



ELTE EÖTVÖS LORÁND
TUDOMÁNYEGYETEM

Előrejelzések

Dékány Csaba

Informatika kar

Tehetséggel fel!

Bolyai Szakkollégium - informatika szakszeminárium

2023. szeptember 26.



Mi a mélytanulás?

Definíció

- **Mesterséges intelligencia:** Intelligens viselkedést mutató program
- **Gépi tanulás** (parametrikus modellek): Modell paramétereinek megtalálása számítógépes módszerekkel, automatikusan (adatok alapján)
- **Mélytanulás:** Neurális hálók matematikai modelljével reprezentált modellek, melyeknek egynél több rejtett rétege van

Tanulás

- Nincs jól meghatározott algoritmus
- Emberi tanuláshoz hasonló, mintapéldák segítségével
- Felügyelt tanulás: **bemenet-címke párok**

Idősorok előrejelzése

Idősorok

- Adatok szekvenciája, melyeket különböző időpillanatokban rögzítettünk
- Pl.: időjárás-előrejelzés, pénzügyi előrejelzések, meghibásodás előrejelzés, gépi fordítás, hanggenerálás
- Társadalmi vagy gazdasági jelentőségük nagy

Indoklás

- Mélytanulási modellek kiválóan alkalmasak idősorok feldolgozására
- Kis kutatási eredménnyel is jelentős javulás érhető el
- Gyorsan fejlődő terület, új megoldások „becsatornázása”

