

Mesterséges ideghálózatok (ANN) alkalmazása az érzékszervi minősítés gyakorlatában

Sipos László, Gere Attila, Kókai Zoltán, Szabó Dániel

Budapesti Corvinus Egyetem, Élelmiszertudományi Kar,
Érzékszervi Minősítő Laboratórium

Érkezett: 2012. április 12.

Kapcsolat: laszlo.sipos@uni-corvinus.hu

A mesterséges ideghálózatok (Artificial Neural Network, ANN) eredetileg az emberi agyműködés leutánzására tervezett nemlineáris közelítő eljárások, mely jellemezhető volt a legfontosabb agyi jellemzőkkel (sokoldalúság, adaptív válasz a külső ingerekre, hatékony alakfelismerés képessége zajos adatok esetén is stb.) A neurofizikai, matematikai, biológiai háttér kidolgozásában úttörő munkát végeztek többek között: McCulloch és Pitt (1943), Hebb (1949), Rosenblatt (1958), Widrow és Hoff (1960). A mesterséges ideghálózatok alkalmazásának igazi lökést Hopfield (1982) publikációja adott, melyben korábbi korlátokat oldott fel a non-linearitás a neuron által kapott teljes input és az ezáltal készült output között, valamint a lehetőség nyílt az outputok inputokkal történő visszacsatolására (visszacsatolásos hálók, feed-forward).

A neurális hálók első gyakorlati alkalmazásai a 80-as évek végére tehető. Terjedése a módszernek köszönhetően dinamikus és széleskörű, mivel ezek képesek az adatokban rejlő komplex kapcsolatok, adatokban rejlő mintázatok felismerésére, és ezt extrapolálva előre tudják jelezni az új adatokat. Segítségükkel érték- és kategória-előrejelzések tehetőek meg nagy biztonsággal. A neurális hálózatokat széles körben alkalmazzák, többek között: tőzsdei előrejelzések, hitel és banki kockázatbecslések, hitelkártya-csalások azonosítása, eladási előrejelzések, folyamatirányítás, általános üzleti előrejelzések, időjárás előrejelzés, beruházások kockázatértékelése, orvosi diagnózisok, tudományos kutatások vagy ellenőrző rendszerek (Neuraltools, 2010).

Az ANN alkalmazásai az utóbbi 15 évben került a kutatók fókuszába, mivel a matematikai alapok kidolgozásával a különböző hálókat implementálták a szoftvercsomagokba:

1. Többretegű feed-forward neurális hálózatok (MLF-NNs)
2. Radiális alap funkciójú neurális hálók (RBF-NN)

3. Kohonen alapú szerkezetek

- a) Önrendező térképek (SOP)
- b) Számlálókiterjesztett mesterséges neurális hálózatok (CP-ANN)
- c) Egyéb felügyelt Kohonen alapú neurális hálózatok (XY fused network, Bi-directional Kohonen).

Az élelmiszeripari elterjedést segítették a nemzetközi gyakorlatban alkalmazott szoftverek. A neurális hálók jellemzően a nagy szoftvercsomagok egy-egy modulját jelentik: MatLab (Neural Network Toolbox), Statistica (Neural Networks), Palisade (NeuralTools), SPSS (Modeler), Alyuda (Neurointelligence), NeuroDimension (Neurosolution).

Élelmiszeripari alkalmazásai elsősorban ott terjedtek el, ahol nagy mennyiségű adatokkal dolgoznak, valamint a mért és becsült adatok között valamilyen összefüggés található. Az alkalmazás spektruma nagyon széleskörű, többek között: közeli infravörös spektroszkópia (Micklander et al. 2006); spektrofotometria (Ni et al. 2003); gázkromatográfia (Steinhart et al. 2000) e-orr (Hines et al. 1999, Pinto et al. 2001; Penza és Cassano, 2004); e-nyelv (Deisingh et al. 2004; Mikhaleva et al. 2006; Gutes et al. 2007). Az ANN terjedését a széles körű problémamegoldás lehetőségeinek köszönheti, amelyek közül a legfontosabbak: kiugró értékek azonosítása, korreláció azonosítása változók között, tér redukció, regresszió nem lineáris változók között, komplex kapcsolatok modellezése, osztályozás, kategóriába sorolás stb.

