PREGLEDNI RAD

Umjetna inteligencija u proizvodnji mesa - primjene, izazovi i smjerovi razvoja

Goran Kiš[1], Vatroslav Bubalo[2], Matea Gale[3], Maja Popović Nikolić Džolan[3]*

Sažetak

U mesnoj industriji sve se češće uvode i koriste računalni sustavi kako bi ubrzali rad u pogonima, ujednačili kvalitetu proizvoda, osigurali ispravnost hrane i olakšali praćenje sirovina uz što manje otpada. Moderni pogoni koriste algoritme strojnog i dubokog učenja, računalni vid, robotiku i prediktivne modele kako bi iskoristili velike količine podataka koje svakodnevno prikupljaju kamerama i senzorima na proizvodnim linijama. Ova tehnologija nudi rješenja za konkretne probleme u mesnom sektoru. Zbog velikih prirodnih razlika među životinjama, teških uvjeta rada u klaonicama i strogih higijenskih propisa, ljudsko oko i ručna procjena više nisu dovoljni za visoku preciznost. Suvremeni programi i algoritmi više se ne bave samo jednostavnim prepoznavanjem i razvrstavanjem pojedinih komada mesa ili proizvoda, već predviđaju tijek cijelog procesa njihove proizvodnje, automatski prikupljaju podatke i pomažu u prilagodbi rada u stvarnom vremenu. Ipak, širenje ove tehnologije još uvijek ograničavaju čimbenici poput kvalitete dostupnih podataka na terenu, problemi s povezivanjem softvera različitih proizvođača, visoka cijena opreme te potreba za modelima koje bi zaposlenici i stručnjaci mogli jednostavno razumjeti i provjeriti. Ovaj pregled donosi uvid u primjenu umjetne inteligencije u mesnom sektoru te analizira njezine prednosti, izazove i smjer budućeg razvoja.

Ključne riječi: umjetna inteligencija; mesna industrija; strojno učenje; procjena kvalitete mesa; sigurnost hrane; održiva proizvodnja

Uvod

Mesni se sektor danas suočava s višestrukim izazovima. Proizvođači moraju paziti da im proizvodi budu vrhunske kvalitete i zdravstveno ispravni, dok istodobno trebaju kontrolirati troškove, štedjeti resurse te voditi računa o dobrobiti životinja i zadovoljavati stroge ekološke propise. Situaciju dodatno otežavaju trajni nedostatak obučenih radnika i sve stroža pravila proizvodnje. Zbog toga se klasičan način rada, u kojem sve ovisi o ljudskom oku i dugogodišnjem iskustvu pojedinca, više ne može nositi s brzim tempom moderne proizvodnje (Baltić i Bišković, 2015.; Jeon i sur., 2025.).

U takvim okolnostima tehnologija nudi konkretna rješenja i pomaže u modernizaciji proizvodnih pogona. Računalni sustavi mogu u sekundi obraditi veliku količinu informacija s proizvodnih traka i uočiti nepravilnosti koje ljudima mogu promaknuti. To zaposlenicima i tehnologi-

[1] **dr. sc. Goran Kiš, redoviti profesor;** Sveučilište u Zagrebu Agronomski fakultet, Svetošimunska cesta 25, 10000 Zagreb, Hrvatska
[2] **dr. sc. Vatroslav Bubalo;** Klinička bolnica Dubrava, Avenija Gojka Šuška 6, 10000, Zagreb, Hrvatska
[3] **Matea Gale, mag. oec.; dr. sc. Maja Popović Nikolić Džolan,** redovita profesorica u trajnom zvanju; Veterinarski fakultet Sveučilišta u Zagrebu, Heinzelova 55, Zagreb, Hrvatska
** Autor za korespondenciju: kis@agr.hr*

ma olakšava donošenje brzih i nepristranih odluka na temelju stvarnih brojki, a ne slobodne, osobne procjene (Lyu i sur., 2025.). Kada se ukloni faktor umora ili subjektivnog dojma, proizvodi postaju ujednačeni, a kontrola nad svakim komadom mesa provodi se sustavno od samog početka proizvodnje do pakiranja.

