

A mesterséges intelligencia alkalmazási lehetőségei az élelmiszerlánc-biztonság területén

Józwiak Ákos^{1,2} 

¹Állatorvostudományi Egyetem, Élelmiszerlánc-tudományi Intézet, Budapest, Magyarország

²Syreon Kutatóintézet, Budapest, Magyarország

Levelező szerző, e-mail: akos.jozwiak@syreon.eu

Beérkezett: 2025. április 30.; elfogadva: 2025. június 24.

Összefoglalás

A termőföldtől az asztalig jelentkező, a klímaváltozás, a globalizáció és a fogyasztói trendek által felerősített kockázatok közepette a mesterséges intelligencia (MI) az élelmiszerlánc proaktív védelmi rendszerévé válhat. A fejlett analitikai, gépi tanulási és nagy nyelvi modelleken alapuló megoldások – az IoT-szenzorokkal támogatott valós idejű üzemfelügyelettől a műholdas mikotoxin-előrejelzésen át az MI-asszisztált kockázatértékelési keretekig – gyorsabb, pontosabb döntéseket tesznek lehetővé. Azonban az MI sikerének feltételei is vannak: a FAIR-alapú, ontológiákkal összekapcsolt adat-ökoszisztéma, a biztonságos adatmegosztás, a magyarázható MI-modellek, a szakértői „human-in-the-loop” felügyelet, valamint az AI-rendelettel összhangban álló átlátható és elszámoltatható irányítási, felügyeleti rendszerek. A következő évtizedben az interoperabilitás fokozása, a live evidence mapping, a biztonságos adatmegosztási eljárások elterjedése, valamint a célzott oktatás és kapacitásfejlesztés teremthetik meg azt a bizalmi és technológiai alapot, amely mellett az MI valós időben előzheti meg az élelmiszer-eredetű egészségkárosodásokat, és hozzájárulhat a fenntarthatóbb, ellenállóbb élelmiszerrendszerekhez.

Kulcsszavak: élelmiszerlánc, élelmiszerlánc-biztonság, mesterséges intelligencia, adattudomány

Application possibilities of Artificial Intelligence in food chain safety

Ákos Józwiak^{1,2}

¹University of Veterinary Medicine, Institute of Food Chain Science, Budapest, Hungary

²Syreon Research Institute, Budapest, Hungary

Summary

Globalized trade, climate volatility and fast-evolving consumer expectations have multiplied the biological, chemical and physical hazards that can emerge “from farm to fork”. While the IoT devices, omics platforms and satellite sensors now generate petabytes of potentially informative data, almost three-quarters of these signals remain unstructured, siloed or simply missing, creating blind spots in conventional risk-assessment and risk-management pipelines. This paper analyses how Artificial Intelligence (AI) can transform that paradox – data overload versus insight scarcity – into a proactive assessment and management system for food-chain safety, through demonstrating AI-application use-cases, prerequisites and governance challenges. Evidence shows that advanced analytics, machine-learning and large language models can be useful in various predictive and decision-making scenarios, but the success of these innovations is gated by many prerequisites and factors. Data readiness – FAIR-compliant, high quality interoperable datasets that also capture the currently missing data – is a key area burdened with many challenges which need significant improvement. Even more important is people readiness – cross-trained food scientists and data scientists are necessary to maintain effective “human-in-the-loop” systems: human expert validation and oversight are crucial at every stage of engaging with AI – at the beginning (when defining objectives, scope, framework and selecting AI tools), during the process (to validate interim results and assure quality), and at the end (to interpret the findings and place them in their proper context). Trust and governance are also crucial enablers: GDPR-aligned pseudonymisation, federated learning for sensitive business or epidemiological data, clearly defined responsibilities, in line with the

EU data and AI regulatory environment, are all important factors to consider. In addition, transparent model documentation and explainable AI solutions are needed to foster stakeholder confidence and facilitate regulatory audits. Achieving the long-term AI vision will require targeted investments in data generation, open semantic standards, capacity-building curricula and continuous algorithmic audits, supported by multi-country “lighthouse” pilots that demonstrate tangible public-health value. If these align, AI will not replace expert risk assessors; it will amplify their reach, turning today’s reaction-based controls into tomorrow’s anticipatory, evidence-centred food safety governance.

Keywords: food chain, food chain safety, artificial intelligence, data science

Bevezets

Az elmlt vtizedben a globlis kereskedelem felgyorsulsa, a klmavltozs egyre szlssesebb hatsai, az e-kereskedelem robbansszer nekedse s a fogyasztk vals idej tjkozdsi gnye egytt olyan sszetett kockzati mtrixot hoztak ltre, amellyel a hagyomnyos mdszerek mr nem tudnak lpst tartani. Az lelmiszer-biztonsgi dntsek gyorssa s megalapozottsga egyre nagyobb mrtkben fgg attl, kpes-e a kzssg „adatrett” krnyezetet teremteni a mestersges intelligencia (MI) szmra (EFSA 2025).

