Mateja Grubor[1], David Milković[2], Nikola Bilandžija[1], Krešimir Čopec[1], Goran Fabijanić[1], Igor Kovačev[1]

Pregledni rad

Autonomni sustavi u akvaponskim sustavima

Sažetak

Cilj rada je pregledno analizirati ulogu autonomnih sustava u akvaponskim sustavima, s naglaskom na njihovu povezanost s konceptima Poljoprivrede 4.0, interneta stvari, senzorskih mreža, umjetne inteligencije, digitalnih blizanaca i kibernetičko-fizičkih sustava. Praktični doprinos rada očituje se u razgraničenju funkcija koje su danas najzrelije za primjenu od onih koje su još uvijek uglavnom na istraživačkoj razini. Pregled literature pokazuje da su za praktičnu primjenu najrazvijeniji IoT nadzor, kontinuirano senzorsko praćenje kvalitete vode i okolišnih uvjeta, automatizirano upravljanje osnovnim parametrima, poput pH vrijednosti, temperature, otopljenog kisika, električne vodljivosti (EC) i svjetla, te korištenje nadzornih ploča za prikaz i interpretaciju podataka. Te funkcije predstavljaju postojeću razinu automatizacije i mogu pridonijeti stabilnijem upravljanju proizvodnjom, smanjenju rizika od poremećaja i učinkovitijem korištenju resursa. Naprednije funkcije, poput računalnog vida, strojnog učenja, digitalnih blizanaca, ontologija i prediktivne optimizacije cijelog sustava, još su uglavnom na eksperimentalnoj razini. Njihova šira primjena ograničena je problemima interoperabilnosti, troška, energetske ovisnosti, pouzdanosti senzora, dostupnosti standardiziranih podataka i složenosti bioloških interakcija. Zaključuje se da budući razvoj treba usmjeriti prema skalabilnim, energetski učinkovitim i semantički povezanim sustavima koji povezuju senzorske podatke, digitalne blizance i umjetnu inteligenciju u cjelovitu potporu odlučivanju.

Ključne riječi: *akvaponski sustavi, autonomni sustavi, IoT, Poljoprivreda 4.0, digitalni blizanac*