Az élelmiszeriparban megvalósult széles körű felhasználás mellett a nemzetközi szakirodalomban azonban csak néhány humán érzékszervi vizsgálatokkal kapcsolatos kutatást publikáltak. Jack és Steele (2002) kutatásukban egy neurális hálózati modell fejlesztését írják le, 144 skót és egyéb nem-skót whisky érzékszervi profil adataira épülve, melyek segítségével osztályozták a termékeket. Kutatásuk arra irányult, hogy megállapítsák, hogy a skót whisky rendelkezik-e a skót whiskytől elvárt érzékszervi tulajdonságokkal, érzékszervi szakértői panel bevonásával. A vizsgálatokat 4 elemű kategóriaskálán végezték (0 = nincs jelen, 3 = erősen jelen van), a profilanalitikus módszert alkalmazva a whisky aromakerék 13 leíró kifejezésének értékelésével (szúrós, fenolos, utó párlatos, gabonás, aldehides, észteres, édes, fás, olajos, savanyú, kénes, dohos, mesterséges.). Az érzékszervi panel átlagértékei adták a neurális hálózat tréningezésének bemenő értékeit. A 13 vizsgált

érzékszervi paraméter alapján a neurális hálózat „skót whisky” vagy „nem skót whisky” kategóriákba csoportosította a termékeket.

Az alkalmazott hálózat a Valószínűség alapú Neurális Hálózat (Probabilistic Neural Networks) volt, mely egy genetikus algoritmust, a „legjobb technika túlélését” alkalmazza, hogy meghatározzon egy súlyozási rendszert a beérkező információkhoz (érzékszervi panel átlagértékei). A hálózat számos súlyozási kombinációt tesztelt, amíg megtalálta azt, amelyik a legjobban osztályozta a termékeket. A következőkben ezt a jól általánosítható megközelítést alkalmazták. Emellett a beérkező adatok relatív fontossága is vizsgálható, azaz, hogy mely érzékszervi tulajdonságok jelentik a skót whisky jellegzetességeit. Munkájuk felhívta a figyelmet arra, hogy a neurális hálózatok hasonlóképpen alkalmazhatók márkaszpecifikus modellek fejlesztéséhez, vagy az eredetiség igazolásához.

Singh és munkatársai (2009) UHT tejminták romlási folyamatait modellezte különböző hőmérsékletű tárolást alkalmazva. A visszafuttatásos algoritmusú (feed-forward back propagation) mesterséges neurális háló modellek 5 bemeneti paraméterrel lettek kifejlesztve (proteolitikus aktivitás, lipolitikus aktivitás, oxidáció, Maillard-reakció, fény visszaverődési érték), hogy előrejelezzék a kimeneti paramétereket: íz- és a teljes érzékszervi pontszámokat. Ebben a tanulmányban többrétegű visszafuttatásos hálózatot (Multi-Layer Feedforward Network) fejlesztettek MATLAB 7.0 segítségével, amelyhez az alábbiakat definiálták:

1. Hálózati modell: Feed-forward neurális hálózat, visszafuttatásos algoritmussal
2. Hálózati réteg: 1 és 2 rejtett réteg bemeneti és kimeneti réteg nélkül
3. Neuronok minden rétegben: 3-25 neuron minden rejtett rétegben
4. Súly és hibamátrix: véletlenszerűen inicializálva
5. Transzformációs függvény minden rejtett rétegen: tangens szigmoid függvény
6. Transzformáció függvény a kimeneti rétegen: tisztán lineáris függvény
7. Tréning algoritmus: Trainbr (Bayes-féle szabályozás)
8. Teljesítmény értékelés: a négyzetes középérték relatív százaléka (%RMS), hogy értékelje a hálózati modell teljesítményét

A kimeneti válaszhoz kapcsolódó hibákat úgy redukálták, hogy minden neuronban csökkentették a hibákat, a kimenettől a bemeneti rétegig az alábbi módszerekkel: gradiens származtatás, Widrow-Hoff féle tanulási szabály, konjugált gradiennsel, kvázi-Newton módszer, Levenberg–Marquardt módszerrel. A visszafuttatásos algoritmussal képzett hálózatok hibája rendszerint a túlbecslés (Mittal és Zhang, 2000), amelynek megoldását a Bayes-szabályzási módszerrel küszöbölték ki, mivel a módszer önműködő módon határozza meg az optimális szabályozási paramétereket. Eredményeik azt mutatatták, hogy a legjobb ANN konfiguráció az íz előrejelzésére (%RMS=5,85) 1 rejtett réteget tartalmazott, benne 15 neuronnal. A teljes érzékszervi pontszámra előrejelző modellnek 2 rejtett rétege volt, és mindegyikben 3-3 neuron. Összefoglalóan megállapítható, hogy a többrétegű visszafuttatásos algoritmusú neurális hálózat segítségével sikeresen becsülték a bemeneti fizikai-kémiai változókkal a kimeneti érzékszervi paramétereket (Singh et al. 2010).