A kihvsok a termfldtl az asztalig vgig jelen vannak: a mezgazdasgot rint vz- s hstressz j toxin-termel gombafajok megjelenst segti el; a globlis elltsi lncokban  a csals s a szndkos szennyezs kockzata; a krforgss gazdasg s az j fehrjeforrsok – pldul a rovaralap termek – pedig ismeretlen veszlyprofilokat hoznak magukkal. Mikzben az IoT-szenzorok, a genomikai platformok s a kereskedelmi nyomon kvetsi megoldsok soha nem ltott adattmetet generlnak, az informcik kzel 75 szzalka rendezetlen vagy nem integrlhat, gy a kockzatelemzs folyamataiban vakfoltok keletkeznek (Jzwiak 2024).

Ezt az adatparadoxont hivatott feloldani a mestersges intelligencia (MI), amely a heterogn forrsokbl szrmaz jelekben is mintzatot talál, elrejelzseket kszt, s kpes vals idej riasztsokat adni. Az EFSA Adattgyi Tancsad Csoportja (Advisory Group on Data) szerint a kvetekz vekben az MI hrom stratgiai terleten hozhat ttrst: (1) a kockzatbecslsi modellek hibrid – mechanisztikus s gpi tanulson alapul – integrlsban; (2) a „live evidence mapping” mdszertan bevezetsvel, amely folyamatosan frissl, gppel olvashat tudstrkepeket knl; valamint (3) a szablyozi, kockzatrtkelsi, kockzatkezelsi munkafolyamatok automatizlsban, ahol az MI segti az ellenrk erforrs-optimalizlst (EFSA et al. 2024; EFSA et al. 2025).

Az MI bevezetse ugyanakkor j tpus kockzatokat s felsznre hoz. A torz vagy hinyz adatok fltrevezet modelleket eredmnyezhetnek; az tlthatatlan, fekete-doboz-szer algoritmusok megneheztik az ellenrzsi, felgyeleti tlthatsgot; az tikai s jogi megfelels pedig kln szakrtelmet gnyel. Az MI csak akkor hozhat vald ttrst, ha a humn szakrti felgyeletet nem kiktatja, hanem felersti, integrlja az egyes folyama-

tokba, s ha a dntshozk magas szint adattudomnyi mveltsggel rendelkeznek (EFRA 2024).

Mindezek fnyben az elttnk ll vtizedben a demogrfia nyoms, a fenntarthatsgi tlls s az elltsi hlzatok digitalizcija nem csupn tbb adatot, hanem jobb minsg, szabnyostott s FAIR-mdon menedzselte adatot gnyel. Ebben a krnyezetben az MI nem pusztn gyorst eszkz: megfelel rnyts mellett az lelmiszer-biztonsg tfog, proaktv vdelmi rendszerv vlhat, amely kpes a fenntarthat fejldsi clkitzsek (lsd *United Nations 2015*) kzelsre anlkl, hogy kzben elvesztennk a trsadalmi bizalmat s a tudomnyos megalapozottsgot.

Az MI alkalmazsi lehetsgei

A fejlett analitika, a gpi tanulas (machine learning, ML) s a legjabb nagy nyelvi modellek (large language models, LLM) kpesek a heterogn adathalmazok vals idej elemzsre, rejtett mintzatok feltrsra s az lelmiszerlnc kritikus kockzatainak proaktv elrejelzsre. Az MI alkalmazsi lehetsgei nagyon sokrtek; az albbiakban jellemz pldk, alkalmazsi esetek kerlnak kifejtsre.

Vals idej zemfelgyelet. A gyrtsorokba ptett IoT-szenzorhlzatok adatait (hmrsklet, pratartalom stb.) ML-algoritmusokkal elemezve 1–2 C-os hmrsklet-ingadozsbl s gzprofil-eltrsbl elre lehet jelezni a *Listeria monocytogenes* exponencilis szaporodsnak eslyt, gy a htlnc mg a hatrrtkek tlpse eltt korriglhat (Gmeiner et al. 2025).

Tvrzkels a mezgazdasgban. Mholdas NDVI-index, radaros talajnedvessg-adatok s nagy felbonts meteorolgiai gridadatok sszeillesztsvel a mikotoxin-kockzati znk 44 kilomteres felbontsban, akr hat httel a betakarts eltt trkepezhetk (Dimitrakopoulou et al. 2025).

Szntetikus adatok az lelmiszer-hitelessgben. A kaktuszmagolaj hamistsnak kiszrsre Monte-Carlo s CT-GAN mdszerrel generlt szntetikus adatok szlgltak tanulhalmazknt. A Random Forest modell 0,95-s pontossggal ismerte fel a napraforgolaj-adalkot, mikzben feltrta az -tokoferol kulcsszerept markervegyletknt (El Harkaoui 2025).