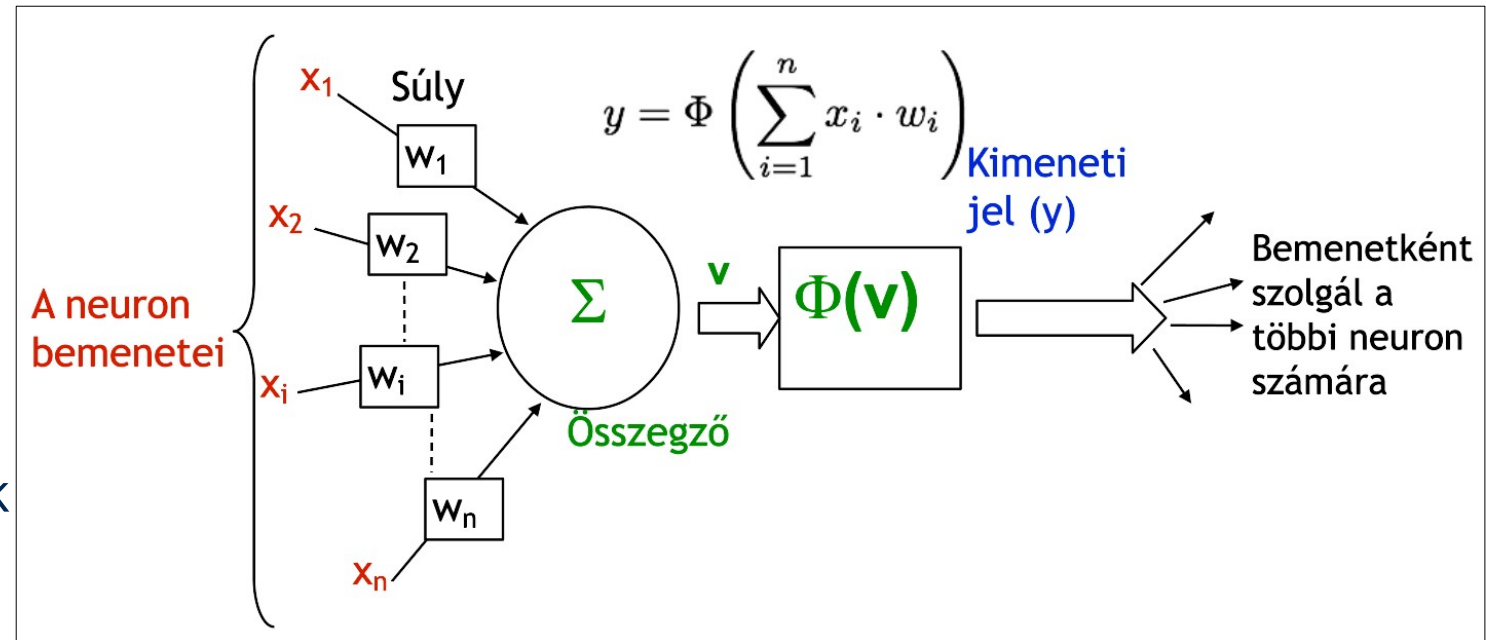
Mesterséges neurális hálók

Mesterséges neuron

- Információ feldolgozó egység
- Biológiai neuron ihlette


Mesterséges neurális háló

- Rétegekbe szervezett neuronok
- Mélytanulási modellek
- Cél: súlyok optimalizálása



Dr. Botzheim János, Gyöngyössy Natabara Máté:
Deep learning workshop előadás 2021

Mesterséges neurális hálók



Ravindra Parmar: Training Deep Neural Networks,
Towards Data Science, <https://towardsdatascience.com/training-deep-neural-networks-9fdb1964b964>


Gradiens módszer

Gradiens módszer

- Mélytanulási modellek súlyainak optimalizálása
- Felügyelt, felügyeletlen tanulás
- Hibafüggvény gradiense a paraméterek függvényében
- Súlyok frissítése

Időbeli gradiens módszer

- Rekurrens neurális hálók
- Több időpillanat
- Kimenetek bemenetekként való visszacsatolása



<https://towardsdatascience.com/a-visual-explanation-of-gradient-descent-methods-momentum-adagrad-rmsprop-adam-f898b102325c>