Anyag és Módszer

Kutatási célkitűzésünk arra irányult, hogy az ANN módszert lehet-e alkalmazni a panelteljesítmény általános jellemzésére és a panel értékelésétől eltérő tagok azonosítására. Az alapfeltételezésünk az volt, hogy egy megbízható panel adatmátrixa egy homogén egységet alkot, amelyben az egyes értékek alapján nem lehetséges a paneltagok azonosítása, mivel ugyanannak a termékeknek, ugyanazon érzékszervi paraméterére közel egyforma értékeket adnak. Amennyiben egy paneltag a paneltől eltérően pontoz, úgy ő azonosíthatóvá válik.

Vizsgálatainkban 5 kereskedelmi forgalomban kapható csemegekukorica-mintát elemeztünk, melyeket két 10 fős panel értékelt, két ismétlésben. A képzetlen panel tagjait a Budapesti Corvinus Egyetem Élelmiszertudományi Karának hallgatóiból toboroztuk, míg a szakértő panel a Kar Érzékszervi Minősítő Laboratóriumának képzett bírálóiból állt. A képzett bírálók az ISO/DIS 8586-1 szabványban foglaltak alapján átestek a megfelelő képzésen.

A minták előkészítését minden esetben egyformán végeztük (főzési idő, edényzet nagysága, anyaga, márkája, főzőlap nagysága és hőmérséklete, vízmennyiség stb.). A minták szervírozásánál figyelembe

vettük továbbá Kilcast (2010) ajánlásait, miszerint egy személy készítette elő a kis mintamennyiségeket a jobb homogenitás érdekében. A mintákat a nemzetközi gyakorlatoknak megfelelően (ISO 6658:2005) véletlen számgenerátorral előállított számhármassokkal kódoltuk.

A minták ízsemlegesítéséhez a szakirodalomban a termék jellegétől függően különböző élelmiszereket alkalmaznak, mi tesztünkhöz ásványvizet használtunk. Korábbi kísérleteinkben előfordult, hogy csapvizet alkalmaztunk, azonban később az állandó összetétel és egyéb érzékszervi módosító hatástól mentes semleges ízű ásványvizet (Aquarius) választottunk (Sipos, 2010).

A vizsgálatokat az ISO 6658:2005 szabvány előírásainak megfelelő érzékszervi laboratóriumban végeztük. A bírálatokat 2 időpontban hajtottuk végre, egyszer a képzett és egyszer a képzetlen bírálókkal, 2-2 ismétléssel alkalmanként. A 17 vizsgálati szempontot a képzett bírálók határozták meg, melyek a következők voltak: „Sárga szín”, „Árnyalat”, „Szemméret”, „Szemméret egyenetlensége”, „Frissesség”, „Illat intenzitás”, „Főtt kukorica íz”, „Édes illat”, „Állomány”, „Lédúság”, „Héj rághatósága”, „Zsengeség”, „Globális ízintenzitás”, „Édes íz”, „Sós íz”, „Főtt íz” és „Utóíz”. A bírálók az értékelést 0-100%-ig terjedő strukturálatlan skálán értékelték, amelyeknek szélsőértékeit konszenzussal állapították meg.

A kutatási sorozat a Palisade szoftvercsalád Neural Tools ver. 5.5 részének felhasználásával hajtottuk végre. Az MLFN/MLPN (Multi-Layer Feedforward Networks, Multi-Layer Perceptron Networks) hálózatot választottuk, mivel az a komplex összefüggések becslésére, valamint a függő és független változó közti komplex kapcsolatok modellezésére is jól alkalmazható. Ez az algoritmus alapvetően a nemlineáris kapcsolatok felderítésének általános megközelítése, továbbá az MLP hálózatok összetettsége a rétegek számától és az egyes rétegekben található neuronok számától függ. Klasszifikációra és nemlineáris függvénybecslésre széles körűen alkalmazzák. MLF hálózatok előnyei, más hálótípusokhoz (Generalized Regression Neural Net (GRNN) és Probabilistic Neural Net (PNN)) képest abban fogalmazhatók meg, hogy kisebb méretűek, így gyorsabban elkészül a predikció, sokkal megbízhatóbbak a tartományon kívül eső tréning adatok (például, amikor néhány független változó értéke a tartományon kívül esik). Az MLF hálózatok további előnye, hogy alkalmasak nagyon kis tréning adatsorok általánosítására (Borosy, 2001).

A hálózat viselkedését az alábbiak határozzák meg: felépítés (rejtett rétegek és a bennük levő nóduszok száma), a kapcsolatok súlyai (a kapcsolatokhoz tartozó paraméter nagysága) és a torzítás, azaz a neuronokhoz kapcsolódó paramétereket átalakító függvény, amely kiszámítja a kimeneti jel értékét. A NeuralToolsban a kimeneti neuron egy azonosításra átalakító függvényt használ, amely a bemenetek súlyozott összegét adja vissza. Az osztályozásra használt MLF hálózatoknak több kimeneti neuronjuk van, melyek mindegyike összefüggésben áll egy lehetséges függő kategóriával. Egy hálózat az eseteket kimeneti értékek alapján osztályozza. A kiválasztott kategória minden esetben a legnagyobb kimeneti értékű neuronhoz kapcsolódik. A kutatásokban a visszafuttatásos algoritmusok helyett más algoritmusok alkalmazását preferálják, melyek gyorsabbak és nagyobb valószínűséggel találják meg a globális optimumot.