Genomsznt kockzatelemzs. Teljes genom szekvencikbl (WGS) tanulo ML-eszkzk kpesek 1500 kr-



1. ábra Szervezetek MI-felkészültségének előfeltételei. A szürkével jelöltek a szerző kiemelései; jelen cikkben ezek kerülnek részletesebb ismertetésre.
 Forrás: Jöhnk et al. 2021 nyomán

nyezeti, szocioökonómiai és klinikai driver integrálására, ezáltal országos szinten előre jelezhetik az antimikrobiális rezisztencia (AMR) trendjeit (Njage et al. 2023).

Metabolomika-vezérelt korai riasztások. Az ISPA CNR labor nem célzott LC-HRMS spektrumait deep-learning algoritmus klaszteresíti, és percek alatt kiemeli a gabona-fuzárium-fertőzésre utaló jellegzetes metabolitmintázatot, hetekkel a mikotoxin-képződés előtt (EFRA 2024).

Kockázattértékelés. A kémiai anyagok fejlesztése és piaci bevezetésük üteme messze meghaladja a tesztelési kapacitásokat, ami jelentős adathiányt eredményez a lehetséges kockázatokkal illetően. Az MI eszközei segíthetnek ennek a problémának a kezelésében, például a toxikológiai kockázatok előzetes, adatalapú és szimulációs becslésével már a fejlesztési folyamat elején, kiváltva ezzel a költséges és időigényes állatkísérleteket. Az MI kulcsszerepet játszhat a gyorsabb, pontosabb és átfogóbb kockázattértékelésben, és ezáltal hozzájárul a biztonságosabb és hatékonyabb termékek fejlesztéséhez (Krewski et al. 2020).

A fenti példákkal is demonstrálható, hogy fejlett ML-megoldások bevezetésével az élelmiszerlánc felügyelete a reaktív hibaelhárításról áttérhet a megelőző, dinamikus kockázatkezelésre, amely egyszerre támogatja a közegészségügy védelmét és a vállalkozások versenyképességét.

Evidenciaszintézis

Minden tudományterület alapja a megbízható evidenciák szisztematikusan feltárása és rendszerezése. Az MI-alapú természetesnyelv-feldolgozás (NLP) és a nagy nyelvi modellek (LLM) ma már nem csupán a publikációk kulcsszavas keresését támogatják: képesek end-to-end szisztematikus irodalomkutatást végezni, amely magában foglalja a deduplikálást, a relevanciaszűrést (active learning), az adatok automatikus kinyerését, sőt a bizonytalansági metrikák hozzárendelését is (EFSA 2025). Az élelmiszer-tudomány területén szintén egyre több élelmiszer-specifikus NLP- és LLM-fejlesztés zajlik (Popovski et al. 2019; Hooton et al. 2020; Ispirova et al. 2022).

Az említett modellek ereje akkor bontakozik ki igazán, ha élő adatfolyamokra – pre-print és publikációs

szerverekre, hatósági riasztásokra, közösségi médiára – kapcsoljuk őket: a „live evidence mapping” révén valós időben frissülő tudástérképek jönnek létre, amelyek vizuálisan mutatják meg, hogy egy adott veszélyhez (pl. új mikotoxin-analógok) hol keletkezik a bizonyíték, és hol vannak fehér foltok (Wolffe et al. 2019). Az EFSA Advisory Group on Data ajánlasként fogalmazza meg a live evidence adatbázisok kifejlesztését a jövőbeni kockázatbecslési dossziékban (EFSA et al. 2025).

Az MI-asszisztált evidenciaszintézis radikálisan rövidebb időt vesz igénybe – hetek helyett napokat –, és heterogén források egy felületen történő összevezetését teszi lehetővé. Azonban ezt jelenleg mindenképpen csak magas szintű MI- és doménszakértői felügyelettel lehet végezni. Ha ezek a feltételek teljesülnek, az evidenciaszintézis proaktív, valós idejű tudáshálózattá válhat, amely a kockázatok változását vagy új kockázatok megjelenését még megjelenésük előtt jelzi a döntéshozóknak.

Előfeltételek

Ahhoz, hogy az MI be tudja váltani a szakma által megfogalmazott és elvárt ígéreteket, számtalan előfeltételnek és szempontnak kell teljesülnie. Az MI-felkészültség feltételeinek sokfajta csoportosítása létezik; az 1. ábra egyfajta megközelítést kínál. A többfajta előfeltétel közül jelen cikkben az adatokra és a tudásra vonatkozók kerülnek részletesebben kifejtésre.

Adatok (data readiness)

Az MI-megoldások bevezetésének első számú feltétele, hogy az élelmiszerlánc minden pontján keletkező adatokat a FAIR-elvek (findable, accessible, interoperable, reusable) szerint kezeljük (Wilkinson et al. 2016). A gyakorlat azonban messze elmarad az elmélettől: a világon rendelkezésre álló élelmiszer-biztonsági adatok mintegy 75 százaléka rendezetlen, a hiányzó vagy nem publikált eredmények pedig – például a negatív laborvizsgálatok, a kis- és középvállalkozások önellenőrzési adatai vagy a hatósági minták „nem detektáltak” sora – szisztematikus torzulást visznek a gépi tanuló modellekbe. Ezek miatt a torzulások miatt a predikciók túl- vagy alulbecsülhetik a valós kockázatot, ami végső soron a fogyasztók biztonságát veszélyezteti.

ságát és a vállalkozások versenyképességét egyaránt veszélyezteti (Józwiak 2024).