$$New W_{ij} = W_{ij} - \mu * F_{W_{ij}}$$

[6] szakirodalom

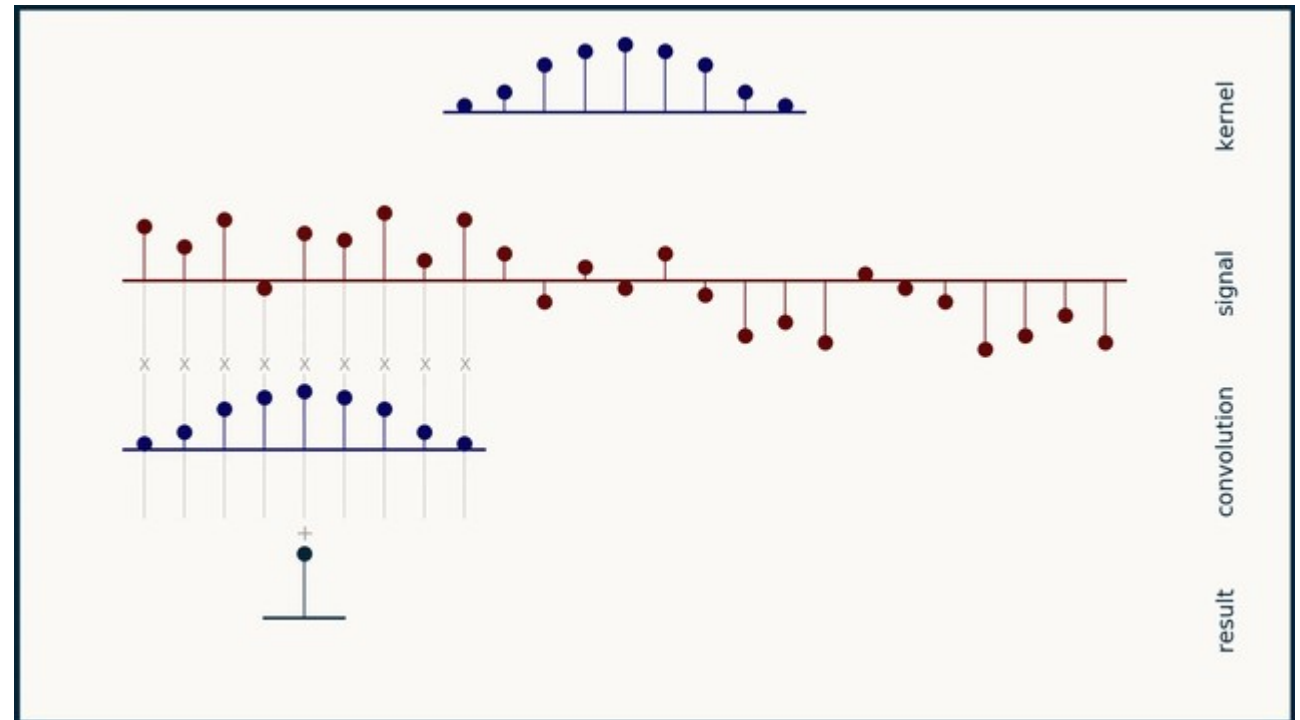
Konvolúciós neurális hálók

Konvolúciós rétegek

- Súlyok megosztottak
- Konvolúciós kernel
- „Csúszóablak-szerűen” számol

Felhasználás

- Elsősorban képfeldolgozás
- Idősorok előrejelzése
- Pl.: HAR, pénzügyi idősorok
- Eltolás-invariancia



https://e2eml.school/images/conv1d/stride_2.gif


LSTM

LSTM memóriablokk

- Rekurrens architektúra
- „Kapuzó-elv”
- Bemeneti, kimeneti, felejtési kapu
- Rejtett memóriaváltozó

Előnyök

- Hosszú és rövid távú összefüggések
- Nagyszámú időlépés kezelése
- Eltűnő gradiens problémát enyhíti



https://www.researchgate.net/figure/Structure-of-the-LSTM-cell-and-equations-that-describe-the-gates-of-an-LSTM-cell_fig5_329362532Mauris eu diam eget elit rhoncus lacinia.

Transformer


Attention mechanizmus

- V, K, Q mátrixok
- Attention pontszámok
- Idősorelemek egymásra vonatkozó relevanciája

Multihead attention

- Vektorok felbontása kisebb vektorokra
- Bizonyos tulajdonságok az egyes „fejekben” való reprezentálása

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

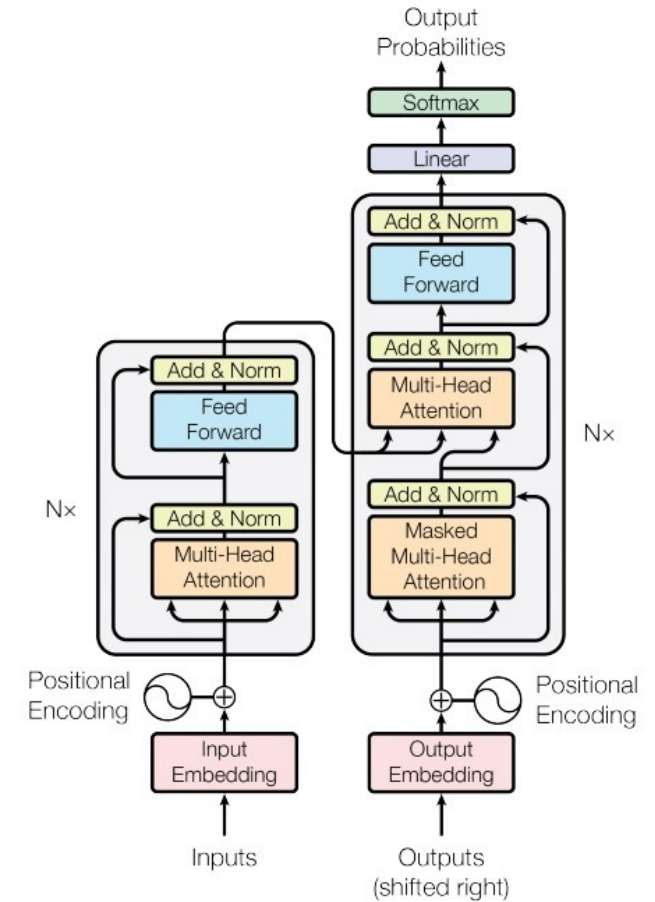


[9] szakirodalom

Transformer


Transformer

- Enkóder-dekóder architektúra
- Saját és kereszt attention egységek
- Számítások könnyen párhuzamosíthatóak
- Pl.: gépi fordítás, szimbolikus szekvencia