Bishop (1995) a NeuralTools a konjugált gradiens (Conjugate Gradient Descent) módszert használja, amely a „second-order” optimáló módszerek kategóriájába tartozik. Ezeket a „determinisztikus” optimáló módszereket arra fejlesztették, hogy megtalálják a függvény lokális minimumát. Lefele haladnak a hiba függvényen. A lokális helyett a globális minimum meghatározás kockázatának csökkentése érdekében a NeuralTools kombinálja a „determinisztikus” és „sztohasztikus” optimálási modelleket. Pontosabban a sztohasztikus „Simulated Annealing” módszer a Conjugate Gradient Descent módszerrel (Masters, 1995) együtt alkalmazza. Az algoritmus az előző próbák alapján eldönti, hogy melyiket alkalmazza a szóban forgó pontnál (Neuraltools, 2010).

A túltréningezés során a hálózat nem csak a függő és független változók közti kapcsolatok jellemzőit tanulja meg, hanem elkezd megtanulni a tréninggel kapcsolatos olyan eseteket, amelyeket általában nem alkalmazunk. Ezek azután nem lesznek alkalmasak olyan esetek adatainak értékelésére, amelyek nincsenek benne a tréningben. Ennek a problémának az elkerülésére a teszt adatsor néha két adatsorra, a „tréning-alatti-tesztelés”-re és a tényleges teszt-adatsorra van bontva, amelyet a tréning után használunk. A „tréning-alatti-tesztelés” hibáját meghatározott időközönként a tréning alatt számoljuk. Amikor növekedni kezd, az bizonyítja, hogy elkezdődött a háló túltréningezése és a tréning megáll. A 2 különböző adatsor alkalmazása gyakran nem reális, amennyiben nem áll rendelkezésre elegendő adat a szétbontásra (a tréning adatok 2 teszt adatsorra bontására). Emellett a hibaszám

emelkedése a „tréning-alatti-tesztelés” adatsorban nem jelzi megbízhatóan a túltréningezést. Az emelkedés lehet lokális, és a hiba elkezdhet csökkenni a további tréningezés során (Neuraltools, 2010).

Mindkét esetben a partícionálást alkalmaztunk az első ismétlés adatain, azaz az adatok 80 %-án tréningeztük a modellt, 20%-án teszteltük. A második ismétlés szolgáltatja a tesztfuttatások kiinduló adatait, ahol a bírálók neveit ismeretlennek tekintettük, illetve a márkanévet kihagytuk a változók köréből. Ezt követően egy függő kategóriaváltozót rögzítettünk (bíráló) és 17 független értékváltozót (érzékszervi paramétert) állítottunk be.

Az MLFN háló struktúrájának optimalizálásához a 'Best Net Search' lehetőséget választottuk, amely 5 hálót tesztel 2-6 nódusszal, és kiválasztja a legjobb predikciót adót. A NeuralTools Best Net Search opciója a túltréningezés megelőzésére lett kialakítva. Alapbeállításokkal a Best Net Search 2 neuronnal kezd egy hálót, ami legtöbbször túl kicsi, hogy túltréningezzük. Az alapbeállításokkal egészen 6 neuronig fogja tréningezni a hálókat. Ha az 5 és 6 neuronos hálókat túltréningezi, akkor az megjelenik az eredményekben. A gyakorlatban a 2, 3 vagy 4 neuronos hálók egyikének lesz a legalacsonyabb teszt hibája.

Eredmények és következtetések

A 'Best Net Search' segítségével a szoftver több MLFN konfigurációt tesztelt, amíg kiválasztotta a legjobb predikciót adót. A képzetlen bírálók esetében a 4 nódusos MLFN, míg a képzett bírálók esetében az 5 Nódusos MLFN adta a legjobb eredményeket (1. táblázat).