Az adatok MI-fejlesztésre való készülségét több, egymással összefüggő dimenzióban kell javítani.

Adatok rendelkezésre állása. Az első és talán legfontosabb probléma, hogy nagyon sok területen egyszerűen nem állnak rendelkezésre megfelelő adatok. Vannak olyan, az élelmiszer- és táplálkozástudományi területen kulcsfontosságú területek, amelyeket a tudományterület még nem tárt fel; például az élelmiszerek molekuláris szintű összetevőiről nagyon kevés információval rendelkezünk (Barabási et al. 2020). Ezzel párhuzamosan – ipari kontextusban vizsgálva a kérdést – megállapítható, hogy bár az adat-boom korában élünk, a legtöbb ipari szereplőre jellemző a folyamat alapú gondolkodás hiánya, és ezzel párhuzamosan nem vagy csak szigetszerűen gyűjtenek adatokat saját termelési környezetükről. Ezen az adatokon nem kivitelezhető az MI-modellek fejlesztése, de még egyszerűbb adatelemzések sem végezhetők.

Minőség és megfelelés. A begyűjtött információknak – az adatminőség konvencionális dimenziói alapján – pontosnak, teljesnek, konzisztensek, érvényesnek, időben naprakésznek és egyedinek kell lenniük (European Commission 2019). Ezek bármelyikének hiánya torzítja az eredményeket, és alapvetően gátolja az MI-modell fejlesztését, márpedig ezek nagyon gyakori problémák az élelmiszerlánc minden szereplőjénél.

Mennyiség és reprezentativitás. A nagy mélységű (granularitású) adatkészletek ellenére gyakori, hogy maga a mintavétel nem reprezentatív (pl. kockázatalapú vagy környelmi jellegű mintavétel), ami statisztikailag torz becsléseket eredményez (pl. állatgyógyászati szermaradékok mintavétele).

Szabványosítás és interoperabilitás. Jelenleg az eltérő ontológiák, terminológiák és adatkatalógusok okozzák a legtöbb gyakorlati problémát az adatelemzés és az MI számára. Például az Európai Unió élelmiszer- és takarmány-gyorsriasztási rendszere, a RASFF saját élelmiszer-klasszifikációt használ, amely nincs összhangban az EFSA FoodEx2 kategorizálásával, így egy több országra kiterjedő élelmiszerlánc-esemény gyors kockázatértékelése legtöbbször késedelmet szenved az ebből következő adattisztítási lépések miatt (EFSA et al. 2020). Az interoperabilitás az egyik legfontosabb kihívás az MI alkalmazásában. Az eltérő forrásból származó adatok még nem – vagy csak nehezen – kapcsolhatók össze automatikusan, pedig a gépi olvashatóság és az ontológia alapú tudásgráfok lennének az MI-alapú kockázatértékelés motorjai. Az ipari és kutatói közösségekben már elterjedt ontológiák és taxonómiák konvergenciája sürgető feladat.

Ontológia- és tudásbázis-építés. Bár ez az interoperabilitási problémakör része, mégis érdemes külön megemlékezni az ontológiák fontosságáról. Az ontológia egy formális, géppel olvasható tudásreprezentáció, amely egy szakterület fontos fogalmait (entitásait), ezek tulajdonsá-

gait és a köztük lévő kapcsolatokat írja le egységes, szabványos szerkezetben. Az ontológiák célja, hogy az adatokat könnyebben megtalálhatóvá, összekapcsolhatóvá és újrahasznosíthatóvá tegyék – így hatékonyan támogatják az interoperabilitást és a tudásmegosztást az élelmiszerlánc biztonságától a gyógyszer- vagy környezetvédelemig (EFSA 2025). Géppel olvasható, szemantikus modellek nélkül nem valósítható meg az automatizált evidenciakivonatolás és a multimodális kockázatimodell-építés, de ezek az ontológiák sok területen hiányoznak vagy hiányosak: például az állatbetegségeknek nincs formális, nemzetközileg elfogadott ontológiája (Józwiak 2024).

Adatmegosztási ösztönzők és védelem. A vállalati és hatósági adatvagyonok érzékeny részeinek (cégnevek, receptúrák, beszállítói listák, részletes műszaki, minőségi vagy biztonsági paraméterek) nyilvánosságra kerülése kockázatot jelent, ezért a kölcsönös adatmegosztás nem túl gyakori az élelmiszerláncban. A bizalmas adattartalmú fájlok megosztását jogi-technikai garanciákkal (szegmentált felhőtárhely, kvázi-anonimizálás, federated learning stb.) kell ösztönözni úgy, hogy közben a közösségi (közegészségügyi, állategészségügyi stb.) érdek is érvényesüljön (EFRA 2024).

