

**Artificial neural networks
in the animal production
sector**S. Á. Nagy¹I. Csabai²T. Varga³B. Póth-Szebenyi⁴Gy. Gábor⁵N. Solymosi^{1*}

1. Állatorvostudományi Egyetem,
Bioinformatikai Központ, H-1078
Budapest István u. 2.

*e-mail: solymosi.norbert@gmail.com

2. ELTE Komplex Rendszerek Fizikája
Tanszék, Budapest

3. SZIMBIÓVET Kft., Egyházasköd

4. Magyar Agrár- és Élettudományi
Egyetem, Kaposvári Campus,
Kaposvár

5. Androvet Kft., Budapest

BIOINFORMATIKA

Mesterséges neurális hálózatok az állattermék-előállításban

**Nagy Sára Ágnes¹, Csabai István², Varga Tamás³, Póth-Szebenyi Bettina⁴,
Gábor György⁵, Solymosi Norbert^{1*}**

ÖSSZEFOGLALÁS

A szerzők bemutatják a mesterséges intelligencia használatának lehetőségeit, amelynek a térnyerése az agráriumban sem kerül el. A mesterséges neurális hálózat az agráriumbeli gépi tanulási módszerek között a leghatékonyabb gépi tanulási eszköz. Az mesterséges neurális hálózatok bonyolult matematikai modellek, amelyek betaníthatók az adatokban (pl. képekben) rejlő mintázatok (pl. állati testrészek) felismerésére. A tanítást követően pedig e mintázatok predikciójára használhatók. Jelen közleményünkben a szerzők összefoglalják az mesterséges neurális hálózat általános szerkezetét és működését. Bemutatnak továbbá felhasználási lehetőségeket kifejezetten az állattermék-előállítás területéről vett példákon keresztül.

SUMMARY

The rise of artificial intelligence (AI) is not going unnoticed in the agricultural sector. The processing of the large amounts of data ('big data') generated in animal production is increasingly being done using artificial intelligence, particularly machine learning (ML). Machine learning is a branch of AI, in which algorithms are automatically trained to solve a task of interest using a given dataset. There are several sub-areas of ML, of which we focus on artificial neural networks (ANNs), the most successfully used in agriculture. The basic units of an ANN are artificial neurons. These are connected to each other similarly to synapses in the brain, forming a network. ANNs can be considered complex mathematical models that can make predictions from given data after a learning process, taking into account millions of parameters. Because they are pretty flexible, these networks have a wide range of applications in many fields. One such field is a subset of agriculture, namely animal production. In our work, we outline the general structure and operation of ANNs. We provide insight into the metrics widely used to indicate the accuracy of prediction and their calculation methods. Possible applications are illustrated with examples specifically from the field of food production. The wide range of applications is illustrated by the fact that the works cited also respond to the challenges faced by aquacultures and beekeepers, in addition to the problems of cattle, pig and poultry farms. Despite their many good features, ANNs cannot solve all problems, regardless of type. Therefore, in our work we also concern about the limitations of the method. Our work contributes to the definition of artificial intelligence, machine learning, and artificial neural networks in the context of agriculture.

Széleskörűen elfogadott tény, hogy az emberiség növekvő populációja, a növekvő minőségi igények, a klimatikus viszonyok megváltozása világszerte egyre nagyobb terhet rónak a mezőgazdaságra [1]. A piac felől érkező, folyamatosan változó minőségi és mennyiségi igények miatt az agrárium is változásra kényszerül. Napjainkban precíziós mezőgazdaság nélkül elképzelhetetlen a költség-hatékonyság fokozása és a környezeti terhelés csökkentése nagyüzemi szinten. A precíziós növénytermesztés és állattartás során nagy mennyiségű adat („big data”) keletkezik, aminek használható információvá alakításában [2] egyre gyakrabban használjuk a mesterséges intelligencia (artificial intelligence, AI) eszköztárát [3].

Precíziós módszerek nélkül elképzelhetetlen a költséghatékonyság fokozása és a környezeti terhelés csökkentése az agráriumban

A gépi tanulási módszerek közül a mesterséges neurális hálózatok a leghatékonyabbak az agrártudományi kutatásokban

Annotáció során osztályba sorolt adatok jelentik a bemeneti adathalmazt

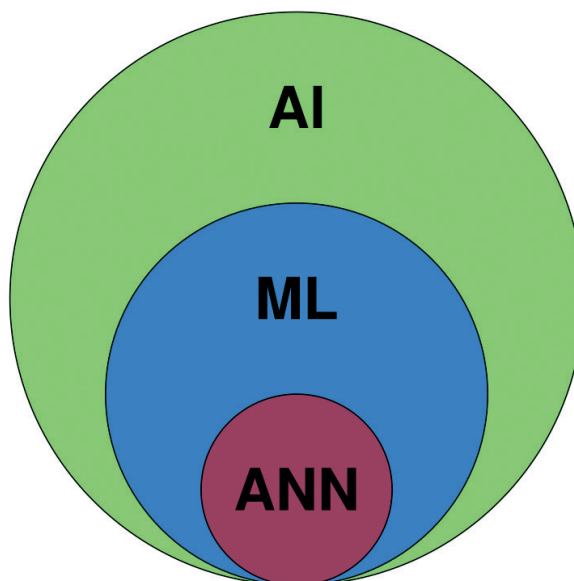
A gépi tanulás (machine learning, ML) az AI egyik részterülete, aminek általános sajátossága, hogy az összegyűjtött adatok felhasználásával, algoritmusokat tanítunk be abból a célból, hogy a számunkra fontos információt automatizáltan prediktálhassuk [1, 4]. BENOS és mtsai 2021-es tanulmányából kiderül, hogy a gépi tanulás alkalmazhatósága az agráriumot tekintve a növénytermesztésen belül a legkutatottabb (68%), ezt követi az állattenyésztés (12%), majd a víz- és talajgazdálkodás (10–10%). Az állattermék-előállításához kapcsolódó gépi tanulás használhatóságát vizsgáló tanulmányok aránya a következőképpen alakult állatfajonként: szarvasmarha (58,5%), juh és kecske (26,8%), sertés (14,6%), baromfi (4,9%) és juhászkutya (2,4%) [1]. Az állattartásban használatos gépi tanulási algoritmusokat két csoportba oszthatjuk: állatjóléti és termelékenységi elemzések (1. ábra).