U praksi se najviše koriste računalni vid, strojno i duboko učenje, robotika te prediktivni modeli. Ti sustavi neprekidno prikupljaju podatke s kamera, senzora i mjernih instrumenata na liniji, tražeći bilo kakva odstupanja od zadanih parametara kako bi spriječili kvarove ili zastoje prije nego do njih uopće dođe. To predstavlja velik pomak u usporedbi s tradicionalnim pristupom. Dok se klasični pregledi provode tek povremeno ili na uzorcima, ovi računalni alati nadziru proizvodni proces bez prekida i javljaju probleme istog trena, kada se oni pojave (Hwang i sur., 2025.). Mogućnosti ove tehnologije ubrzano rastu. Prve generacije sustava rješavale su samo jednostavne zadatke, poput razvrstavanja robe na traci ili analize statičnih slika. Danas napredni programi mogu simulirati cijeli tijek rada u pogonu, samostalno bilježiti podatke, prilagođavati brzinu strojeva i pomagati voditeljima u vođenju poslovanja. Stoga ovi alati više nisu samo teorijski koncept, nego postaju standardni dio onoga što danas nazivamo pametnom industrijom i novom fazom proizvodnje hrane (Sun i sur., 2025.).

Ipak, uvođenje takvih rješenja u praksi ide sporije nego u laboratoriju. Glavne prepreke su loša ili neujednačena kvaliteta podataka s terena, nedostatak kompatibilnosti između softvera različitih proizvođača te visoka cijena same opreme. Uz to, tehnolozima i inspektorima trebaju transparentni modeli čije odluke mogu lako razumjeti i provjeriti, a ne zatvorene „crne kutije“. O rješavanju ovih tehničkih i financijskih prepreka izravno ovisi koliko će brzo mesna industrija u praksi prihvatiti ove nove alate u svakodnevnom poslovanju (Idamokoro, 2025.).

AI u proizvodnji mesa

Zanimljivo je da primjena ovih sustava ne počinje tek u klaonici ili u fazi pakiranja proizvoda, nego znatno ranije – na samoj farmi. Kamere i senzori u stajama mogu kontinuirano pratiti ponašanje, zdravlje i dobrobit životinja, ali i optimalnost uvjeta u uzgojnom prostoru. Ako sustav na vrijeme uoči odstupanja, uzgajivači mogu reagirati odmah, prije nego što se problem odrazi na zdravlje stada, rast životinja ili, naposljetku, na samu kvalitetu mesa (Jeon i sur., 2025.). Ova faza je ključna jer sve što se događa prije klanja – od prehrane i uvjeta u staji do načina prijevoza i stresa koji životinja doživi – izravno određuje fizikalna svojstva i tehnološku iskoristivost mesa. Računalni sustavi povezuju te podatke tijekom cijeloga uzgojnog ciklusa. Time proizvođači dobivaju vrijedan uvid na temelju kojeg mogu pravodobno reagirati, izbjeći serije nezadovoljavajuće kvalitete i smanjiti ekonomske gubitke (Lyu i sur., 2025.).

Dodana vrijednost ove tehnologije očituje se u integraciji podataka s farme s onima iz samoga procesa prerade. Pametni algoritmi mogu unaprijed procijeniti koje životinje možda neće postići željeni prirast ili donijeti očekivanu vrijednost trupa nakon klaoničke obrade. Na taj način farmeri mogu učinkovitije planirati proizvodne procese i upravljati stadom. To je zapravo srž preciznog stočarstva – cilj je postići stabilne proizvodne rezultate uz što manji utrošak hrane, vode i energije (Wolfert i sur., 2017.; Sun i sur., 2025.).

Jasno je, dakle, da ove digitalne alate ne treba promatrati kao zatvorene sustave koji služe samo za rasijecanje, porcioniranje ili pakiranje mesa. Prava se vrijednost krije u sposobnosti povezivanja svakog koraka u lancu opskrbe: od primarne poljoprivredne proizvodnje i uzgoja, preko klaoničke obrade i tehnološke dorade, do distribucije i maloprodaje. Kada se podaci iz svih tih faza objedine u cjelovitu bazu, čitav proizvodni proces postaje jednostavniji za upravljanje, sigurniji za potrošače, ekonomski isplativiji i ekološki prihvatljiviji (Kamilaris i sur., 2018.; Liakos i sur., 2018.).

Procjena kvalitete mesa

Tehnologija obrade podataka danas se brzo razvija upravo na primjeru ocjenjivanja mesnih proizvoda. Kupci i prerađivači kvalitetu mesa ocjenjuju na temelju boje, mramoriranosti, mekoće, svježine i sposobnosti zadržavanja vode, pazeći pritom na površinske greške i strukturne nedostatke. Točna procjena tih svojstava određuje konačnu tržišnu vrijednost proizvoda, omogućuje njegovu ispravnu klasifikaciju te izravno utječe na povjerenje kupaca (Esmaeily i sur., 2024.).