Tudás – az emberi tényező (people readiness)

Az adatok készülsége mellett az emberek felkészülsége – vagyis a humán erőforrás, a multidiszciplináris szemlélet és az adattudományi kompetenciák – legalább ilyen kritikus. A big data és az MI nem csupán IT-probléma: a döntések értelmezéséhez az élelmiszerlánc-tudomány, a statisztika, az adattudomány, az MI és a szabályozási ismeretek integrált tudása szükséges (EFSA 2025).

Jelenleg a kockázatértékelési képzések túlnyomórészt alap statisztikai modulokra korlátozódnak, míg a data science, a Python/R vagy a gépi tanulási workflow-k ritkán szerepelnek a tantervben. A 2024-es EFSA Data Readiness szimpózium résztvevői rámutattak: az MI-projektek leglassabb része nem a kód, hanem a belső szakértők adat- és modellismeretének hiánya (EFSA 2025). Az MI-modellek valós bevezetésének előfeltétele a transzparens, magyarázható algoritmus és az ezek értelmezésére képes személyzet. Az AI Act-kompatibilis governance-képzés, a magyarázhatóság és a „human-in-the-loop” felügyelet nélkül könnyen bizalmi válság alakulhat ki ezen a területen (EFSA 2025).

Átláthatóság és magyarázhatóság. Magyarázható MI (explainable AI – XAI) alatt azokat a módszereket és technikákat értjük, amelyek feltárják a hagyományosan „fekete doboz” jellegű MI-modellek belső működését, és az emberek számára értelmezhető magyarázatot adnak arra, hogy egy adott bemenetből milyen logika mentén, milyen tényezők súlyozásával született a kimenet (Longo et al. 2024). XAI nélkül az élelmiszeripari szereplők és a hatóságok nem fogadják el a gépi ajánlásokat, ezért szabványos XAI-keretekre és konzisztens módsze-

rekre van szükség, különben ugyanarra a modellre különböző magyarázatok születhetnek, ami aláássa a bizalmat (EFRA 2024).

Etikai, jogi és társadalmi vonatkozások. A közegészségügyben alkalmazott MI-modellek etikailag érzékeny adatokat kezelnek, így ezek alkalmazása során adat- és jogbiztonsági „védőkörlátokra” van szükség: federatív tanulási, adatminimalizálási vagy pszeudonimizálási módszerek alkalmazása javasolt (*privacy-preserving AI*). Az AI-rendelet (2024/1689/EU *rendelet*) kockázatalapú megközelítése kötelező előírásokat tartalmaz: például a „magas kockázatú” élelmiszer-biztonsági MI-rendszerek csak úgy hozhatók forgalomba, ha auditálható adat- és modell-governance, folyamatos emberi felügyelet, valamint átlátható magyarázati kimenetek állnak mögöttük. A bizalomépítés kulcsa a GDPR-kompatibilis adatkezelés, a magyarázhatóság, valamint az a hibrid működés, amelyben az MI kiegészíti – nem pedig helyettesíti – az emberi szakértelmet.

Diszkusszió

Összefoglalva, az MI csak annyira lesz „okos”, amennyire az őt kiszolgáló adat- és metaadat-ökoszisztéma gazdag, reprezentatív, számítógép- és MI-barát és biztonságosan megosztható. A FAIR-alapú, ontológiákkal összekapcsolt adat-ökoszisztéma, a biztonságos adatmegosztás, a magyarázható MI-modellek, valamint a szakértői „human-in-the-loop” felügyelet együtt alkotják azt a támaszt, amely nélkül az MI-modellek torzítanak, áttekinthetetlenül válnak, vagy éppen etikai-jogi falakba ütköznek. Az emberi validálás és felügyelet kiemelten fontos a kutatás elején (a célok és a keretek meghatározása, MI-eszközök kiválasztása), a folyamat közben (köztes eredmények validálása, minőségbiztosítása) és a folyamat végén (az eredmények értelmezése és kontextusba illesztése).

Fontos hangsúlyozni, hogy az MI nem csodaszer, de nem is csak arról szól, hogy gyorsabbá vagy pontosabbá tegye az elemzéseket. Az MI már jelenlegi fejlettségi szintjén is alkalmas arra, hogy teljesen átalakítsa az élelmiszer-biztonsági üzleti, szabályozói, kockázatértékelési folyamatokat, és teljesen új, magasabb minőségű megértést – ezáltal biztonságosabb és fenntarthatóbb élelmiszerrendszereket – tegyen lehetővé. Ennek jelenleg nem az MI a korlátja; a lehetőségeknek az adat- és az emberi tényezők szabnak gátat.