Jelenleg a szakirodalomban az utóbbira vonatkozó találatok vannak túlsúlyban. A gépi tanulásnak számos válfaja létezik (pl. regressziós, random forest, k-legközelebbi szomszéd), az ezekben használt modellek alkalmazhatósága is céltól függően változó. A megoldani kívánt feladat és a rendelkezésre álló adatbázis tulajdonságainak fényében lehet a megfelelő modelleket kiválasztani [5]. BENOS és mtsainak irodalmi áttekintése alapján a gépi tanulási módszerek közül a mesterséges neurális hálózatok (artificial neural networks, ANN) a leghatékonyabbak az agrártudományi kutatásokban.

A továbbiakban az ANN-ek általános ismertetését, ill. azokra vonatkozó példákat mutatunk be. Munkánkban betekintést nyújtunk a gépi tanulás főbb jel-

1. ÁBRA. A mesterséges neurális hálózat (artificial neural network, ANN) az agráriumbeli mesterséges intelligencia (artificial intelligence, AI) alkalmazások között a leghatékonyabb gépi tanulási (machine learning, ML) eszköz

FIGURE 1. The artificial neural network (ANN) is the most effective machine learning (ML) tool among the artificial intelligence (AI) applications in agriculture



lemzőibe, alkalmazhatóságába. Tisztázzuk a gépi tanulás és a neurális hálók viszonyrendszerét. Áttekintjük az ANN alapvető felépítését és működését példákon keresztül, valamint a neurális hálók predikciós képességének értékelésével is foglalkozunk. Végül az ANN állatitermék-előállításban való használhatóságára mutatunk be példákat. Munkánk célja betekintést adni a gépi tanulási modellek, legfőképpen az ANN-ek állatitermék-előállításban való felhasználásáról.

GÉPI TANULÁS MESTERSÉGES NEURÁLIS HÁLÓZATOKKAL

A gépi tanulás olyan algoritmusokkal foglalkozik, amelyek képesek mintázatok felismerésére

A gépi tanulás a mesterséges intelligencia azon területe, amely olyan algoritmusokkal foglalkozik, amelyek képesek – az emberhez hasonlóan – mintázatok felismerésére [6]. Ezek olyan algoritmusok, amelyek képesek korábbi „tapasztalatok” felhasználásával egy adott feladat megoldására [1], anélkül, hogy direkt módon a probléma megoldására lennének programozva [5, 7]. Ahhoz, hogy egy már megalkotott általános gépi tanulási modell az általunk megoldani kívánt feladatra adjon választ, „tanítani” kell. A tanítási módszerek alapvetően két csoportba oszthatók: felügyelt (supervised) és nem felügyelt (unsupervised). Az előbbi esetén a tanítás során az algoritmus felhasználja a megfigyelt kimeneteket, míg az utóbbi nem. Alkalmazás szerint is több alaptípus létezik, pl. osztályba sorolás, objektumdetektálás, keypoint-detektálás. Változatos problémákon való alkalmazhatóságuknak és azon tulajdonságuknak köszönhetően, hogy sikeresen lehet nagy elemszámú és komplex adathalmazokon is használni, számos tudományterületen egyre elterjedtebb a gépi tanulási modellek használata [6].


A gépi tanulás folyamatának általános mozzanatait egy olyan osztálybasorolási példán keresztül mutatjuk be, amely felügyelt tanítást alkalmaz. Tegyük fel, hogy be szeretnénk tanítani egy algoritmust arra, hogy digitális fényképekről eldöntse, hogy mit ábrázolnak. Erre példa MACHUVE és mtsainak munkája, amelyben egy olyan megoldást fejlesztettek Tanzániában, aminek segítségével a gazdák baromfiürülékről készült digitális fénykép alapján korai információhoz juthatnak az állatok megbetegedésére vonatkozóan [8]. Felügyelt tanítás esetén a bementi adathalmazunk olyan adatokból áll, amihez hozzárendelünk egy címkét arra vonatkozóan, hogy milyen osztályba (ground truth) tartoznak [6]. Ez az ún. annotáció (annotation, labeling). Jelen esetben az annotálás azt jelenti, hogy van egy több mint 8000 db, kereszttezett és őshonos tojóttyúk ürlékéről készült digitális fényképből álló adathalmaz, aminek minden egyes elemét „ba-

2. ÁBRA. Egy neuron információátadási sémája

Ha az idegsejtbe érkező bemeneti jelek összegződésének eredménye meghalad egy adott határértéket, akkor kimeneti jel képződik. Ha nem haladja meg a határértéket, akkor elnyelődik, nem jut tovább a jel

FIGURE 2. The information propagation scheme of a neuron

When the sum of the input signals to the neuron exceeds a certain threshold, an output signal is produced. If it does not exceed the threshold, it is swallowed and the signal is not passed on




Az annotáció mellett a megfelelő gépi tanulási modell kiválasztása is kulcsfontosságú lépés

A mesterséges neurális hálózatok alapötletét az idegsejtek információfeldolgozási, -továbbítási modellje adta

romfipestis”, „kokcidiózis”, „szalmonellózis” vagy „egészséges” címkével látták el a kutatók PCR-vizsgálatokra és szakértői makroszkópos véleményre alapozva.

A bemeneti adathalmazunk megalkotása mellett, a megfelelő gépi tanulási modell kiválasztása az egyik kulcsfontosságú mozzanat, ami a hatékonyságot befolyásolja [5]. MACHUVE és mtsai vizsgálatukban öt különböző ANN-t tanítottak be a tojóttyúkúkok ürülékéről készült képek osztályba sorolására. A továbbiakban áttekintjük a neurális hálóok általános szerkezetét és működését [8].