1. táblázat: 'Best Net Search' eredményei képzetlen és képzett bíráló csoporton

Best Net Search	Incorrect (%) képzetlen	Incorrect (%) képzett
MLFN 2 nódusz	100%	100%
MLFN 3 nódusz	100%	100%
MLFN 4 nódusz	90%	100%
MLFN 5 nódusz	100%	90%
MLFN 6 nódusz	100%	100%

Az MLFN modell kialakításánál a tréningezéshez a minták véletlenszerűen lettek kiválasztva. A klasszifikációs mátrix megadja, hogy hány esetet tudott a háló jól előrejelezni. A 'Bad Prediction' (%) a hibát százalékos értékben jeleníti meg. A képzetlen bírálók közül az egyes bírálók érzékszervi pontértékei alapján a tréning adataihoz képest a teszteredmények jobban azonosítják a bírálókat. Nagyon hasonlóan pontozott a képzetlen 1, 2, 4, 5, 6 bíráló, így őket az értékek alapján nehezen azonosította az MLFN neurális hálója, ezért a Bad Prediction érték magasnak (100%) adódott. Emiatt a háló összekeveri a többi panel értékeivel, azaz megbízható paneltagok a panelben. A képzett bírálók esetében több paneltag pontozott nagyon hasonlóan, így a képzetlenekhez képest is több 100%-os Bad Prediction értéket kaptunk (2. táblázat).

2. táblázat: A képzetlen és képzett bírálók klasszifikációs eredményei

Bírálók	BP (%) tréning	BP (%) teszt	Bírálók	BP (%) tréning	BP (%) teszt
képzetlen_1	100%	100%	képzett_1	75%	100%
képzetlen_2	100%	100%	képzett_2	60%	0%
képzetlen_3	20%	0%	képzett_3	100%	100%
képzetlen_4	0%	100%	képzett_4	33%	100%
képzetlen_5	100%	100%	képzett_5	0%	100%
képzetlen_6	0%	100%	képzett_6	100%	100%
képzetlen_7	20%	0%	képzett_7	100%	100%
képzetlen_8	20%	0%	képzett_8	20%	0%
képzetlen_9	20%	0%	képzett_9	25%	0%
képzetlen_10	25%	0%	képzett_10	0%	0%

Képzetlen bírálók esetében az összes 50 klasszifikációból 14-szer tudta jól előre jelezni az MLFN háló a paneltagokat pontszámaik mintázatai alapján. A legtöbb esetben a 3-as bírálót találta el a modell, így a 3-as paneltagot azonosította külön a modell, így ez a bíráló tért el leginkább a panel többi tagjától. A képzetlen 1, 2, 4, 5, 10 bíráló esetében a modell 80-100%-os Bad Prediction (%) értékeket adott, tehát adataik alapján nem azonosíthatóak, így a háló összekeveri a többi panel tagjainak értékeivel, azaz megbízhatóak a tagok az érzékszervi panelben. Mivel a modell bírálónként 5 predikciót végzett, így ha a modell egynél többször azonosítani tudta a bírálót (2-60 BP(%)), 3-40

BP(%), 4-20 BP(%), 5-0 BP(%)), akkor a modell javaslata alapján szakmailag eltérőnek értékeltük a bírálót többi bírálótól. Az természetesen további vizsgálatokat igényel, hogy mi az eltérés oka: betegség, skála félreértelmezése, konszenzus hiánya stb. (3. táblázat).

3. táblázat: A képzetlen paneltagok értékelése az MLFN háló predikciója alapján

Bírálók	BP (%) predikció	Következtetés
képzetlen_1	100%	paneltag összhangban van a panellel*
képzetlen_2	100%	paneltag összhangban van a panellel*
képzetlen_3	20%	eltérő paneltag**
képzetlen_4	100%	paneltag összhangban van a panellel*
képzetlen_5	100%	paneltag összhangban van a panellel*
képzetlen_6	60%	eltérő paneltag**
képzetlen_7	40%	eltérő paneltag**
képzetlen_8	40%	eltérő paneltag**
képzetlen_9	60%	eltérő paneltag**
képzetlen_10	80%	paneltag összhangban van a panellel*

* A modell a paneltag értékei alapján nem azonosítja.

** A modell a paneltag értékei alapján azonosítja.

A képzett bírálók esetében az 5 nódusos MLFN adta a legjobb eredményeket. (A 'Best Net Search' segítségével a szoftver több MLFN konfigurációt tesztelt, míg kiválasztotta a legjobb predikciót). A képzett bírálók esetében az összesen 50 klasszifikációból 10-szer tudta jól előre jelezni az MLFN háló a paneltagokat pontszámaik mintázata alapján. A legtöbb esetben a 10-es számú képzett bírálót találta el a modell, így a 10-es paneltag értékei alapján azonosítható, tehát eltér a többektől, azaz eltér a panel eredményeitől. A képzett 1, 2, 3, 4, 5, 6, 7 bíráló esetében a modell 80-100%-os Bad Prediction (%) értékeket adott, ezért adataik alapján így nem azonosíthatóak, ezért a háló összekeveri a többi panel értékeivel, azaz a megbízható tagokkal az érzékszervi panelben (4. táblázat).