Az emberi képességek fejlesztése kulcsfontosságú a sikeres MI-implementációhoz. Az élelmiszer-tudományi, állatorvos-tudományi és agrártudományi tantervekbe be kell építeni az adattudomány, a gépi tanulás és az MI-alapú módszertan alapjainak képzését. Emellett szükség van olyan interdiszciplináris mesterképzési programokra is, amelyek ötvözik az élelmiszerlánc-tudományt a digitális kompetenciákkal. A gyakorló szakemberek számára folyamatos továbbképzési programokat kell indítani, amelyek nemcsak a technikai ismereteket, hanem az MI-

modellek kritikus értékelését és etikai vonatkozásait is lefedik. A „human-in-the-loop” szemlélet elsajátítása különösen fontos, mivel biztosítani kell, hogy a szakértők képesek legyenek felügyelni és validálni az MI-alapú döntéseket (EFSA 2025). Az élelmiszerlánc-hatóság munkatársai és a kockázatértékelők számára specializált képzési modulokra van szükség, amelyek az explainable AI-technikákat, a modellauditálást és a szabályozói megfelelőség értékelését helyezik a középpontba (Thakkar et al. 2023).

Az MI sikeres alkalmazása az élelmiszerlánc-biztonságban jelentős szakpolitikai változtatásokat is igényel. Fontos feladat a harmonizált, EU-szintű interoperabilitási szabályok kidolgozása, amelyek lehetővé teszik a tagállamok közötti zökkenőmentes adatáramlást (2024/1689/EU *rendelet*). A szabályozói környezetet is fel kell készíteni az MI-alapú – vagy MI-asszisztált – döntéshozatalra: egyértelmű irányelvekre van szükség az algoritmikus transzparenciára, az adatvédelemre és az elszámoltathatóságra vonatkozóan. Az AI-rendelet (2024/1689/EU *rendelet*) implementációja során kiemelt figyelmet kell fordítani az élelmiszerlánc-specifikus alkalmazásokra, különösen a magas kockázatú rendszerek kategorizálására és auditálására.

Az MI-alapú élelmiszerlánc-biztonsági rendszerek bevezetése ugyanakkor jelentős kockázatokat is hordoz magában, amelyek megfelelő kezelés nélkül alááshatják a technológia hasznosságát. Az algoritmikus torzítás különösen problematikus, amikor a tanító adatok nem reprezentatívak (Dhal-Kar 2025). A hamis pozitív riasztások gazdasági költségei sem elhanyagolhatók: egy téves Salmonella-előrejelzés akár több millió eurós termékviszahívást és márkáérték-csökkenést okozhat. További kritikus pont a „black-box” algoritmusok átláthatatlansága, ami jogi és etikai dilemmákat vet fel szabályozói döntéshozatal esetén (Arrighi et al. 2025). Az MI-rendszerek iránti túlzott bizalom (*automation bias*) pedig veszélyeztetheti a döntéshozatalt, és erodálja a szakértelm értékét. Ezeket a kockázatokat csak strukturált megközelítéssel lehet mérsékelni: reprezentatív, kiegyensúlyozott adathalmazok építésével, robusztus validálási protokollokkal, költség-haszon-elemzésekkel a riasztási küszöbök optimalizálásához, valamint kötelező explainable AI-megoldásokkal (Manning et al. 2022). Alapvető fontosságú a folyamatos algoritmusauditálás, a torzításdetektálási eszközök használata és diverzifikált szakértői csapatok bevonása a fejlesztési és validálási folyamatokba.

A következő évtizedben az MI-alapú élelmiszerlánc-biztonság fejlődése több szakaszban várható. Rövid távon a meglévő adatok jobb kihasználása, az automatizálás és különböző pilotprojektek jellemzik majd a területet. Középtávon az interoperábilis rendszerek kiépülése és a real-time monitoring széles körű elterjedése várható. Hosszú távon pedig a prediktív és proaktív élelmiszerlánc-irányítás válhat valósággá. A siker érdekében viszont koordinált kutatás-fejlesztési programokra van szükség, amelyek a technológiai innovációt valós gyakor-

lati alkalmazásokra fordítják le. Az MI végső soron nem fogja helyettesíteni az élelmiszerlánc-szakértőket, inkább felerősíti a képességeiket és a hatókörüket, és a mai reaktív kontrollt átalakítja előrejelző, bizonyítékokon alapuló élelmiszerlánc-biztonsági irányítássá. Ez azonban csak akkor valósulhat meg, ha sikerül megteremteni a megfelelő adat-előfeltételeket, humán kapacitásokat és intézményi-jogi kereteket.