Uobičajeni pregledi mesa i dalje ovise o ljudskom oku i iskustvu ocjenjivača. Ljudi se, međutim, umaraju, a njihove se procjene razlikuju, što otežava ujednačenost rada u brzim i velikim pogo-

nima. Taj se problem rješava uvođenjem kamera i modela dubokog učenja koji pregledavaju meso u određenim fazama procesa proizvodnje, bez oštećivanja tkiva (Hwang i sur., 2025.). Ovi računalni programi primaju podatke sa senzora i digitalnih kamera, uspoređuju ih s ranije unesenim primjerima i ocjenjuju fizikalna svojstva pojedinih komada mesa na traci. Sustav prepoznaje odstupanja u boji, rasporedu masnog tkiva ili svježini, uočavajući i sitne promjene koje ljudski kontrolori lako previde. Cijeli proces procjene traje djelić sekunde, pa se kontrola odvija izravno na proizvodnoj traci kontinuirano i bez zastoja (Hassoun i sur., 2023.; Idamokoro i sur., 2025.).

Modeli dubokog učenja s visokom točnošću određuju svježinu mesa. Kada se računalni vid poveže s hiperspektralnim kamerama, koje analiziraju kemijski sastav i distribuciju vlage ili strukturiranim svjetlom, koje trodimenzionalno mapira površinsku teksturu i volumen komada mesa, sustav može predvidjeti mekoću i teksturu vlakana. Spajanje podataka iz više različitih senzorskih mjerenja osiguravaju se znatno pouzdaniji rezultati u usporedbi s primjenom samo jedne metode (Alvarez-Garcia, 2024.).

Primarna prednost uvođenja ovakvih rješenja očituje se u ujednačavanju kriterija. Svaki se proizvod analizira s pomoću istog algoritma, što isključuje odstupanja među smjenama, radnicima ili različitim pogonima istog proizvođača. Klasifikacija postaje ujednačena, smanjuje se broj pogrešno svrstanih serija, a cijela proizvodnja postaje predvidljiva. Čak i minimalna unaprjeđenja u preciznosti sortiranja donose znatne financijske uštede jer prerađivačima olakšavaju pakiranje skupljih kategorija mesa te kupcima osiguravaju stabilnu kvalitetu (Wang i Li, 2024.; Yu i sur., 2026.).

Sigurnost hrane

Digitalni alati donose izravnu korist u području zaštite zdravlja potrošača i održavanja povjerenja u ispravnost hrane (Hwang i sur., 2025.). Meso je sirovina podložna brzom kvarenju i lakoj kontaminaciji, kemijskim spojevima ili stranim tijelima u svim fazama – od klaoničke obrade, preko skladištenja u hladnjačama do transporta. Rano otkrivanje neispravnosti sprječava da kontaminirani proizvodi uopće napuste proizvodni pogon (Hwang i sur., 2025.). Laboratorijski testovi i mikrobiološke analize ostaju temelj svake kontrole, no te su analize nerijetko dugotrajne. U trenutku kada stignu rezultati, meso se već često nalazi u distributivnim centrima ili na policama trgovina. Algoritmi mogu ukloniti taj vremenski pritisak jer neprekidno prate proizvodne parametre u pogonu i pružaju jasan uvid u stanje sustava u stvarnom vremenu. Računalo obrađuje podatke o temperaturi, vlažnosti zraka i čistoći s proizvodnih linija te identificira okolnosti u kojima se patogeni mikroorganizmi najbrže razmnožavaju. Sustav prepoznaje rizične obrasce i upozorava zaposlenike mnogo prije nego što se kvarenje fizički uoči ili laboratorijski potvrdi, što ostavlja dovoljno vremena za zaustavljanje proizvodne serije sumnjive na onečišćenje (Idamokoro i sur., 2025.). Stoga u kontekstu kontrole kvalitete (Quality Control - QC) i osiguranja kvalitete (Quality Assurance - QA), digitalni sustavi donose revolucionarni odmak od tradicionalnih metoda. Oni transformiraju kontrolu kvalitete iz reaktivnog procesa (uočavanje pogreške nakon što se dogodi) u proaktivni sustav koji radi u stvarnom vremenu. Znanstveni radovi potvrđuju da strojno učenje uspješno predviđa razvoj bakterijskih kolonija i procjenjuje higijenu radnih površina. Zbog toga se sve više zahtijevaju „objašnjivi modeli" (engl. Explainable AI), pri čemu tehnolozi i sanitarni inspektori mogu točno rekonstruirati korake i parametre na temelju kojih je donesen zaključak o ispravnosti određenog proizvoda. Tako oblikovana, precizna i jasna obrazloženja odluka grade povjerenje nadzornih tijela i samih potrošača u pouzdanost te sigurnost računalnih sustava (Esmaeily i sur., 2024.).