A modellek validálását az érzékszervi panelek teljesítményértékelésére kifejlesztett célszoftver (Tomic et al. 2007, Tomic et al. 2010,

Naes et al, 2010), a PanelCheck szoftver Tucker-1 és tojánhéj diagram (eggshell) módszereinek alkalmazásával végeztük el. Mind a képzetlen, mind a képzett bírálók esetében ugyanazokat a bírálókat azonosítottuk eltérő paneltagként.

4. táblázat: A képzett paneltagok értékelése az MLFN háló predikciója alapján

Bírálók	BP (%) predikció	Következtetés
képzett_1	100%	paneltag összhangban van a panellel*
képzett_2	80%	paneltag összhangban van a panellel*
képzett_3	100%	paneltag összhangban van a panellel*
képzett_4	80%	paneltag összhangban van a panellel*
képzett_5	80%	paneltag összhangban van a panellel*
képzett_6	100%	paneltag összhangban van a panellel*
képzett_7	100%	paneltag összhangban van a panellel*
képzett_8	60%	eltérő paneltag**
képzett_9	60%	eltérő paneltag**
képzett_10	40%	eltérő paneltag**

* A modell a paneltag értékei alapján nem azonosítja.

** A modell a paneltag értékei alapján azonosítja.

Következtetések és javaslatok

A mesterséges ideghálózatok (ANN) széles körű élelmiszeripari alkalmazáson kívül a nemzetközi szakirodalomban csak néhány humán érzékszervi vizsgálatokkal kapcsolatos kutatási eredményt publikáltak, melynek háttérében az állhat, hogy a kutatók elemzéseikhez a hagyományos statisztikai módszereket alkalmazzák, és ezek az újszerű módszerek körükben jelenleg kevésbé ismertek. A neurális hálók érzékszervi kutatásban való alkalmazásával számos kutatási probléma lenne megoldható, amelyek tesztelésére a közeli jövő programját képezi. Előzetes vizsgálataink alapján elsősorban a panelteljesítmény monitorozásához lehetne ezeket a módszereket alkalmazni.

Két vagy több panel összehasonlításánál, amennyiben a panel tagjai hasonló vagy egyforma értékeket adnak az egyes tulajdonságokra, akkor a neurális háló nehezen vagy egyáltalán nem tudja azonosítani az egyes bírálókat pontértékei alapján (képzett-laikus, etalonpanel-célpanel, etalonpanel-képzett panelek stb.).

A panel ismétlőképességének tesztelésénél ugyanazon paneltagok első napi teljesítményét a második napi teljesítményével hasonlítjuk össze (függő változó: bíráló, független változók: érzékszervi paraméterek).

Az érzékszervi panel megkülönböztető képességének tesztelésénél az a kérdés, hogy a neurális háló milyen biztonsággal tudja azonosítani a vizsgált termékeket a bírálók által adott érzékszervi pontszámok alapján (függő változó: termékek, független változók: érzékszervi paraméterek).

Az érzékszervi panel egyetértésének, összhangjának tesztelésénél a validálásoknál általánosan alkalmazott „leave-one-out” módszer alapján egy adatot (a bírálót pontszámaival együtt) kiveszünk a teljes adathalmazból és a modellt a maradék adatok felhasználásával állítjuk fel. Ezek után a kivett adatot beillesztjük a modellbe és megfigyeljük, hogy a csoportokba való besorolás helyes-e vagy sem. A metódust elvégezzük az összes adatra, és összeszámoljuk a helyes és helytelen besorolásokat. Ezzel lehetővé válik a bírálópaneltől eltérő (kiugró) bíráló azonosítása, vagy új paneltag bírálati csoporttal levő összhangjának vizsgálata (függő változó: termékek, független változók: érzékszervi paraméterek).

Egy-egy érzékszervi tulajdonság hatásának becslésénél a 'relative variable impact value' segítségével megadható, hogy mely tulajdonságok milyen százalékban vettek részt a termékek azonosításában. Ezzel a módszerrel azonosítani lehetne, hogy mely érzékszervi paraméterek vesznek részt döntően egy-egy termék azonosításában (függő változó: termékek, független változók: érzékszervi paraméterek). További vizsgálatokkal célszerű feltárni, hogy az érzékszervi kutatásokban általánosan alkalmazott PCA-biplot milyen összefüggéseket mutat ezzel a módszerrel. Amennyiben a függő változók a bírálók, a független változók az érzékszervi paraméterek, akkor a problémás érzékszervi tulajdonságok azonosítása is lehetséges. Amelyik tulajdonságnak a legnagyobb hatása ('relative variable impact value') van a bírálók

elkülönítésére, annak értékei meghatározóak a bírálókra, azaz nincs összhangban a panel e tulajdonság alapján. Ezután a bírálatvezető már személyre szabott érzékszervi feladatot tud előírni az azonosított bírálónak az azonosított tulajdonságra vonatkozóan.