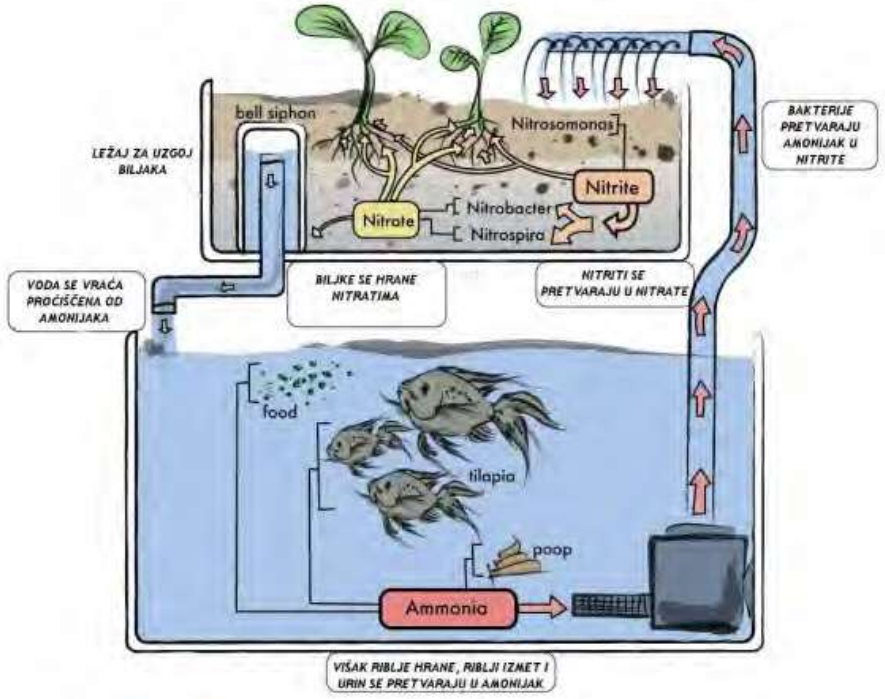
Uvod

Akvaponski sustavi predstavljaju integrirane proizvodne sustave koji povezuju recirkulacijsku akvakulturu i hidroponski uzgoj biljaka (slika 1). U takvom sustavu otpadne tvari iz akvakulturne komponente, nakon mikrobiološke pretvorbe amonijaka u nitrate, postaju izvor hraniva za biljke, dok biljke i biofilteri pridonose pročišćavanju vode koja se vraća ribama (Goddek i sur., 2019; Abbasi, Martinez i Ahmad, 2022). Zbog zatvorenog kruženja vode, mogućnosti proizvodnje biljaka i riba na ograničenoj površini te smanjenog oslanjanja na mineralna gnojiva, akvaponski se sustavi sve češće razmatraju kao tehnologija održive i urbane proizvodnje hrane. Unatoč navedenim prednostima, akvaponski sustavi tehnički su zahtjevni jer istodobno obuhvaćaju ribe, biljke, mikroorganizme, vodu, hraniva, opremu za cirkulaciju, aeraciju i filtraciju te kontrolirani okoliš. Svaka promjena u jednom podsustavu može izazvati posljedice

*1 Dr. sc. **Mateja Grubor**, izv. prof. dr. sc. **Nikola Bilandžija**, doc. dr. sc. **Krešimir Čopec**, **Goran Fabijanić**, dipl. ing. agr., viši stručni suradnik, izv. prof. dr. sc. **Igor Kovačev**, Sveučilište u Zagrebu Agronomski fakultet, Svetošimunska cesta 25, 10000 Zagreb, Hrvatska*
*2 **David Milković**, student, Sveučilište u Zagrebu Agronomski fakultet, Svetošimunska cesta 25, 10000 Zagreb, Hrvatska*
*Autor za korespondenciju: **mgrubor@agr.hr***

u drugome, primjerice poremećaj pH vrijednosti može utjecati na nitrifikaciju, dostupnost hraniva i zdravstveno stanje riba. Zbog toga su komercijalni akvaponski sustavi povezani s visokim potrebama za nadzorom i radom, a u literaturi se navodi potreba za kontinuiranim inspekcijama sustava tijekom cijelog dana (Reyes Yanes i sur., 2022; Abbasi, 2022).

U tom se kontekstu autonomni sustavi pojavljuju kao središnji element razvoja akvaponskih sustava 4.0. Pojam autonomije u ovom radu odnosi se na sposobnost sustava da mjeri stanje, interpretira podatke, donosi odluke i aktivira odgovarajuće radnje uz minimalnu intervenciju čovjeka. Takva autonomija obuhvaća senzore, bežične senzorske mreže, internet stvari (Internet of Things, IoT), aktuatorske sklopove, algoritme kontrole, računalni vid, strojno učenje, digitalne blizance i sustave potpore odlučivanju. Cilj rada je sintetizirati dostupnu literaturu o autonomnim akvaponskim sustavima te kritički prikazati njihove funkcije, koristi, ograničenja i smjerove razvoja.



Slika 1. Akvaponski sustav / **Figure 1.** Aquaponic system
(Izvor/Source : https://portalosuma.com/2015/07/11/akvaponija-jednostavan-uzgoj-hrane-bez-zemlje/)

Akvaponski sustavi 4.0 kao okvir autonomije

Razvoj akvaponskih sustava može se tumačiti kroz postupni prijelaz od ručno upravljanih sustava prema digitalnim i podatkovno vođenim farmama. Abbasi, Martinez i Ahmad (2022) opisuju akvaponske sustave 4.0 kao sustav u kojem se tehnologije Industrije 4.0, poput IoT-a, računarstva u oblaku, umjetne inteligencije, robotike, velikih podataka i semantičkog modeliranja, koriste za daljinski nadzor, kontrolu i inteligentno odlučivanje. Time se autonomija ne svodi na izolirani uređaj, nego na arhitekturu u kojoj fizički procesi i digitalni modeli razmjenjuju podatke u stvarnom vremenu.