Ova tehnologija nadzire i pranje i dezinfekciju strojeva. Senzori integrirani u CIP sustave (Clean-in-Place) prate protok vode, koncentraciju kemijskih sredstava za dezinfekciju i temperaturu tijekom pranja te odmah signaliziraju ako neki dio opreme nije ispravno dezinficiran. Na taj se način sprječava dolazak nove sirovine na neočišćenu liniju. Kontrola se tako mijenja iz naknadne u preventivnu, što predstavlja značajan napredak jer se problemi rješavaju prije nego što se potencijalna šteta nastane (Yu i sur., 2026.).

Automatizacija i robotika u preradi mesa

Fizički rad u preradi mesa iznimno je težak. Radnici obavljaju poslove klanja, rasijecanja trupova u polovice, četvrti odnosno osnovne komade mesa te pakiranja gotovih proizvoda. Ti su zadaci repetitivni, naporni i nerijetko uzorkuju ozljede na radu. Istodobno, u pogonima vlada kroničan nedostatak kvalificirane radne snage, što je industriju

usmjerilo prema automatizaciji (Kim i sur., 2023.). Spoj robotike i umjetne inteligencije promijenio je način rada jer strojevi sada preuzimaju zadatke koji su prije zahtijevali isključivo manualni rad. Starije generacije industrijskih robota mogle su repetitivno izvoditi krute, unaprijed programirane pokrete. Nasuprot tome, suvremeni robotski sustavi koriste senzore i pametne algoritme kako bi identificirali oblik i točan položaj svakog komada mesa. Sustav prilagođava pokrete alata u stvarnom vremenu i samostalno donosi odluke tijekom rada. To je nužno jer se radi s biološkim materijalom; trupovi se razlikuju po obliku i veličini, za razliku od standardiziranih industrijskih dijelova (Lyu i sur., 2025.).

Znanstveni timovi danas osmišljavaju robote za gotovo sve faze u preradi mesa. To obuhvaća rasijecanje trupova, egzenteraciju, odvajanje mesa od kostiju, oblikovanje osnovnih komada mesa, precizno rezanje na porcije i na kraju automatsko slaganje u ambalažu. Mnogi od tih sustava još prolaze testiranja i nisu u širokoj komercijalnoj upotrebi, no brzi napredak računalnog vida, kamera i algoritama dubokog učenja ubrzava njihovu implementaciju u proizvodne pogone (Wang i Li, 2024.). Uvođenje ovih pametnih strojeva donosi jasne prednosti za poslovanje pogona. Roboti ubrzavaju proizvodni proces, obrađuju meso ujednačeno i znatno smanjuju stopu pogrešaka u usporedbi s ljudskim faktorom. Budući da je manipulacija radnika sirovinom smanjena na minimum, smanjuje se i rizik od naknadne mikrobiološke kontaminacije mesa (Talib i sur., 2024.). Istodobno, strojevi preuzimaju ergonomski najzahtjevnije poslove, što rasterećuje radnike i čuva njihovo zdravlje. Zbog tih izravnih praktičnih učinaka robotika je područje u kojemu tehnologija najbrže prelazi iz faze laboratorijskog projekta u komercijalne proizvodne pogone (Sharma i Tharani, 2024.; Sun i sur., 2025.).

Sljedivost i održivost

Potrošačima je danas iznimno važno poznavati podrijetlo hrane koju konzumiraju. S druge strane, proizvođačima i inspekciji potrebni su točni podaci o svim postupcima u lancu opskrbe, od farme do prodajnog mjesta. Ako se pojavi sumnja u ispravnost neke pošiljke, sustav mora odmah reagirati. Učinkovito postavljen sustav sljedivosti omogućuje da se sporna serija identificira u najkraćem roku i povuče s polica prije nego što ugrozi zdravlje potrošača (Hassoun i sur., 2023.). Pametni softver olakšava ovaj posao automatskom integracijom podataka iz različitih izvora, uključujući farme, klaonice, pogone prerade mesa, hladnjače i transportna vozila. Kada se svi ti odvojeni podaci povežu u zajedničku bazu, put svakog pojedinačnog pakiranja mesa može se do detalja rekonstruirati. time je olakšano uočavanje bilo kakve nesukladnosti poput prekida hladnog lanca tijekom transporta. Na taj način inspekcija učinkovitije provodi nadzor, dok potrošači dobivaju vjerodostojan dokaz o sigurnosti hrane (Wolfert i sur., 2017.; Sun i sur., 2025.).