Az első ANN-ek fejlesztésének, alkalmazásának alapötletét az idegsejtek információfeldolgozási, -továbbítási modellje adta [9, 10]. Ezek olyan matematikai modellek, amelyek az agy felépítéséhez hasonló szerkezettel bírnak [6]. Az agyhoz hasonlóan a neurális hálóok működését biztosító alapegységek is a neuronok. A rendszer legegyszerűbb sémája az, hogy egy idegsejtbe jelek érkezik és azokat a sejt valamilyen szabályrendszer alapján továbbítja (vagy sem) a másik idegsejt felé (2. ábra). Ez egy mesterséges neuron esetében azt jelenti, hogy



3. ÁBRA. Mély neurális hálózat

A bemeneti és kimeneti rétegek között, ún. rejtett rétegekbe rendezetten nagyszámú neuron helyezkedik el. A hálózat teljesen összekötött, mivel minden réteg minden eleme minden szomszédos réteg összes elemével kapcsolatban áll. A rejtett rétegek, ill. a bemeneti és kimeneti rétegek elemeinek száma a modellezési feladatnak megfelelően változik. A példánkban a bemeneti rétegben minden piros korong az ürülékről készült kép egy pixelét jelzi, míg a kimenet a négy lehetséges osztályt

FIGURE 3. Deep neural network

A large number of neurons are arranged in hidden layers between the input and output layers. The network is fully connected, as each element of each layer is connected to all elements of all neighbouring layers. The number of hidden layers, or the elements of input and output layers, varies according to the modelling task. In our example, each red circle in the input layer represents one pixel of the image of the feces, while the output represents the four possible classes



4. ÁBRA A gépi tanulás folyamatának sémája

A tanuló adathalmazon az algoritmus a hálózat neuronjainak paramétereit (súlyok) iteratív módon úgy változtatja, hogy a kézi annotáció és a predikció eltérését minimalizálja. Meghatározott számú iterációnként a validációs halmazon is predikciót végzünk, aminek eredményét szintén összevetjük a kézi annotációval

FIGURE 4. Schema of the machine learning process

On a learning dataset, the algorithm iteratively changes the parameters (weights) of the network neurons to minimize the deviation between manual annotation and prediction. For a given number of iterations, prediction is also performed on the validation set, the result of which is also compared with the manual annotation

A tanítóhalmaz alapján a rendszer prediktálja a validációs halmaz eredményeit

ő maga egy olyan függvény, ami egy, de inkább több bemeneti értéket (input) kimeneti értéké (output) alakít [11].

A gépi tanulásban alkalmazott neurális hálózatok ebből az egyszerű egységből kiindulva egy, de inkább több rétegbe rendezett nagyszámú neuronból állnak (3. ábra). Az egyik réteg neuronjainak outputjai lesznek a következő réteg inputjai [6]. A szomszédos rétegek elemei között lehet teljes vagy részleges az összekötöttség. A nagyszámú neuronrétegből álló hálózatokat mély hálózatoknak is nevezzük, az ezekre épülő gépi tanulást pedig mély tanulásnak (deep learning). Ahogy az inger hatására az ingerület végighalad az idegsejteken, úgy halad a kezdeti bemeneti érték neuronról neuronra az ANN szerkezetén.

Az ANN tanítását megelőzően az annotált képeket két csoportba osztjuk, a nagyobb részük (pl. 80%-a) alkotja a tanítóhalmazt (train set), a kisebb részük (20%) pedig az ún. validációs halmazt (validation set). A tanítás első lépésében az ANN minden neuronja kap egy véletlen vagy nem véletlen (pl. előtanításból származó) kezdeti paramétert (ún. súlyokat). Az input adatok (jelen esetben egy kép) belépnek az ANN-be és jelek formájában végighaladnak a neuronokon, aminek az eredménye a hálózat végén a kimenet. A példánkban a kimenet azt jelenti, hogy egy képhez négy valószínűséget rendel, legyen mondjuk az „egészséges” osztályba tartozás valószínűsége 87%, a „szalmonellózis” osztályba tartozásé 45%, a „kokcidiózisé” 28%, míg a „baromfipestisé” 9%. Ezek alapján az adott kép esetén a legnagyobb valószínűsége annak van, hogy egészséges állat ürülékét ábrázolja, így ebbe az osztályba lesz besorolva, ez lesz a végső kimeneti érték. Az így létrehozott predikciókat összehasonlítja a szakértői annotációval, és az eltéréseket csökkentendő, módosítja a neuronok súlyait. Majd a módosított súlyokkal újra prediktál osztályt a képekhez, amit megint összevet a kézi annotációval. Meghatározott számú ismétlésenként (iterációnként) az algoritmus a validációs halmaz képeit használva is készít predikciót (4. ábra).

A validációs halmazon végzett előrejelzések eredménye alapján lehet kiválasztani a legjobb eredményt adó algoritmusokat

A validációs halmazon végzett előrejelzések eredménye és a szakértői annotáció közötti különbség adja az ún. predikciós hibát, ami a modell osztályozási képességéről nyújt információt. Mivel a folyamat során minden egyes iterációval megváltoznak a paraméterek, meghatározott számú iterációnként eltárolják az ANN-hez tartozó összes paramétert és azt, hogy mekkora az eltérés a szakértői és a prediktált osztályok között. Így a tanítás befejeztével a legkisebb hibát adó paramétergyűjtemény lesz a munka eredménye, amely később felhasználható hasonló digitális fényképek osztályozására. A bemutatott példában tanító és va-

lidációs halmazokat használtunk, azonban számos esetben alkalmaznak ezen túl egy független tesztalmodrt is [12]. Ez lehetőséget nyújt arra, hogy az ANN predikciós megbízhatóságára, általánosíthatóságára vonatkozóan megalapozottabb képet kaphassunk.

