorolt pozitív hatásokban mérhető.

FELHASZNÁLT IRODALOM

- [1] HODGKIN, Alan Lloyd – HUXLEY, Andrew Fielding (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology*, 117(4).
- [2] SCHMIDHUBER, Jürgen (2015). Deep Learning in Neural Networks: An Overview. *Neural Networks*, 61/2015.
- [3] LECUN, Yann – BENGIO, Yoshua – HINTON, Geoffrey (2015). Deep learning. *Nature*, 521(7553).
- [4] GOODFELLOW, Ian – BENGIO, Yoshua – COURVILLE, Aaron (2016). *Deep Learning*. MIT Press.
- [5] VASWANI, Ashish et al. (2017). Attention is All You Need. *Advances in Neural Information Processing Systems*.
- [6] HASSABIS, Demis (2017). Artificial intelligence: Chess match of the Century. *Nature*, 544(7651).
- [7] HAYKIN, Simon S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson Education.
- [8] ROSENBLATT, Frank (1958). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*. 65(6).
- [9] MINSKY, Marvin – PAPERT, Seymour A. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Cambridge.
- [10] BISHOP, Christopher M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- [11] AIML.com: What is an activation function? What are the different types of activation functions? Discuss their pros and cons (<https://aiml.com/what-is-an-activation-function-what-are-the-different-types-of-activation-functions-discuss-their-pros-and-cons/>).



- [12] RUMELHART, David E. – HINTON, Geoffrey E. – WILLIAMS, Ronald J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088).
- [13] LECUN, Yann – BOTTOU, Léon – BENGIO, Yoshua – HAFFNER, Patrick (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11).
- [14] KRIZHEVSKY, Alex – SUTSKEVER, Ilya – HINTON, Geoffrey E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- [15] LearnOpenCV: Convolutional Neural Network (CNN): A Complete Guide (<https://learnopencv.com/understanding-convolutional-neural-networks-cnn/>).
- [16] SIMONYAN, Karen – ZISSERMAN, Andrew (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. arXiv preprint arXiv:1409.1556.
- [17] RAWAT, Waseem – WANG, Zenghui (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, 29(9).
- [18] GREFF, Klaus – SRIVASTAVA, Rupesh K. – KOUTNÍK, Jan – STEUNEBRINK, Bas R. – SCHMIDHUBER, Jürgen (2017). LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10).
- [19] CHO, Kyunghyun et al., (2014). Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. *EMNLP 2014 (Conference on Empirical Methods in Natural Language Processing)*.
- [20] HOCHREITER, Sepp – SCHMIDHUBER, Jürgen (1997). Long Short-Term Memory. *Neural Computation*, 9(8).
- [21] SUJATNA, Yayat – SATYO, Adhitho – HASTOMO, Widi – YUNINGSIH, Nia – ARIF, Dody – HANDAYANI, Sri – ROSADI KARDIAN, Aqwam – WARDHANI, Ire (2023). Stacked LSTM-GRU Long-Term Forecasting Model for Indonesian Islamic Banks. *Knowledge Engineering and Data Science*. 6.
- [22] LU, Siyuan – WANG, Meiqi – LIANG, Shuang – LIN, Jun – WANG, Zhongfeng (2020). Hardware Accelerator for Multi-Head Attention and Position-Wise Feed-Forward in the Transformer. *2020 IEEE 33rd International System-on-Chip Conference (COCC)*, Las Vegas.
- [23] YE, Joel – PANDARINATH, Chethan (2021). Representation learning for neural population activity with Neural Data Transformers. *Neurons, Behavior, Data analysis, and Theory*, 5(3).
- [24] ROGERS, Anna – KOVALEVA, Olga – RUMSHISKY, Anna; (2020). A Primer in BERTology: What We Know About How BERT Works. *Transactions of the Association for Computational Linguistics*, 8.
- [25] Quantpedia: BERT Model – Bidirectional Encoder Representations from Transformers. (<https://quantpedia.com/bert-model-bidirectional-encoder-representations-from-transformers/>)



IMPRESSZUM

Szerző(k):
Gaál Márk
Németh Richárd

Kézirat lezárásának ideje:
2025.08.19.

Szerkesztők:
Farkas Ádám PhD
Kelemen Roland
Glavanits Judit PhD
Karácsony Gergely PhD
Keserű Barna Arnold PhD
Király Péter Bálint PhD
Németh Richárd
Spitzer Jenő

Kiadó:
Smart Law Research Group

Elérhetőségek:
<http://smartlawresearch.hu/>

ISSN:
2732-3846

A sorozat egyes számaiban foglalt vélemények, állásfoglalások a szerzők saját véleményét tükrözik. Azok nem tekinthetők sem a kiadó, sem a szerzőt foglalkoztató intézmények hivatalos álláspontjának.

A sorozat célja a SmartLaw Reseach Group, illetve annak tagjai és esetleges külső együttműködők által végzett kutatások részeredményeinek közzététele a szakmai, tudományos megvitathatóság érdekében, illetve a későbbi publikációk előkészítésének támogatása érdekében