[9] szakirodalom

Attention pontszámok vizualizációja



[9] szakirodalom


Spacetimeformer

Téridő attention (spatial-temporal)

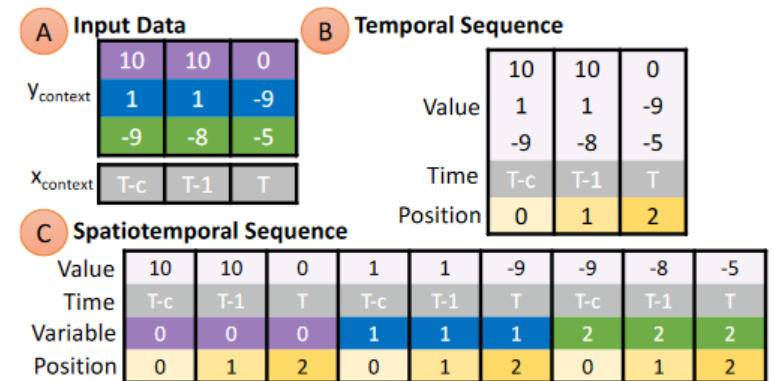
- Attention pontszámok számítása idődimenzióként és az idősoradatok egyes dimenziói mentén
- Idősor kilapítása

Spacetimeformer

- Hosszú, **valós** értékű idősorok
- Lokális, globális attention
- Idő, dimenzió „vektorszótárak”
- Gyors attention