Irodalomjegyzék

- Arrighi, L., Alves de Moraes, I., Zullich, M., Simonato, M., Barbin, D. F. & Barbon, S. Jr. (2025) Explainable Artificial Intelligence techniques for interpretation of food datasets: A review. *ArXiv*, 2504.10527. <https://doi.org/10.48550/arXiv.2504.10527>
- Az Európai Parlament és a Tanács (EU) 2019/1381 rendelete (2019. június 20.) az élelmiszerláncban alkalmazott uniós kockázateértékelés átláthatóságáról és fenntarthatóságáról, továbbá a 178/2002/EK, az 1829/2003/EK, az 1831/2003/EK, a 2065/2003/EK, az 1935/2004/EK, az 1331/2008/EK, az 1107/2009/EK, valamint az (EU) 2015/2283 rendelet és a 2001/18/EK irányelv módosításáról. <https://eur-lex.europa.eu/legal-content/HU/TXT/HTML/?uri=CELEX:32019R1381>
- Az Európai Parlament és a Tanács (EU) 2024/1689 rendelete (2024. június 13.) a mesterséges intelligenciára vonatkozó harmonizált szabályok megállapításáról, valamint a 300/2008/EK, a 167/2013/EU, a 168/2013/EU, az (EU) 2018/858, az (EU) 2018/1139 és az (EU) 2019/2144 rendelet, továbbá a 2014/90/EU, az (EU) 2016/797 és az (EU) 2020/1828 irányelv módosításáról (a mesterséges intelligenciáról szóló rendelet). https://eur-lex.europa.eu/legal-content/HU/TXT/HTML/?uri=OJ:L_202401689
- Barabási, A. L., Menichetti, G. & Loscalzo, J. (2020) The unmapped chemical complexity of our diet. *Nature Food*, Vol. 1. pp. 33–37. <https://doi.org/10.1038/s43016-019-0005-1>
- Dhal, S. B. & Kar, D. (2025) Leveraging Artificial Intelligence and advanced food processing techniques for enhanced food safety, quality, and security: A comprehensive review. *Discover Applied Sciences*, Vol. 7. Article No. 75. <https://doi.org/10.1007/s42452-025-06472-w>
- Dimitrakopoulou, M.-E., Marinos, G., Karvounis, M., Stoitsis, G., Manouselis, N., Thanopoulos C. & Elliott, C. (2025) What lies behind mycotoxin presence in animal feed? A case study. *Journal of Food Protection*, Vol. 88. No. 4. <https://doi.org/10.1016/j.jfp.2025.100464>
- EFRA (Extreme Food Risk Analytics) Project (2024) The Potential of AI in Food Risk Prevention. Food Safety 4EU – EU Food Safety Platform. <https://efraproject.eu/the-potential-of-ai-in-food-risk-prevention>
- EFSA (European Food Safety Authority), Alvarez-Pinera, J., Bager, F., Bystrický, M., Ditmann Rasmussen, S., Foster, D., Fuchs, K., Gilsenan, M., Grahek-Ogden, D., Józwiak, Á., Moez, S., Neagu, M., O'Dea, E., Perrella, A., Richardson, J., Scharfenberg, E., Sokolic, D., Stack, M., Vermeersch, K. & Wienk, K. (2020) Report of the Advisory Forum Task Force on Data Collection and Data Modelling. EFSA Supporting Publication EN-1901. <https://doi.org/10.2903/sp.efsa.2020.EN-1901>
- EFSA (European Food Safety Authority), Abbinante, F., Basic, S., Foster, D., Fuchs, K., Georgieva, N., Józwiak, Á., Nellesmann, Ch., Maldonado, A., De Martino, M., O'Dea, E., Scharfenberg, E., Stack, M., Tuominen, M., Volatier, J.-L. & Wienk, K. (2024) 2023 Annual Report of the Advisory Group on Data. EFSA Supporting Publication EN-8760. 13 pp. <https://doi.org/10.2903/sp.efsa.2024.EN-8760>
- EFSA (European Food Safety Authority), Abbinante, F., Baggesen, D. L., Bašić, S., Flamini, V., Foster, D., Fuchs, K., Grahek-Ogden, D., Georgieva, N., Józwiak, Á., Maldonado, A., De Martino, M., Melo de Vasconcelos, F., Raeke, J., Scharfenberg, E., Stack, M., Stärk, K., Tuominen, M., Volatier, J.-L. & Wienk, K. (2025) 2024 Annual Report of the Advisory Group on Data. EFSA Supporting Publication EN-9374. <https://doi.org/10.2903/sp.efsa.2025.EN-9374>
- EFSA (European Food Safety Authority) (2025) Symposium on Data Readiness for Artificial Intelligence. EFSA Supporting Publication EN-9434. <https://doi.org/10.2903/sp.efsa.2025.EN-9434>
- El Harkaoui, S., Ortiz Cruz, C., Roggenland, A., Schneider, M., Rohn, S. et al. (2025) Adulteration detection in cactus seed oil: Integrating analytical chemistry and machine learning approaches. *Current Research in Food Science*, Vol. 10. Article No. 100986. <https://doi.org/10.1016/j.crf.2025.100986>
- European Commission Directorate-General for Informatics (DIGIT) (2019) Data quality management. ISA² Programme. European Commission, Brussels. <https://interoperable-europe.ec.europa.eu/sites/default/files/document/2019-09/SEMIC%20Study%20on%20data%20quality%20management.pdf>
- Gmeiner, A., Ivanova, M., Kaas, R. S., Xiao, Y., Otani, S. & Leekitcharoenphon, P. (2025) ListPred: A predictive ML tool for virulence potential and disinfectant tolerance in *Listeria monocytogenes*. *Infection, Genetics and Evolution*, Vol. 130. Article No. 105739. <https://doi.org/10.1016/j.meegid.2025.105739>
- Hooton, F., Menichetti, G. & Barabási, A. L. (2020) Exploring food contents in scientific literature with FoodMine. *Scientific Reports*, Vol. 10. No. 1. Article No. 16191. <https://doi.org/10.1038/s41598-020-73105-0>
- Ispirova, G., Cenikj, G., Ogrinc, M., Valenčič, E., Stojanov, R., Korošec, P., Cavalli, E., Koroušić Seljak, B. & Eftimov, T. (2022) CafeteriaFCD Corpus: Food Consumption Data Annotated with Regard to Different Food Semantic Resources. *Foods*, Vol. 11. No. 17. <https://doi.org/10.3390/foods11172684>
- Józwiak, Á. (2024) Prerequisites for data analysis and AI. Presented at the International Scientific Conference on “Global commodity chains from a risk assessment perspective”, Berlin, 27.–29. Mai 2024. <https://doi.org/10.17590/20240618-104950-0>
- Jöhnik, J., Weißert, M. & Wyrski, K. (2021) Ready or Not, AI Comes – An Interview Study of Organizational AI Readiness Factors. *Business & Information Systems Engineering*, Vol. 63. pp. 5–20. <https://doi.org/10.1007/s12599-020-00676-7>
- Krewski, D., Andersen, M. E., Tyshenko, M. G. et al. (2020) Toxicity testing in the 21st century: Progress in the past decade and future perspectives. *Archives of Toxicology*, Vol. 94. No. 1. pp. 1–58. <https://doi.org/10.1007/s00204-019-02613-4>
- Longo, L., Brcic, M., Cabitza, F., Choi, J., Confalonieri, R., Ser, J. D., Guidotti, R., Hayashi, Y., Herrera, F., Holzinger, A., Jiang, R., Khosravi, H., Lecue, F., Malgieri, G., Páez, A., Samek, W., Schneider, J., Speith, T. & Stumpf, S. (2024) Explainable Artificial Intelligence (XAI) 2.0: A manifesto of open challenges and interdisciplinary research directions. *Information Fusion*, Vol. 106. Article No. 102301. <https://doi.org/10.1016/j.inffus.2024.102301>
- Manning, L., Brewer, S., Craigon, P. J., Frey, J., Gutierrez, A., Jacobs, N., Kanza, S., Munday, S., Sacks, J. & Pearson, S. (2022) Artificial Intelligence and ethics within the food sector: Developing a common language for technology adoption across the supply chain. *Trends in Food Science & Technology*, Vol. 125. pp. 33–42. <https://doi.org/10.1016/j.tifs.2022.04.025>
- Njage, P. M. K., van Bunnik, B., Munk, P., Marques, A. R. P. & Aarestrup, F. M. (2023) Association of health, nutrition, and socioeconomic variables with global antimicrobial resistance: A modelling study. *Lancet Planet Health*, Vol. 7. No. 11. pp. e888–e899. [https://doi.org/10.1016/S2542-5196\(23\)00213-9](https://doi.org/10.1016/S2542-5196(23)00213-9)
- Popovski, G., Kochev, S., Seljak, B. K. & Eftimov, T. (2019) FoodIE: A Rule-based Named-entity Recognition Method for Food Information Extraction. In: *Proceedings of the 8th International Con-*