Felhasznált irodalom

- Bishop, Christopher M., *Neural Networks for Pattern Recognition*, Oxford, 1995.
- Borosy, A. P. (2001): Mesterséges ideghálózatok. In: Horvay szerk. Sokváltozós adatelemzés (Kemometria). Budapest, Nemzeti tankönyvkiadó. 312–329
- Deisingh A.K., Thompson, M. (2004): Application of electronic noses and tongues in food analysis, *J. Food Sci. Tech.*, 39, 587
- Ganjyal, G., Hanna, M.A., Supprung, P., Noomhorm, A. and Jones, D. (2006): Modeling selected properties of extruded rice flour and rice starch by neural networks and statistics. *Cereal Chemistry*, (AACC International, Inc.) 83. 223–227
- Gutés, A. Céspedes, F. Valle, M. (2007): Electronic tongues in flow analysis. *Analytica Chimica Acta*, 600 (1-2) 90–96
- Hebb, D.O. (1949): *The organization of behavior: A neuropsychological theory*. New York, John Wiley and Sons. 335
- Hines E. L., Llobet, E. Gardner, J.W. (1999): Neural network based electronic nose for apple ripeness determination. *Electronic Letters*, 35, 821–823
- Hopfield, J. (1982): Neural networks and physical systems with emergent collective computational abilities, *Proc. Natl. Acad. Sci. U.S.A.*, 79 (8) 2554–2558.
- ISO 6658:2005 Sensory analysis – Methodology – General guidance
- ISO/DIS 8586-1 Sensory analysis – Methodology – General guidance for the selection, training and monitoring of assessors and experts
- Jack, F. R., Steele, G. M. (2002): Modelling the sensory characteristics of Scotch whisky using neural networks—a novel tool for generic protection. *Food Quality and Preference*, 163–172
- Kilcast, D. (2010): Sensory quality control for taint prevention. In: KILCAST, D. (ed.) *Sensory analysis for food and beverage quality control*. Woodhead, Cambridge.
- Masters, Timothy, *Advanced Algorithms for Neural Networks*, Wiley, 1995.
- McCulloch, W. S. and Pitts, W. H. (1943): A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115–137
- Micklander, E., Kjeldahl, K., Egebo, M., Norgaard, L. (2006): Multi-product calibration models of near infrared spectra of foods. *Journal of Near Infrared Spectroscopy*, 14, 395–402

- Mikhaleva, N.M., Kulapina, E.G. (2006): Multisensor systems for separate determination of homologous anionic and non-ionic surfactants. *Electroanalysis*, 18, 1389–1395
- Millan, F.R., Roa, V., and Tapia, M.S. (2001): Mathematical modeling of food moisture adsorption isotherms using artificial neural networks. *Interciencia*, 26 (5) 190–194
- Mittal, G.S., Zhang, J. (2000): Use of artificial neural network to predict, temperature, moisture and fat in slab-shaped foods with edible coatings during deep fat frying. *Journal of Food Science*, 65, 978–983
- Naes, T., Brockhoff, P. B. & Tomic, O. (2010): *Statistics for sensory and consumer science*. Wiley, Chicester. 209–224
- NeuralTools Version 5.7 Manual (2010)
- Ni, Y. Huang, C. Kokot, S. (2007): Simultaneous determination of iron and aluminium by differential kinetic spectrophotometric method and chemometrics. *Anal. Chim. Acta*, 599 209–218
- Penza, M., Cassano, G. (2004): Chemometric characterization of Italian wines by thin-film multisensors array and artificial neural networks. *Food Chemistry*, 283–296
- Pinto, C.G., Laespada, M.E.F., Pavon, J.L.P., Cordero, B.M. (2001): Electronic olfactometry. A new tool in analytical chemistry. *Quim. Anal.*, 20 (1) 3–11
- Rosenblatt, F. (1958): The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65 (6), 386–408
- Singh, R.R.B., Ruhil, A.P., Jain, D.K., Patel, A.A., Patil, G.R. (2009): Prediction of sensory quality of UHT milk – A comparison of kinetic and neural network approaches. *Journal of Food Engineering*, 146–151
- Sipos, L. (2009): *Ásványvíz-fogyasztási szokások elemzése és ásványvizek érzékszervi vizsgálata*. PhD értekezés. Budapesti Corvinus Egyetem, Döntéstámogató Rendszerek Doktori Iskola, 110
- Stephan, A., Steinhart, H. (2000): Bitter taste of unsaturated free fatty acids in emulsions: contribution to the off-flavour of soybean lecithins. *European Food Research and Technology*, 17–25
- Tomic, O., Luciano, G., Nilsen, A., Hyldig, G., Lorensen, K. & Næs, T. (2010): Analysing sensory panel performance in proficiency tests using the PanelCheck software. *European Food Research and Technology*, 230 (3) 497–511
- Tomic, O., Nilsen, A. N., Martens, M. & Næs, T. (2007): Visualization of sensory profiling data for performance monitoring, *LWT - Food Science and Technology*, 40, 262–269
- Widrow, B. and Hoff, M.E. Jr. (1960): Adaptive Switching Circuits. *IRE WESCON Convention Record*. 96–104