Ova tehnologija pomaže i u boljoj organizaciji transporta i skladištenja. Algoritmi analiziraju povijest prodaje, trenutno stanje zaliha i vremenske uvjete kako bi precizno predvidjeli potražnju mesa na tržištu u predstojećem razdoblju. To omogućuje proizvođačima da preciznije planiraju rad i stvaranje prekomjernih zaliha u skladištima. Rezultat takvog pristupa očituje se u smanjenju količine otpada na kraju lanca opskrbe te u bržoj distribuciji svježih proizvoda do prodajnih mjesta. (Hassoun i sur., 2023.). Uštede na ovom području izravno utječu na očuvanje okoliša. Uzgoj stoke zahtijeva golemu potrošnju vode, hrane i energije, zbog čega svaki otpis proizvoda predstavlja uzaludno utrošene resurse. Bolje planiranje i smanjenje količine otpada u pogonima omogućuju bolju iskoristivost primarne sirovine. Smanjenje proizvodnog otpada prerađivačima donosi veću financijsku učinkovitost, ali ujedno smanjuje ukupni ekološki pritisak cjelokupne industrije (Esmaeily i sur., 2024.).

Buduće perspektive primjene AI u proizvodnji mesa

Razvoj multisenzorskih modula, računalnog vida, IoT jedinica, robotike i računalstva u oblaku potaknut će širenje ovih digitalnih rješenja u narednim godinama. Umjesto izoliranih programskih rješenja za pojedinačne zadatke, industrija se okreće povezanim sustavima. Oni prate cjelokupan lanac opskrbe mesom, od uzgajivača i farmi, preko klaonica i prerade, pa sve do skladištenja, prijevoza i maloprodajnih mjesta. Na taj se način podaci neprekidno skupljaju i analiziraju, što omogućuje donošenje odluka na liniji proizvodnje u stvarnom vremenu (Jeon i sur., 2025.).

Velik iskorak predstavlja uvođenje „digitalnih blizanaca“ (engl. *digital twins*). Riječ je o virtualnim modelima proizvodnih pogona koji služe za

simulaciju različitih scenarija prije implementacije promjena u praksi. Tehnolozi na taj način mogu provjeriti kako promjena hranidbe stoke, uvođenje novih uvjeta u stajama, reorganizacija procesa rasijecanja ili logističke promjene utječu na krajnji proizvod. Sve se analize provode bez zaustavljanja rada u stvarnom pogonu, što olakšava planiranje te smanjuje nepotrebne troškove (Sun i sur., 2025.). Generativni sustavi (engl. *Generative AI*) također se implementiraju u proizvodnim sustavima jer mogu brzo analizirati velike količine tehničke dokumentacije, sastaviti dnevna izvješća, pomoći u tumačenju laboratorijskih nalaza i pripremiti podatke za voditelje proizvodnje (Wafi i sur., 2024.). Ipak, u kontekstu zdravstvene ispravnosti hrane nužan je oprez i stalan nadzor stručnjaka jer ovi modeli mogu generirati netočne ili neprovjerene informacije ako se primjenjuju bez odgovarajuće validacije i testiranja (Idamokoro i sur., 2025.).

Usporedno s time raste potreba za razvojem „objašnjive umjetne inteligencije“ (engl. *Explainable Artificial Intelligence*; XAI). U prehrambenoj industriji nije dovoljno da računalni sustav autonomno generira zaključak, tehnolozi i inspektori moraju imati uvid u podatke i kriterije koje je sustav uzeo u obzir prilikom donošenja odluke. Kada su modeli razumljivi i jasni, to pridonosi većem stupnju povjerenja kod proizvođača, ali i kod regulatornih tijela i potrošača. To ujedno olakšava uvođenje ovih alata u rutinsku kontrolu kvalitete i sigurnosti hrane (Wang i Li, 2024.; Yu i sur., 2026.).

Masovna implementacija ovih digitalnih rješenja u praksi prvenstveno ovisi o rješavanju ključnih tehničkih pitanja. Potrebno je standardizirati formate podataka kako bi se različitim softverskim platformama omogućila nesmetana komunikacija i pouzdana razmjena informacija. Razvijeni modeli moraju posjedovati visoku razinu robusnosti kako bi stabilno funkcionirali u zahtjevnim vlažnim i hladnim uvjetima klaoničkih pogona, a prije integracije u sustav moraju proći neovisne validacijske provjere. Uz naprednu opremu, industrija zahtijeva i visoko obrazovane kadrove koji razumiju arhitekturu ovih programa te posjeduju znanja za ispravnu interpretaciju generiranih podataka (Hassoun i sur., 2023.; Alvarez-Garcis, 2024.).

Suvremena tehnologija neće zamijeniti tehnologe i stručne kadrove u mesnoj industriji, nego će im poslužiti kao koristan alat za učinkovitije upravljanje procesima i smanjenje operativnih pogrešaka. Povezivanjem praktičnog ljudskog iskustva i naprednih digitalnih rješenja moguće je oblikovati sustave koji optimiziraju potrošnju resursa, jamče visoku razinu sigurnosti hrane te pokazuju visoku stopu prilagodljivosti dinamičnim promjenama na tržištu (Dhal i Kar, 2025., Esmaeily i sur., 2024.).