A PREDIKCIÓ MINŐSÉGÉNEK ÉRTÉKELÉSE

A mesterséges neurális hálózatok besorolási hibáját minden esetben ismernünk kell

Az előzőekben láthattuk, hogy egy adott képhez azt az osztályt rendeli végül a neurális hálózat, amelynek a legnagyobb a valószínűsége. Azonban ez természetesen nem hibátlan predikció, vagyis mindig előfordulnak hibás besorolások. A gépi tanulási algoritmusok, így a mesterséges neurális hálózatok besorolási hibáját minden esetben ismernünk kell annak érdekében, hogy a használhatóságát értékelni tudjuk. A következőkben összefoglaljuk a szakirodalomban használt, a besorolási hibát számszerűsítő mértékeket, először kettő, majd több osztályra vonatkozóan. Mindkét helyzetben ún. kontingenciatáblázatban foglaljuk össze a szakértői és a prediktált osztályok egyezőségét, eltérését.

A két osztályra vonatkozó predikciós pontosság becslését Mao és mtsai munkáján keresztül mutatjuk be [13]. Ők ANN-eket tanítottak be arra, hogy elkülönítsék brojlercsirkék stresszjelző hangmintázatát a semleges istálló zajoktól. Itt tehát két osztályt használtak: a stresszt és nem-stresszt jelző hangokat. Ebben az esetben a kontingenciatáblázat egy kétszer-kettes mátrix (Táblázat), aminek a cellái a következők. A valódi negatív predikciók (true negative, TN) cellája tartalmazza azoknak a hangoknak a számát, amelyeknek a szakértői osztályozása és a neurális hálózat alapján prediktált osztálya is az istálló zaj volt. A valódi pozitív predikciók (true positive, TP) cellája tartalmazza azoknak a hangoknak a számát, amelyeknek a szakértői osztályozása és a neurális hálózat alapján prediktált osztálya is a stresszjelzés volt. A téves negatív predikciók (false negative, FN) cellája azoknak a hangoknak a számát tartalmazza, amelyek a szakértői osztályozás alapján stresszjelzések voltak, de a neurális hálózat istálló zajként klasszifikálta. A téves pozitív predikciók (false positive, FP) cellája azoknak a hangoknak a számát tartalmazza, amelyek a szakértői osztályozás alapján istálló zajok voltak, de a neurális hálózat stresszjelzésnek azonosította.

A kontingenciatáblázatból számolhatunk számos mértéket, amellyel jellemezhető a betanított neurális hálózatunk predikciós megbízhatósága. Ilyen az ac-

A kontingenciatáblázat foglalja össze a szakértői és a prediktált osztályok egyezőségét, eltérését

TÁBLÁZAT. Mao és mtsai közleményéből becsülhető kontingenciatáblázat [13]

A cellák értékei a szakértői és a prediktált osztályok egyezőségét, eltérését számszerűsítik. Az FN a téves negatív, az FP a téves pozitív, a TN a valódi negatív, a TP a valódi pozitív predikciók száma. Ezek alapján a predikció minőségét összegző értékek: accuracy = 0,957, Cohen-féle kappa = 0,908, F1 score = 0,943, precision = 0,927, recall = 0,959

TABLE Contingency table estimated from Mao et al. [13]

The values in the cells quantify the agreement or disagreement between the expert and predicted classes. FN is the number of false negatives, FP is the number of false positives, TN is the number of true negatives, and TP is the number of true positives predicted. Based on these, the values summarising the quality of prediction are: accuracy=0.957, Cohen's kappa=0.908, F1 score=0.943, precision=0.927, recall=0.959

Szakértői osztályozás	Predikció		Összesen
	Istálló zaj	Stresszjelzés	
Istálló zaj	TN = 643	FP = 30	673
Stresszjelzés	FN = 16	TP = 379	395
Összesen	659	409	1068

$curacy = (TP + TN) / (TP + TN + FP + FN)$, az $F1\ score = 2 \times TP / (2 \times TP + FP + FN)$, a $precision = TP / (TP + FP)$, ill. a $recall = TP / (TP + FN)$, ami megegyezik a szenzitív-tás/érzékenység (sensitivity, Se) és valós pozitivitási arány/true positive rate (TPR) metrikákkal. Szintén gyakran használt mérték a Cohen-féle kapp = $(accuracy - random\ accuracy) / (1 - random\ accuracy)$, ahol a $random\ accuracy = p1 \times p2 + (1 - p1) \times (1 - p2)$, továbbá $p1 = (TP + FN) / (TP + FP + TN + FN)$ és $p2 = (TP + FP) / (TP + FP + TN + FN)$. Mindegyik metrika értéke 0 és 1 között változhat, minél közelebb van az egyhez, annál jobb predikciót jelez.

Mivel a bemutatott mértékek két osztály esetén kalkulálhatók, ha ennél több osztályra vonatkozóan becsüljük a predikció minőségét, akkor az ún. egy az összes ellen (one-versus-all) megközelítést használjuk. Ez azt jelenti, hogy minden osztály esetén kiszámoljuk, hogy hány predikció esett az osztályba (ezek lesznek a TP és FP értékek), ill. hogy összesen hány esett a többi osztályba (TN és FN). Így mindegyik osztályra külön-külön becsülhetünk minőségi mértékeket. Előfordul, hogy az összes osztályra vonatkozóan megadják ezen minőségi metrikák átlagát is, mint teljes predikciós minőségi becslést.

Folytonos változókon alkalmazott predikciók esetén a bemutatott osztályba-sorolási minőségi mértékek helyett a megfigyelt és prediktált értékek különbségét felhasználva fejezzük ki a modell pontosságát. Ilyen gyakrabban használt mérték az MSEP (mean square error of prediction) vagy az RMSEP (root mean square error of prediction). Minél kisebb az értékük, annál pontosabb a predikció.