- ference on Pattern Recognition Applications and Methods (ICPRAM). SciTePress. pp. 915–922. <https://doi.org/10.5220/0007686309150922>
- Thakkar, Sh., Slikker Jr., W., Yiannas, F., Silva, P., Blais, B., Rei Chng, K., Liu, Zh., Adholeya, A., Pappalardo, F., da Luz Carvalho Soares, M., Beeler, P. E., Whelan, M., Roberts, R., Borlak, J., Hugas, M., Torrecilla-Salinas, C., Girard, Ph., Diamond, M. C., Verloo, D., Panda, B., Rose, M. C., Berenguer Jornet, J., Furuham, A., Fang, H., Kwegyir-Afful, E., Heintz, K., Arvidson, K., Garcia Burgos, J., Horst, A. & Tong, W. (2023) Artificial intelligence and real-world data for drug and food safety – A regulatory science perspective. *Regulatory Toxicology and Pharmacology*, Vol. 140. Article No. 105388. <https://doi.org/10.1016/j.yrtph.2023.105388>
- United Nations (2015) Transforming our world: The 2030 Agenda for Sustainable Development. United Nations General Assembly A/RES/70/1. <https://docs.un.org/en/A/RES/70/1>
- Wilkinson, M., Dumontier, M., Aalbersberg, I. et al. (2016) The FAIR Guiding Principles for scientific data management and stewardship. *Scientific Data*, Vol. 3. Article No. 160018. <https://doi.org/10.1038/sdata.2016.18>
- Wolffe, T. A. M., Whaley, P., Halsall, C., Rooney, A. A. & Walker, V. R. (2019) Systematic evidence maps as a novel tool to support evidence-based decision-making in chemicals policy and risk management. *Environment International*, Vol. 130. Article No. 104871. <https://doi.org/10.1016/j.envint.2019.05.065>