Zaključak

Digitalni sustavi postupno mijenjaju način rada u mesnom sektoru. Dosadašnji rezultati u praksi potvrđuju da ova tehnologija pomaže u ujednačavanju procjene kvalitete, štiti zdravstvenu ispravnost hrane, ubrzava najzahtjevnije procese na proizvodnim linijama te olakšava praćenje proizvoda kroz cjelokupni lanac opskrbe. Metode poput računalnog vida, dubokog učenja i robotike generiraju objektivne podatke u stvarnom vremenu, čime se smanjuje utjecaj umora ili subjektivnog faktora u proizvodnom pogonu.

Masovna implementacija ovih rješenja ipak zahtijeva ekonomski pristupačniju opremu, standardizaciju formata podataka i osiguravanje softverske interoperabilnosti između različitih proizvođača. Također, razvijeni modeli moraju biti transparentni i provjerljivi kako bi tehnolozi u pogonima mogli u potpunosti evaluirati računalne proračune te donositi odluke bez sumnje u njihovu ispravnost.

Strojevi i algoritmi neće zamijeniti ljudski faktor. Oni služe isključivo kao pouzdana podrška tehnolozima i operaterima, pomažući im da smanje količinu proizvedenog otpada, učinkovitije kontroliraju kvalitetu te potrošačima osiguraju sigurne i ujednačene proizvode.

References

[1] **Alvarez-García, W.Y. (2024):** Implementing artificial intelligence to measure meat quality parameters in local market traceability processes. Int J Food Sci Technol.; 59(11), 8058-8068. doi.org/10.1111/ijfs.17546.

[2] **Baltić, M.Z., M. Bošković (2015):** When man met meat: meat in human nutrition from ancient times till today. Proc Food Sci. 5:6–9. doi: https://doi.org/10.1016/j.profoo.2015.09.002.

[3] **Dhal S.B., D. Kar (2025):** Leveraging artificial intelligence and advanced food processing techniques for enhanced food safety, quality, and security: A comprehensive review. Discov Appl Sci. 7:75. doi: 10.1007/s42452-025-06472-w.

[4] **Esmaeily, R., M.A. Razavi, S.H. Razavi (2024):** A step forward in food science, technology and industry using artificial intelligence. Trends Food Sci Technol.143,104286. doi:10.1016/j.tifs.104286.

[5] **Hassoun, A., S. Jagtap, G. Garcia-Garcia, H. Trollman, M. Pateiro, J.M.Lorenzo, M. Trif, A. Vasile Rusu , R.Muhammad Aadil, V. Šimat, J. Cropotova, J.S. Câmara (2023):** Food Quality 4.0: From traditional approaches to digitalized automated analysis. J Food Eng. 337, 111216. doi:10.1016/j.jfoodeng.2022.111216

[6] **Hwang, Y.H., M.Z. Alam, O.P. Malav, M.A. Hossain, M. Rebezov (2025):** A Comprehensive Review of Artificial Intelligence (AI)-Driven Approaches to Meat Quality and Safety. Food Sci Anim Resour. 45(4), 998-1013. doi:10.5851/kosfa.2025.e32.

[7] **Idamokoro, E.M. (2025):** AI-Driven Innovations in Meat Quality and Safety: Applications, Challenges, and Future Directions. Am J Biochem Biotechnol. 21(3):420-427. doi:10.3844/ajbbsp.2025.420.427.

[8] **Jeon,g K., G. Jo, J.H. Lee, Y.H.B. Kim, J. Choi, H. Oh, J. Jeong, E. Leee (2025):** Artificial Intelligence in Meat Processing: A Comprehensive Review of Data-Driven Applications and Future Directions. Meat Muscle Biol. 9(1),20157. doi:10.22175/mmb.20157.

[9] **Kamilaris, A., F.X. Prenafeta-Boldú (2018):** Deep learning in agriculture: A survey. Comput Electron Agric.147,70-90. doi:10.1016/j.compag.2018.02.016.

[10] **Kim, J., Y.K. Kwon, H.W. Kim, K.H. Seol, B.K. Cho (2023):** Robot technology for pork and beef meat slaughtering process: a review. Animals. 13:651. doi: https://doi.org/10.3390/ani13040651.

[11] **Liakos, K.G., P. Busato, D. Moshou, S.Pearson, D. Bochtis (2018):** Machine Learning in Agriculture: A Review. Sensors.18(8), 2674. doi:10.3390/s18082674.

[12] **Lyu, Y., F. Wu, Q. Wang, G. Liu, Y. Zhang, H. Jiang, M. Zhou (2025):** A review of robotic and automated systems in meat processing. Front Robot AI. 12,1578318. doi:10.3389/frobt.2025.1578318.