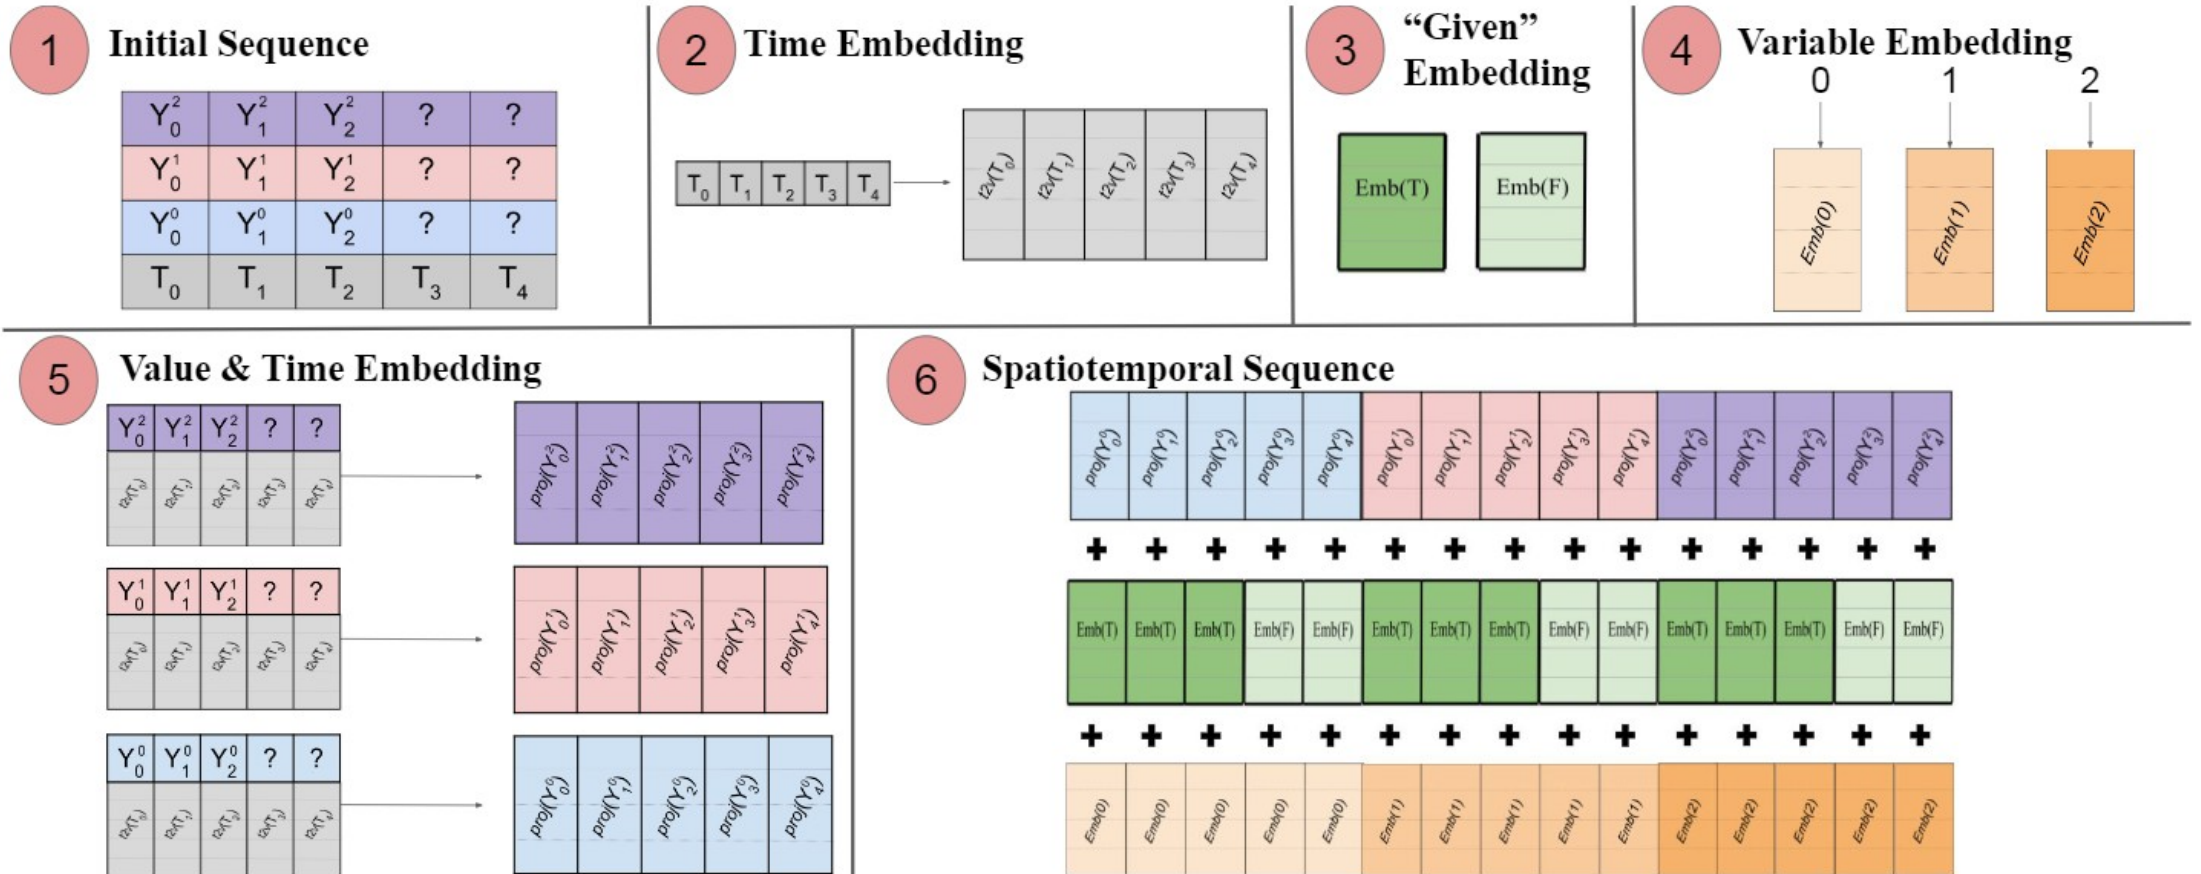


[10] szakirodalom



[10] szakirodalom

Spacetimeformer



[10] szakirodalom

Gyakorlati feladat

Napenergia mennyiségének előrejelzése

- Benchmark adatsor a megismert technológiák összehasonlítására
- AL SOLAR alabamai adatbázis
- 5 percenként mérések