Mesterséges ideghálózatok (ANN) alkalmazása az érzékszervi minősítés gyakorlatában

Összefoglalás

A mesterséges ideghálózatok (ANN) alkalmazásának terjedése a módszernek köszönhetően dinamikus és széleskörű, mivel ezek képesek az adatokban rejlő komplex, nem lineáris mintázatok, kiugró értékek, korrelációk azonosítására, valamint a nem lineáris változók közötti regresszió alkalmazására, értékek és kategóriák előrejelzésére. A különböző neurális hálók (MLF-NNs, RBF-NN, Kohonen hálók) élelmiszertudományi alkalmazása megvalósult, köszönhetően a nagy szoftverfejlesztő cégeknek, amelyek ezeket termékeikbe/programjaikba beépítették. Ezek többek között a következők: MatLab (Neural Network Toolbox), Statistica (Neural Networks), Palisade (NeuralTools), SPSS (Modeler), Alyuda (Neurointelligence), NeuroDimension (Neurosolution). Ennek ellenére a nemzetközi szakirodalomban csak néhány humán érzékszervi vizsgálatokkal kapcsolatos kutatási eredményt publikáltak.

A kutatási célunk az ANN módszerének alkalmazása a panelteljesítmény általános jellemzésére, és a panel értékelésétől eltérő tagok azonosítására. Kutatásunkban 5 kereskedelmi forgalomban kapható csemegekukorica mintát elemeztünk, melyeket egy képzetlen és egy képzett 10 fős panel értékelt, 2 ismétlésben. A neurális háló felépítését a 'Best Net Search segítségével végeztük, a képzetlen bírálók esetében a 4 nódusos MLFN, míg a képzett bírálók esetében az 5 Nódusos MLFN adta a legjobb predikciót a tréning 80%, teszt 20% beállításokkal, véletlen mintavétellel (Palisade, Neural Tools 5.5). A modellek validációját elvégeztük az érzékszervi panelek teljesítményértékelésére kifejlesztett célszoftver a PanelCheck szoftver Tucker-1 és tojásbélyeg diagram (eggshell) módszereinek alkalmazásával. Összefoglalásként megállapítottuk, hogy mind a képzetlen (3,6,7,8,9), mind a képzett bírálók (8,9,10) esetében ugyanazokat a bírálókat azonosítottuk eltérő paneltagként a két szoftverrel.

Application of Artificial Neural Network (ANN) in Praxis of the Sensory Evaluation

Abstract

The application of the Artificial Neural Networks is more and more widespread in several fields of scientific research due to the flexibility of this method. With the use of an ANN model it can be easily identified outliers, correlation and the complex nonlinear patterns in the data set. Consequently ANN can be applied to space reduction, numerical and/or categorical prediction and of course regression between nonlinear variables. The different types of neural networks (MLF-NNs, RBF-NN, Kohonen networks) have already been transferred to the food sector thanks to those software developing companies who had integrated this method in their products/software, some of them are MatLab (Neural Network Toolbox), Statistica (Neural Networks), Palisade (NeuralTools), SPSS (Modeler), Alyuda (Neurointelligence) and NeuroDimension (Neurosolution). In spite of these there is only a limited number of publications dealing with ANN and human sensory evaluation.

The aim was to apply the ANN method to evaluate the performance of a human sensory panel and to identify panel members who perform differently compared to the rest of the panel. In this research five commercially available sweet corn samples were evaluated by a trained and an untrained sensory panel using two replicates. Both of the panels consisted of 10 panelists. The creation of the neural net was performed using 'Best Net Search' algorithm, which resulted in case of the untrained panel a 4 nodes MLFN net and in case of the trained panel a 5 nodes MLFN net. The training and testing conditions were set to 80% and 20% with random sampling (Palisade, Neural Tools 5.5). The models were validated by PanelCheck software which is designed to evaluate the performance of sensory panels by the Norwegian Nofima Research Institute. The applied mathematical methods were the Tucker-1 and eggshell plots. As a conclusion we have defined that in case of the untrained and trained panel the same assessors were marked as different with the application of the two softwares.