[13] **Sharma S., L.Tharani (2024.):** Optical sensing for real-time detection of food-borne pathogens in fresh produce using machine learning. Sci Prog. 107:368504231223029. doi: 10.1177/00368504231223029.

[14] **Sun, Q., Y. Yuan, B. Xu, S. Gao, X. Zhai, F. Xu, J. Shi (2025):** Innovative Technologies Reshaping Meat Industrialization: Challenges and Opportunities in the Intelligent Era. Foods 14(13),2230. doi:10.3390/foods14132230.

[15] **Talib A, A. Samad, M.J. Hossain, A. Muazzam, B. Anwar, R. Atique, Y.H. Hwang, S.T. Joo (2024.):** Modern trends and techniques for food preservation. Food Life. 2024:19–32. doi: 10.5851/fl.2024.e6.

[16] **Wang, M., X. Li (2024):** Application of artificial intelligence techniques in meat processing: A review. J Food Process Eng. 47:e14590. doi:10.1111/jfpe.14590.

[17] **Wafi M.A.A., M.A. Tumiran (2024.):** Harnessing artificial intelligence (AI) to mitigate food waste: Innovative strategies for sustainable consumption. Malays J Soc Sci Hum. 9:e003147. doi: 10.47405/mjssh.v9i12.3147.

[18] **Wolfert, S., L. Ge, Verdouw, M.J. Bogaardt (2017):** Big Data in Smart Farming: A review. Agric Syst.153, 69-80. doi:10.1016/j.agsy..01.023.

[19] **Yu F., D, Zhang, J. Zhang, W. Wang, J. Cheng, C. Zhang (2026):** Artificial intelligence driven meat preservation technology: research progress, challenges, and future directions. Food Qual Saf. 10:fyaf083. doi:10.1093/fqsafe/fyaf083.

Dostavljeno/Received: 10.06.2026. **Prihvaćeno/Accepted: 10.07.2026.**

Artificial Intelligence in Meat Production - Applications, Challenges and Future Directions

Abstract

Computer systems are increasingly being introduced and used in the meat industry to speed up operations, standardize product quality, ensure food safety, and facilitate the tracking of raw materials with minimal waste. Modern plants use machine learning and deep learning algorithms, computer vision, robotics, and predictive models to utilize the large amounts of data collected daily by cameras and sen-

sors on production lines. This technology offers solutions to concrete problems in the meat sector. Due to the significant natural differences between animals, challenging working conditions in slaughterhouses, and strict hygiene regulations, the human eye and manual assessment are no longer sufficient for high precision. Modern programs and algorithms no longer focus solely on recognizing and classifying individual pieces of meat or products but rather predict the course of the entire production process, automatically collect data, and aid in adjusting work in real-time. However, the spread of this technology is still limited by factors such as the quality of available data in the field, problems with connecting software from different manufacturers, the high cost of equipment, and the need for models that employees and experts can easily understand and verify. This review provides insight into the application of artificial intelligence in the meat sector and analyzes its advantages, challenges, and future development directions.

Keywords: artificial intelligence; meat industry; machine learning; meat quality assessment; food safety; sustainable production

Künstliche Intelligenz in der Fleischproduktion - Anwendungen, Herausforderungen und Entwicklungsrichtungen

Zusammenfassung

In der Fleischindustrie werden zunehmend Computersysteme eingeführt und eingesetzt, um den Betriebsablauf zu beschleunigen, die Produktqualität zu standardisieren, die Lebensmittelsicherheit zu gewährleisten und die Rückverfolgbarkeit von Rohstoffen bei minimalem Ausschuss zu erleichtern. Moderne Betriebe nutzen Algorithmen des maschinellen Lernens und des Deep Learning, Computer Vision, Robotik und Vorhersagemodelle, um die riesigen Datenmengen zu verwerten, die täglich von Kameras und Sensoren an den Produktionslinien erfasst werden. Diese Technologie bietet Lösungen für spezifische Probleme im Fleischsektor. Aufgrund der großen natürlichen Schwankungen bei den Tieren, der schwierigen Arbeitsbedingungen in Schlachthöfen und strenger Hygienevorschriften reichen das menschliche Auge und die manuelle Begutachtung für eine hohe Präzision nicht mehr aus. Moderne Programme und Algorithmen befassen sich nicht mehr nur mit der einfachen Erkennung und Sortierung einzelner Fleischstücke oder Produkte, sondern prognostizieren auch den gesamten Produktionsprozess, erfassen automatisch Daten und helfen dabei, den Betrieb in Echtzeit anzupassen. Die Verbreitung dieser Technologie wird jedoch nach wie vor durch Faktoren wie die Qualität der vor Ort verfügbaren Daten, Probleme bei der Anbindung von Software verschiedener Hersteller, die hohen Kosten für die Ausrüstung sowie den Bedarf an Modellen eingeschränkt, die für Mitarbeiter und Experten leicht verständlich und überprüfbar sind. Dieser Überblick bietet einen Einblick in die Anwendung künstlicher Intelligenz in der Fleischbranche und analysiert deren Vorteile, Herausforderungen und zukünftige Entwicklungsrichtungen.