LSTM modell

- Következő 4 órára vett napenergia mennyiségének 10 percenkénti előrejelzése

Spacetimeformer modell

- [10] szakirodalomban szereplő modell, kevesebb paraméterrel
- Következő 4 órára vett napenergia mennyiségének 10 percenkénti előrejelzése


Eredmények

LSTM modell

- MSE: 21.992
- Tanítási idő: kb.: 1 óra 15 perc (1 GPU)
- Paraméterek száma: 893 693

Spacetimeformer modell

- MSE: 7.5755
- Tanítási idő: kb.: 4 óra (1 GPU)
- Paraméterek száma: 63 900



Tanítási és validációs hiba az LSTM modell tanítása során (skálázott).
Készült: Google Colab segítségével

Metrika/Modell	LSTM	Spacetimeformer
MSE	21.992	7.5755

Jövő

Diagnosztizálás, betegség-előrejelzés orvosi adatokból

- Megismert modellek alkalmazása
- Szakirodalmi összefoglaló tanulmányok felhasználása
- Új eredmények „becsatornázása” az egészségügybe

Probléma

- Rövid idősorok
- Hiányzó mérések

Szakirodalmak

- [1] Deisenroth, M. P., Faisal, A. A., & Ong, C. S. (2020). Mathematics for Machine Learning. In Mathematics for Machine Learning. <https://doi.org/10.1017/9781108679930>
- [2] Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- [3] Rabiner, L. R., & Juang, B. H. (1986). An Introduction to Hidden Markov Models. IEEE ASSP Magazine, 3(1). <https://doi.org/10.1109/MASSP.1986.1165342>
- [4] Yang, J. B., Nguyen, M. N., San, P. P., Li, X. L., & Krishnaswamy, S. (2015). Deep convolutional neural networks on multichannel time series for human activity recognition. IJCAI International Joint Conference on Artificial Intelligence, 2015-January.
- [5] Borovykh, A., Bohte, S., & Oosterlee, C. W. (2017). Conditional time series forecasting with convolutional neural networks. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 10614 LNCS.
- [6] Werbos, P. J. (1990). Backpropagation Through Time: What It Does and How to Do It. Proceedings of the IEEE, 78(10). <https://doi.org/10.1109/5.58337>
- [7] Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation, 9(8). <https://doi.org/10.1162/neco.1997.9.8.1735>
- [8] Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference. <https://doi.org/10.3115/v1/d14-1179>
- [9] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. Advances in Neural Information Processing Systems, 2017-December.
- [10] Grigsby, J., Wang, Z., & Qi, Y. (2021). Long-Range Transformers for Dynamic Spatiotemporal Forecasting.
- [11] Kazemi, S. M., Goel, R., Eghbali, S., Ramanan, J., Sahota, J., Thakur, S., ... & Brubaker, M. (2019). Time2vec: Learning a vector representation of time. *arXiv preprint arXiv:1907.05321*.
- [12] Choromanski, K., Likhoshesterov, V., Dohan, D., Song, X., Gane, A., Sarlos, T., ... & Weller, A. (2020). Rethinking attention with performers. *arXiv preprint arXiv:2009.14794*.



ELTE EÖTVÖS LORÁND
TUDOMÁNYEGYETEM

Köszönöm a figyelmet!

„A Kulturális és Innovációs Minisztérium ÚNKP-22-6 kódszámú Új Nemzeti Kiválóság Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával készült.”