A megfigyelt és a prediktált értékek különbségét felhasználva fejezhető ki a modell pontossága

PÉLDÁK MESTERSÉGES NEURÁLIS HÁLÓZATOK ALKALMAZHATÓSÁGÁRA

Az eddig leírt tulajdonságokból adódóan, az ANN számos tudományterületen alkalmazható számtalan probléma megoldására. A következőkben egy-egy példával szemléltetjük a neurális háló sokrétű használhatóságát az állatitermék-előállítás folyamata során. E folyamat első mozzanatai közé tartozik a takarmányelőállítás, ehhez kapcsolódóan Nagy és mtsai lucernaszenázs-min-tákban detektáltak antimikrobiális rezisztenciagéneket (ARG) [14]. Az ARG-ket tartalmazó DNS-szekvenciák plazmideredetét ANN felhasználásával prediktálták. Ugyanezt a megközelítést alkalmazták állati termékekben, így nyerstejben [15], probiotikus élelmiszerekben [16] és étrend-kiegészítőben [17] azonosított ARG-k mobilitásának vizsgálatában.

Annak ellenére, hogy a mézelő méhek extenzíven tartott haszonállatok, a méztermeléshez kapcsolódóan számos ML-alkalmazás születik. PAOLILLO és mtsai mézelő méhek kaptár-higiéniái viselkedésének digitális felvételeken történő megfigyelésére használtak ANN-t [18]. BILIK és mtsai méhek *Varroa destructor* atka fertőzöttségének detekciójában alkalmaztak neurális hálókat [19]. ALVES és mtsai mély tanuláson alapuló szoftvert fejlesztettek, amely a lépsejtek hét típusát tudja automatizáltan elkülöníteni [20]. RACHINENI és mtsai nádcukorból készült sziruppal, barnarizssziruppal és kukoricasziruppal hamisított mézeket vizsgáltak mágneses magrezonancia spektroszkópia segítségével [21]. Az alkalmazott gépi tanulási eljárások – köztük az ANN – is alkalmasnak bizonyultak a szirupok mézben való felderítésére.

Az extenzívnek mondható méhtartással szemben, a tejelő szarvasmarhatartás folyamatainak gépesítése már a 19. század vége óta elindult [22]. Az első fejőgép megjelenését számtalan gép követte a tejtermelésben, ami manapság tejelő tehenészetekben növeli az automatizáció mértékét, segít az érzékelésben. Az érzékelők bővülő köre és mindennapi használata lehetőséget biztosít gépi tanulási módszerek fejlesztésére és használatára [23]. Mesterséges neurális hálót használva tettek már kísérletet a sántaság automatikus felismerésére [24, 25], az aktivitás monitorozásán alapuló ivarzásmegfigyelés javítására [26], valamint

Neurális hálózatokkal prediktálható egyes antimikrobiális rezisztenciagének plazmideredete

Mesterséges neurális hálót fejlesztettek már sántaság- és ivarzásmegfigyelésre, ill. kondíciópontozásra is szarvasmarhában

A sertés- és baromfitartásban, valamint az élelmiszerbiztonság területén is fejlesztettek már neurális hálózatokon alapuló rendszereket

a kondíciópontozás (body condition score, BCS) gépesítésére is [12, 27, 28]. Egy magyarországi tehenészetben készült vizsgálatban az ANN predikciós képességét határozták meg különböző BCS-skálák esetében. Továbbá az is a vizsgálat tárgyát képezte, hogy a pontozáshoz figyelembe vett terület mérete, hogyan befolyásolja a predikciót. Kutatásuk során sikerült olyan beállítást alkalmazni, amellyel közepes/erős predikcióhoz juthatunk ANN segítségével [12].

A tehenészeti telepeken jellemző gépesítettség is meghaladja az intenzív és félintenzív akvakultúrák automatizáltsága. Ezek gazdaságos működése csak adatintenzív technológiákkal érhető el. Ehhez elengedhetetlen az innovatív és automatizált technikák kifejlesztése, használata [29]. Akvakultúrák esetében is számos lehetőség kínálkozik neurális hálók alkalmazására. Zhou és mtsai kutatásukban négy csoportba soroltak halakat étvágyuk szerint ANN segítségével [30]. FERNANDES és mtsai olyan ANN-t hoztak létre, amely képes nílusi tilápiákat azonosítani, azok testtömegét és karkaszuk tömegét megbecsülni [31]. Liu és mtsai a vízben jelen lévő oldott oxigén mennyiségét jelezték előre ANN segítségével [32].

Az akvakultúrákhoz hasonlóan a sertéstartás bizonyos szegmenseiben a nagyfokú iparosodottság elkerülhetetlen, amely szintén automatizált munkafolyamatokon, adatelemzésen alapul [33]. ZHANG és mtsai 3D-s képek feldolgozásával olyan, teljesen automatikus rendszert hoztak létre, amely képes sertések testtömegét és testméreteit felmérni [34]. Az állatok termélekenységének vizsgálatán túl a takarmányra vonatkozó információkat is szerezhetünk neurális hálók segítségével [35]. BRÜNGER és mtsai arra tettek kísérletet, hogy vágóhídon készített fényképekre alapozva ANN segítségével automatizálni tudják a farokrágás jeleinek (0-tól 3-ig osztályozva, súlyosság szerint) felismerését a vágási folyamat során. Ezzel könnyítve meg az állatjóléti felmérések kivitelezését [36]. A viselkedés közvetlen vizsgálata is elérhető ANN segítségével. Videóelemzéssel lehetséges a sertések szociális viselkedésének értékelése, ezáltal pedig a viselkedés megváltozásának korai felismerése. WUTKE és mtsai modelljükkel képesek voltak videófelvételen szereplő sertéseket azonosítani, követni, és a szociális interakcióikat (fej-fej, fej-farok kontaktus) azonosítani [37]. A takarmány- és vízfelvétel vizsgálata szintén elvégezhető ANN-re alapozott videóelemzéssel. KIM és mtsai választás utáni malacok takarmány- és vízfelvételi szokásait vizsgálták. Tanulmányukban arra jutottak, hogy a modell a jövőben alkalmas lehet a választás utáni kritikus időszakban a malacok takarmányfelvételét követni, amivel hozzájárul a takarmányozás javulásához [38].