Schlüsselwörter: künstliche Intelligenz; Fleischindustrie; maschinelles Lernen; Fleischqualitätsbewertung; Lebensmittelsicherheit; nachhaltige Produktion

Inteligencia artificial en la producción de carne - aplicaciones, desafíos y perspectivas de desarrollo

Resumen

En la industria cárnica se introducen y utilizan cada vez con mayor frecuencia sistemas informáticos con el fin de agilizar las operaciones en las plantas de producción, homogeneizar la calidad de los productos, garantizar la seguridad alimentaria y facilitar la trazabilidad de las materias primas, mi-

nimizando al mismo tiempo la generación de residuos. Las plantas de producción modernas utilizan algoritmos de aprendizaje automático y aprendizaje profundo, visión artificial, robótica y modelos predictivos para aprovechar las grandes cantidades de datos que recopilan diariamente mediante cámaras y sensores instalados en las líneas de producción. Esta tecnología ofrece soluciones para problemas concretos del sector cárnico. Debido a la gran variabilidad natural entre los animales, a las exigentes condiciones de trabajo en los mataderos y a los estrictos requisitos higiénicos, la inspección visual y la evaluación manual ya no son suficientes para alcanzar un elevado nivel de precisión. Los sistemas y algoritmos modernos ya no se limitan al reconocimiento y la clasificación de piezas individuales de carne o de productos cárnicos, sino que también permiten predecir el desarrollo de todo el proceso productivo, recopilar datos de forma automatizada y contribuir a la adaptación de las operaciones en tiempo real. No obstante, la expansión de estas tecnologías sigue estando limitada por factores como la calidad de los datos disponibles en las condiciones reales de producción, las dificultades para integrar programas informáticos de diferentes fabricantes, el elevado coste de los equipos y la necesidad de desarrollar modelos que puedan ser fácilmente interpretados y verificados por los empleados y los profesionales del sector. Esta revisión ofrece una visión general de las aplicaciones de la inteligencia artificial en el sector cárnico y analiza sus ventajas, desafíos y perspectivas de desarrollo futuro.

Palabras claves: inteligencia artificial; industria cárnica; aprendizaje automático; evaluación de la calidad de la carne; seguridad alimentaria; producción sostenible

Intelligenza artificiale nella produzione della carne – applicazioni, sfide e prospettive di sviluppo

Riassunto

Nell'industria della carne vengono introdotti e utilizzati con sempre maggiore frequenza sistemi informatici allo scopo di velocizzare le attività negli stabilimenti, uniformare la qualità dei prodotti, garantire la sicurezza degli alimenti e facilitare la tracciabilità delle materie prime, riducendo al minimo gli scarti. Gli stabilimenti moderni utilizzano algoritmi di apprendimento automatico e profondo, visione artificiale, robotica e modelli predittivi per sfruttare le grandi quantità di dati raccolte quotidianamente mediante telecamere e sensori installati sulle linee di produzione. Questa tecnologia offre soluzioni a problemi concreti del settore della carne. A causa delle notevoli differenze naturali tra gli animali, delle difficili condizioni di lavoro nei macelli e delle rigorose norme igieniche, l'occhio umano e la valutazione manuale non sono più sufficienti per garantire un'elevata precisione. I moderni programmi e algoritmi non si occupano più soltanto del semplice riconoscimento e della classificazione dei singoli tagli di carne o prodotti, ma prevedono l'andamento dell'intero processo produttivo, raccolgono automaticamente i dati e contribuiscono all'adeguamento delle operazioni in tempo reale. Tuttavia, la diffusione di questa tecnologia è tuttora limitata da fattori quali la qualità dei dati disponibili sul campo, i problemi di integrazione tra software di diversi produttori, l'elevato costo delle attrezzature e la necessità di disporre di modelli che possano essere facilmente compresi e verificati dagli operatori e dagli esperti. La presente rassegna offre una panoramica dell'applicazione dell'intelligenza artificiale nel settore della carne e ne analizza i vantaggi, le sfide e le future direttrici di sviluppo.

Parole chiave: intelligenza artificiale; industria della carne; apprendimento automatico; valutazione della qualità della carne; sicurezza alimentare; produzione sostenibile