


## Munkakereslet előrejelzése neurális hálóval

**Bakó Tamás** (tudományos segédmunkatárs, MTA KRTK Közgazdaság-tudományi Intézet)

Az utóbbi években egyre többet hallani arról, hogy a gépi tanulási módszerek kiterjedtek a műszaki alkalmazások világából és teret nyertek a társadalomtudományokban is. Muraközy (2018)<sup>1</sup> jó áttekintést ad arról, hogy melyek azok a területek, ahol lehet és érdemes is használni a gépi tanulási módszereket a közgazdaságtanban. Jelen írás egy konkrét alkalmazás példáján keresztül kíván mélyebb betekintést nyújtani az egyik legelterjedtebb módszer, a neurális háló működésébe.

A mesterséges intelligencia/gépi tanulás körébe tartozó módszerekről a legtöbben azt gondolják, hogy ezek nyilván az elmúlt pár év, esetleg 1-2 évtized kutatásainak eredményei. Valójában az alapokat sokkal régebben lerakták és ez különösen igaz a neurális hálókra. McCulloch és Pitts (1943)<sup>2</sup> vetették fel először, hogy az agyban lévő neuronok milliárdjaira, mint sok-sok, összekapcsolt számítógépre tekinthetünk. A mesterséges neurális háló – noha számos komoly különbség van a jelenlegi neurális hálók és az emberi agy tényleges működése között – alapvetően az agy tanulási folyamatának egyfajta számítástudományi leképezése. A mesterséges neurális háló számos iteráció során tanul, mégpedig úgy, hogy minden iteráció után megváltoztatja kicsit a „neuronok” közötti kapcsolatok (szinapszisok) erősségét. A neurális hálók több neuronból állnak, melyek rétegekbe szerveződnek, ahogy azt az alábbi ábra is mutatja:

1. ábra



Az ábrán 1. jelölt (bemeneti) réteg 3 neuronból áll, outputja a 2., szintén 3 neuronból álló réteg inputja. A mélytanulás (deep learning) elnevezés az egymás mögött elhelyezkedő rétegekre, azok számára utal. A neuronok és rétegek számát a modellező határozza meg a feladat jellegétől és bonyolultságától függően. A neurális hálóban a bemeneti vektor  $x_i$  komponensei  $w_i$  súlyokkal

<sup>1</sup> Muraközy Balázs (2018): Gépi tanulás, predikció és okság a közgazdaság-tudományban, Magyar Tudomány, 179(2018)7, 1027-1037

<sup>2</sup> McCulloch, W.S. és Pitts, W.H (1943): A Logical Calculus of Ideas Immanent in Nervous Activity”, Bulletin of Mathematical Biophysics, Vol. 5. 1943, p. 115-133

szorzódnak össze, amelyet az ábrán körökkel jelzett neuronok kapnak meg. Ha ez a súlyozott összeg eléri egy küszöbértéket, akkor a neuron aktiválódik. Azok a kapcsolatok (szinapszisok) fognak megerősödni, ahol a neuronok aktiválódtak, mégpedig úgy, hogy nagyobb súlyt fognak kapni a következő iteráció3 során. Az iteráció addig folyik, amíg a bemeneti és a kimeneti érték közötti eltérés minimális nem lesz.



Számos neurális hálózati topológia létezik, melyek közül az egyik legelterjedtebb a rekurrens (visszacsatolt) neurális hálózat, mely információt nyer az adatok időbeli struktúrájából a visszacsatolás segítségével (ezt jelzik a visszaható nyilak a neuronoknál). Fontos számítástudományi tétel, hogy bármely nemlineáris dinamikai rendszer tetszőleges pontossággal közelíthető egy rekurrens neurális hálóval. A rekurrens hálók képesek figyelembe venni az előző kimeneteket is az adott bemeneti értékek mellett. Erre a tulajdonságukra úgy is gondolhatunk, mint belső memóriára, amely tárolja az eddigi eredményeket. A rekurrens hálózat valójában egy gyűjtőnév, mely több hálózattípust foglal magában. Az általunk használt rekurrens hálózat az ún. Long-Short Term Memory (LSTM), mely különböző kapukkal igyekszik az információk áramlását szabályozni. Az LSTM ezzel a szabályozással határozza meg, hogy melyik részét hagyja el, tartsa meg változatlanul, vagy frissítse az aktuális tudásnak, és mindezt milyen mértékben tegye. A hagyományos rekurrens hálózatok csak rövid távú memóriával rendelkeznek, az LSTM azonban képes a szekvenciális adatokban megbúvó hosszú távú függéseket is megjegyezni, miközben a rövid távú kapcsolatokat is figyelembe veszi. Ez utóbbi tulajdonság különösen hasznos idősorok előrejelzése során, ezért megvizsgáltuk, hogy az LSTM neurális háló mennyire alkalmazható rövid távú munkakereslet előrejelzésére. A feladat olyan modell megtalálása, mely a legjobban adja vissza a foglalkoztatás rövid távú változását 2016-2017 között a 1994-2015 közötti adatok alapján. A neurális háló predikciós képességét a hagyományos ARIMA modellel hasonlítottuk össze több, az irodalomban elterjedt mutató alapján (RMSE, MAE, MAPE és Theil'u). Ez alapján megállapítottuk, hogy az LSTM neurális háló jobb rövidtávú predikciós képességgel rendelkezik, mint az ARIMA modell. A modellekben „magyarázó” változóként csak az előző időszakai értékek szerepeltek, továbbá csak az aggregált foglalkoztatást jeleztük előre. A továbbiakban a célunk olyan LSTM neurális háló alkalmazása, amely további input változókat tartalmaz, valamint egyszerre jelzi előre több ágazat foglalkoztatását.

Érdemes megemlíteni, hogy a gépi tanulási módszereket általában a nagyméretű komplex adathalmazokkal hozzák összefüggésbe. Jelen példa mutatja, hogy ez nem szükségszerű, hiszen mindössze 88 adatpontból történt az előrejelzés. Noha az eddigi tapasztalatok kedvezőek, a neurális hálók még nem tekinthetők a közgazdászok standard, elfogadott előrejelző eszközeinek, ezért további, hasonló vizsgálatok szükségesek annak bizonyítására, hogy érdemes megtanulni, és alkalmazni ezt a technikát.

<sup>3</sup> Az első iteráció során a kezdeti súlyok véletlenszerűen kerülnek meghatározásra.