A baromfitartás során szintén számos lehetőség van ANN-k használatára. LI és mtsai naposcsibék hang alapján történő szexálását vizsgálta sikeresen labor körülmények között. Három különböző baromfifaj naposcsibéinek hangját elemezve a neurális háló különbséget tudott tenni a kakasok és a tojók között [39]. Léteznek olyan neurális hálók, amelyek képesek brojlercsirkék gyarapodási görbéjét [40], vagy akár tojótyúkok tojástermelési görbéjét [41] prediktálni. A viselkedés monitorozására szintén alkalmazható módszernek bizonyult a ANN brojlercsirkék esetében. A csirkéket 1–50 napos koruk között vizsgálva ANN segítségével automatikusan osztályozni tudták a viselkedésük alapján őket négy kategóriába (evés, ivás, állás, pihenés) [42].

A gépi tanulás alkalmazhatósága az állatitermék-előállításban nem csak a szűken vett állattartásban jelenik meg. Számtalan példa létezik az élelmiszerlánc későbbi pontjain is ANN használatára növényi, állati és mikrobiális eredetű élelmiszerek vonatkozásában is [43, 44]. CORONEL-REYES és mtsai tyúktojások frissességét prediktálták sikeresen ANN segítségével közeli infravörös reflexiók (near infrared reflectance, NIR) mérések alapján [45]. Yu és mtsai szintén NIR technológiát alkalmaztak hiperspektrális képalkotással kiegészítve fehér garnélarákok bakteriális szennyezettségének felderítésére. A használt ANN-modell képes volt

nagy pontossággal prediktálni a garnélarákok szennyezettségét [46]. Mindkét módszer képes anélkül precíz eredményt adni, hogy a vizsgált élelmiszer minőségét rontaná, ami előnyös tulajdonság az élelmiszer-vizsgálatoknál.

MEGVITATÁS

Ahogy a bemutatott példákból látható, és a mesterséges intelligencia általános terjedése alapján várható, az állatitermék-előállítás folyamatában egyre több ML-, ezen belül ANN-alkalmazás jelenik meg. Annak ellenére, hogy az ML-modellek képesek az adatokban rejlő minták azonosításán keresztül bonyolult feladatokra megoldást adni [47], számos hátulütőjük említhető. Ilyen az adatérzékenységük, ami kritikus pontja a hatékonyságuknak. Amikor a való életből származó adatokkal dolgozunk, a legritkább esetben találkozunk jól dokumentált, jól strukturált, kellő gyakorisággal és pontossággal, különböző forrásokból gyűjtött, sokféle és nagy mennyiségű adattal („big data”). Sokkal inkább a retrospektív adatgyűjtés a jellemző, amelynek sokszor velejárója a kétértelmű, hiányzó, kiugró értékeket és értelmetlen adatokat tartalmazó adatsorok [5]. Ezeket sok esetben rosszul kezelik az ML-modellek, ami a hatékonyság romlásában mutatkozik meg. A másik, hatékonyságot rontó körülmény az adott feladathoz nem megfelelő modell alkalmazása. Ezt úgy kerülik el, hogy több eltérő modellt próbálnak ki párhuzamosan, és a legkisebb hibát eredményező(ke)t tartják meg. Az ML általánosságban vett nehézségein túl, a mezőgazdaságban való alkalmazását számos egyéb, az agráriumra jellemző tényező is terheli. A gyakorlatban való felhasználást nehezíti az a körülmény, hogy az ML-rendszerek adatérzékenysége miatt a megfelelő adatgyűjtés általában nagyszámú érzékelőn keresztül valósul meg. Ezek sokszor drágák, kezdetben jelentős befektetést igényelnek az állattartó, növénytermesztő részéről [48], amelyek gátat jelenthetnek a beszerzésüknek. Továbbá a termelés felügyeletére megvásárolt különböző gyártmányú érzékelők sokszor nem alkalmasak arra, hogy egy szabványosított adatinfrastruktúrát biztosítsanak az egyes gyártók különböző módszerei miatt [3]. Egy adott adathalmazon, környezetben betanított ANN kiterjeszhetősége változó. Ami azt jelenti, hogy egy adott állományban fejlesztett és jól prediktáló modell nem biztos, hogy máshol is ugyanolyan jól működik. Érdemes azonban rámutatni arra a lehetőségre, hogy egy betanított ANN neuronjaihoz tartozó súlyokat egy másik ANN-nek, azonos feladatra való tanítása során kezdeti paraméterként lehet használni. Így az új adatokon történő tanítás egy ún. előtanított ANN-ből indul ki. Ez azzal jár, hogy az ilyen módon végzett adaptálás kevesebb új tanító adatot igényel. Ezt felismerve nem kivételes az, hogy a területen dolgozó kutatók az általuk létrehozott súlyokat közléstessik, ezáltal mások fejlesztéseit megkönnyítve [12]. A korlátait figyelembe véve a gépi tanulás és azon belül a mesterséges neurális hálókat a mezőgazdaságban hatékony eszközt adnak a kezünkbe, hogy optimalizálhassuk a termelési hatékonyságot, és ezzel párhuzamosan csökkenthessük a termelés okozta környezeti terhelést [1, 23].

A gépi tanulási rendszerek alapja a megfelelő pontossággal gyűjtött adathalmaz

A mesterséges neurális hálókat segíthetnek optimalizálni a termelési hatékonyságot és csökkenteni a környezeti terhelést

KÖSZÖNETNYILVÁNÍTÁS

A munka az Európai Unió támogatásával valósult meg, az RRF-2.3.1-21-2022-00004 MILAB azonosítójú, Mesterséges Intelligencia Nemzeti Laboratórium projekt keretében.

IRODALOM

- Benos L, Tagarakis A, Dolias G, Berruto R, Kateris D, Bochtis D (2021) Machine learning in agriculture: A comprehensive updated review. *Sensors* 21:3758. <https://doi.org/10.3390/s21113758>
- Nagy S, Tőzsér D, Szombath G, Baranyi D, Reibling T, Biksi I, Solymosi N (2017) Statisztikai ellenőrző diagramok az állattermék-előállításban. *Magy Állatorvosok Lapja* 139:515–523
- Cockburn M (2020) Application and prospective discussion of machine learning for the management of dairy farms. *Animals* 10:1690. <https://doi.org/10.3390/ani10091690>
- Slob N, Catal C, Kassahun A (2021) Application of machine learning to improve dairy farm management: A systematic literature review. *Prev Vet Medicine* 187:105237. <https://doi.org/10.1016/j.prevetmed.2020.105237>
- Sarker I (2021) Machine learning: Algorithms, real-world applications and research directions. *SN Comput Sci* 2:1–21. <https://doi.org/10.1007/s42979-021-00592-x>
- Greener J, Kandathil S, Moffat L, Jones D (2022) A guide to machine learning for biologists. *Nat Rev Mol Cell Biol* 23:40–55. <https://doi.org/10.1038/s41580-021-00407-0>
- Bi Q, Goodman K, Kaminsky J, Lessler J (2019) What is machine learning? a primer for the epidemiologist. *Am Journal Epidemiology* 188:2222–2239. <https://doi.org/10.1093/aje/kwz189>
- Machuve D, Nwankwo E, Mduma N, Mbelwa J (2022) Poultry diseases diagnostics models using deep learning. *Front Artif Intell* 5:733345. <https://doi.org/10.3389/frai.2022.733345>
- McCulloch W, Pitts W (1943) A logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys* 5:115–133
- Kleene S, Ashby W, Culbertson J, Davis M, De Leeuw K, Mac Kay D, McCarthy J, Minsky M, Moore E, Shannon C, Shapiro N, Uttley A, Von Neumann J (1956) Representation of events in nerve nets and finite automata. Shannon C, McCarthy J (eds) *Automata Studies*, Princeton University Press, pp 3–42
- Nayeri S, Sargolzaei M, Tulpan D (2019) A review of traditional and machine learning methods applied to animal breeding. *Anim Health Res Rev* 20:31–46. <https://doi.org/10.1017/S1466252319000148>
- Nagy S, Kilim O, Csabai I, Gábor G, Solymosi N (2023) Impact evaluation of score classes and annotation regions in deep learning-based dairy cow body condition prediction. *Animals* 13:194. <https://doi.org/10.3390/ani13020194>
- Mao A, Giraudet C, Liu K, Nolasco I, Xie Z, Xie Z, Gao Y, Theobald J, Bhatta D, Stewart R, McElligott A (2022) Automated identification of chicken distress vocalizations using deep learning models. *J Royal Soc Interface* 19:20210921. <https://doi.org/10.1098/rsif.2021.0921>
- Nagy S, Tóth A, Papp M, Kaplan S, Solymosi N (2022) Antimicrobial resistance determinants in silage. *Sci Reports* 12:1–10. <https://doi.org/10.1038/s41598-022-09296-5>
- Tóth A, Csabai I, Krikó E, Tőzsér D, Maróti G, Patai Á, Makrai L, Szita G, Solymosi N (2020) Antimicrobial resistance genes in raw milk for human consumption. *Sci Reports* 10:1–7. <https://doi.org/10.1038/s41598-020-63675-4>
- Tóth A, Csabai I, Maróti G, Jerzsele Á, Dubecz A, Patai Á, Judge M, Nagy S, Makrai L, Bányai K, Szita G, Solymosi N (2020) A glimpse of antimicrobial resistance gene diversity in kefir and yoghurt. *Sci Reports* 10:1–12. <https://doi.org/10.1038/s41598-020-80444-5>
- Tóth A, Csabai I, Judge M, Maróti G, Becsei Á, Spisák S, Solymosi N (2021) Mobile antimicrobial resistance genes in probiotics. *Antibiotics* 10:1287. <https://doi.org/10.3390/antibiotics10111287>
- Paolillo G, Petrini A, Casiraghi E, De Iorio M, Biffani S, Pagnacco G, Minozzi G, Valentini G (2022) Automated image analysis to assess hygienic behaviour of honeybees. *PLoS one* 17:e0263183. <https://doi.org/10.1371/journal.pone.0263183>
- Bilik S, Kratochvila L, Ligocki A, Bostik O, Zemcik T, Hybl M, Horak K, Zalud L (2021) Visual diagnosis of the Varroa Destructor parasitic mite in honeybees using object detector techniques. *Sensors* 21:2764. <https://doi.org/10.3390/s21082764>
- Alves T, Pinto A, Ventura P, Neves C, Biron D, Junior A, De Paula Filho P, Rodrigues P (2020) Automatic detection and classification of honey bee comb cells using deep learning. *Comput Electron Agric* 170:105244. <https://doi.org/10.1016/j.compag.2020.105244>
- Rachineni K, Kakita V, Awasthi N, Shirke V, Hosur R, Shukla S (2022) Identifying type of sugar adulterants in honey: Combined application of NMR spectroscopy and supervised machine learning classification. *Curr Research Food Science* 5:272–277. <https://doi.org/10.1016/j.crfs.2022.01.008>
- Odorčić M, Rasmussen M, Paulrud C, Bruckmaier R (2019) Milking machine settings, teat condition and milking efficiency in dairy cows. *Animal* 13:94–99. <https://doi.org/10.1017/S1751731119000417>
- Liakos K, Busato P, Moshou D, Pearson S, Bochtis D (2018) Machine learning in agriculture: A review. *Sensors* 18:2674. <https://doi.org/10.3390/s18082674>
- Kang X, Zhang X, Liu G (2020) Accurate detection of lameness in dairy cattle with computer vision: A new and individualized detection strategy based on the analysis of the supporting phase. *J Dairy Science* 103:10628–10638. <https://doi.org/10.3168/jds.2020-18288>
- Shahinfar S, Khansefid M, Haile-Mariam M, Pryce J (2021) Machine learning approaches for the prediction of lameness in dairy cows. *Animal* 15:100391. <https://doi.org/10.1016/j.animal.2021.100391>
- Wang J, Bell M, Liu X, Liu G (2020) Machine-learning techniques can enhance dairy cow estrus detection using location and acceleration data. *Animals* 10:1160. <https://doi.org/10.3390/ani10071160>
- Tao Y, Li F, Sun Y (2022) Development and implementation of a training dataset to ensure clear boundary value of body condition score classification of dairy cows in automatic system. *Livest Sci* 259:104901. <https://doi.org/10.1016/j.livsci.2022.104901>
- Zhao K, Zhang M, Shen W, Liu X, Ji J, Dai B, Zhang R (2023) Automatic body condition scoring for dairy cows based on efficient net and convex hull features of point clouds. *Comput Electron Agric* 205:107588. <https://doi.org/10.1016/j.compag.2022.107588>
- Lopes B, Silva L, Blanquet I, Georgieva P, Marques C (2021) Prediction of fish mortality based on a probabilistic anomaly detection approach for recirculating aquaculture system facilities. *Rev Sci Instrum* 92:025119. <https://doi.org/10.1063/5.0045047>
- Zhou C, Xu D, Chen L, Zhang S, Sun C, Yang X, Wang Y (2019) Evaluation of fish feeding intensity in aquaculture using a convolutional neural network and machine vision. *Aquaculture* 507:457–465. <https://doi.org/10.1016/j.aquaculture.2019.04.056>
- Fernandes A, Turra E, De Alvarenga É, Passafaro T, Lopes F, Alves G, Singh V, Rose G (2020) Deep learning image segmentation for extraction of fish body measurements and prediction of body weight and carcass traits in Nile tilapia. *Comput Electron Agric* 170:105274. <https://doi.org/10.1016/j.compag.2020.105274>

32. Liu Y, Zhang Q, Song L, Chen Y (2019) Attention-based recurrent neural networks for accurate short-term and long-term dissolved oxygen prediction. *Comput Electron Agric* 165:104964. <https://doi.org/10.1016/j.compag.2019.104964>
33. Neethirajan S, (2020) The role of sensors, big data and machine learning in modern animal farming. *Sens Bio-Sensing Res* 29:100367. <https://doi.org/10.1016/j.sbsr.2020.100367>
34. Zhang J, Zhuang Y, Ji H, Teng G, (2021) Pig weight and body size estimation using a multiple output regression convolutional neural network: A fast and fully automatic method. *Sensors* 21:3218. <https://doi.org/10.3390/s21093218>
35. Ahmadi H, Rodehutsord M (2017) Application of artificial neural network and support vector machines in predicting metabolizable energy in compound feeds for pigs. *Front Nutr* 4:27. <https://doi.org/10.3389/fnut.2017.00027>
36. Brünger J, Dippel S, Koch R, Veit C, (2019) 'Tailception': using neural networks for assessing tail lesions on pictures of pig carcasses. *Animal* 13:1030–1036. <https://doi.org/10.1017/S1751731118003038>
37. Wutke M, Heinrich F, Das P, Lange A, Gentz M, Traulsen I, Warns F, Schmitt A, Gültas M (2021) Detecting animal contacts—a deep learning-based pig detection and tracking approach for the quantification of social contacts. *Sensors* 21:7512. <https://doi.org/10.3390/s21227512>
38. Kim M, Choi Y, Lee J, Sa S, Cho H (2021) A deep learning-based approach for feeding behavior recognition of weanling pigs. *J Anim Sci Tech* 63:1453. <https://doi.org/10.5187/jast.2021.e127>
39. Li Z, Zhang T, Cuan K, Fang C, Zhao H, Guan C, Yang Q, Qu H (2022) Sex detection of chicks based on audio technology and deep learning methods. *Animals* 12:3106. <https://doi.org/10.3390/ani12223106>
40. Ahmad H (2009) Poultry growth modeling using neural networks and simulated data. *J Appl Poult Res* 18:440–446. <https://doi.org/10.3382/japr.2008-00064>
41. Savegnago R, Nunes B, Caetano S, Ferraudo A, Schmidt G, Ledur M, Munari D (2011) Comparison of logistic and neural network models to fit to the egg production curve of white leghorn hens. *Poult Sci* 90:705–711. <https://doi.org/10.3382/ps.2010-00723>
42. Guo Y, Aggrey S, Wang P, Oladeinde A, Chai L (2022) Monitoring behaviors of broiler chickens at different ages with deep learning. *Animals* 12:3390. <https://doi.org/10.3390/ani12233390>
43. Liang N, Sun S, Zhang C, He Y, Qiu Z (2022) Advances in infrared spectroscopy combined with artificial neural network for the authentication and traceability of food. *Critical Rev. Food Sci Nutr* 62, 2963–2984. <https://doi.org/10.1080/10408398.2020.1862045>
44. Funes E, Allouche Y, Beltrán G, Jiménez A (2015) A review: artificial neural networks as tool for control food industry process. *J Sens Technol* 5:28–43. <https://doi.org/10.4236/jst.2015.51004>
45. Coronel-Reyes J, Ramirez-Morales I, Fernandez-Blanco E, Rivero D, Pazos A (2018) Determination of egg storage time at room temperature using a low-cost NIR spectrometer and machine learning techniques. *Comput Electron Agric* 145:1–10. <https://doi.org/10.1016/j.compag.2017.12.030>
46. Yu X, Yu X, Wen S, Yang J, Wang J (2019) Using deep learning and hyperspectral imaging to predict total viable count (tvc) in peeled pacific white shrimp. *J Food Meas Charact* 13:2082–2094. <https://doi.org/10.1007/s11694-019-00129-0>
47. Boutaba R, Salahuddin M, Limam N, Ayoubi S, Shahriar N, Estrada-Solano F, Caicedo O (2018) A comprehensive survey on machine learning for networking: evolution, applications and research opportunities. *J Internet Serv Appl* 9:1–99. <https://doi.org/10.1186/s13174-018-0087-2>
48. Yang X, Zhang S, Liu J, Gao Q, Dong S, Zhou C (2021) Deep learning for smart fish farming: applications, opportunities and challenges. *Rev Aquac* 13:66–90. <https://doi.org/10.1111/raq.12464>

Közlésre érk.: 2023. febr. 7.