U klasičnom akvaponskom sustavu proizvođač redovito provjerava pH, temperaturu vode, otopljeni kisik, električnu vodljivost, razinu vode, protok, temperaturu zraka, vlagu i svjetlost. U autonomnom sustavu te funkcije preuzimaju senzori, mikrokontroleri i softverski modeli. Taha i sur. (2022) ističu da IoT i pametni senzorski sustavi omogućuju praćenje i upravljanje operacijama akvaponskih sustava u stvarnom vremenu, dok Zamnuri i sur. (2024) naglašavaju da je to posebno važno za male proizvođače koji često nemaju dovoljno stručnog znanja za održavanje kemijske i biološke ravnoteže sustava. Takvim bi proizvođačima „lagana" autonomija (npr. rješenja bazirana na jeftinim mikrokontrolerima poput ESP32/Arduino i pametnim telefonima) mogla biti ključna za komercijalnu održivost, za razliku od skupih industrijskih rješenja.

Senzori, aktuatori i upravljačke funkcije

Osnovu autonomije čini pouzdano mjerenje. U dostupnoj literaturi najčešće se navode senzori za pH, temperaturu vode, temperaturu zraka, relativnu vlažnost zraka, otopljeni kisik, električnu vodljivost, mutnoću, razinu vode, intenzitet svjetlosti i protok (Wei i sur., 2019; Taha i sur., 2022; Rachana, 2025). Ti se podaci koriste za aktiviranje aktuatora, primjerice pumpi, aeratora, ventila, dozatora pH korektora, hranilica za ribe, rasvjete, ventilatora ili raspršivača. U jednostavnijim izvedbama upravljanje se temelji na pragovima, primjerice uključivanje aeracije pri padu otopljenog kisika ili korekcija pH vrijednosti kada mjerenje odstupi od optimalnog raspona. U tablici 1. dan je prikaz funkcija autonomnih akvaponskih sustava.

Takav pristup poboljšava sigurnost rada, ali još uvijek ne znači punu autonomiju. Sustav temeljen na pravilima tipa "ako-onda" učinkovit je za lokalnu regulaciju pojedinih varijabli, no akvaponski sustav je nelinearan biološko-tehnički sustav u kojem se odluke o vodi, hranjenju, gustoći nasada, svjetlu i hranivima međusobno uvjetuju. Ghandar i sur. (2021) upozoravaju da kibernetičko-fizički akvaponski sustavi najčešće ne optimiziraju cijeli ekosustav, nego lokalno kontroliraju podsustave. Stoga je važan prijelaz s reaktivne kontrole prema prediktivnom i adaptivnom upravljanju.

Tablica 1. Funkcije autonomnih akvaponskih sustava
Table 1. Functions of autonomous systems in aquaponics

Funkcija/Function	Senzori i izvori podataka/ Sensors and data sources	Tipična radnja/ Typical action	Razina autonomije/ Autonomy level
Kvaliteta vode	pH, otopljeni kisik, temperatura, EC, mutnoća	aeracija, korekcija pH, promjena protoka	lokalna kontrola i rana detekcija rizika
Okoliš biljaka	temperatura zraka, relativna vlaga, svjetlost, kamera	rasvjeta, ventilacija, raspršivanje	automatizirana regulacija mikroklime
Hranidba i ribe	timeri, kamere, senzori vode, modeli dobrobiti	hranjenje, alarm, izdvajanje anomalija	poluautonomna ili prediktivna kontrola
Rast i kvaliteta usjeva	RGB/HSV slike, segmentacija, morfometrija	procjena bolesti, kloroze, razmaka i biomase	AI potpora odlučivanju
Cjelovita optimizacija	IoT baza, digitalni blizanac, ontologija	simulacija scenarija i preporuke	visoka, ali istraživački nedovoljno zrela

Izvor/Source: sistematizirano prema Wei i sur. (2019), Ghandar i sur. (2021), Taha i sur. (2022), Reyes Yanes i sur. (2022), Abbasi (2022), Zamnuri i sur. (2024), Debroy i sur. (2025) i Dennison i sur. (2025).

Umjetna inteligencija, računalni vid i prediktivno upravljanje

Noviji radovi pomiču fokus s pukog prikupljanja podataka prema predikciji i dijagnostici. Abbasi (2022) razvija okvir u kojem se računalni vid i strojno učenje koriste za detekciju bolesti lisnatog povrća, procjenu kloroze, morfoloških svojstava i razmaka biljaka. Takvi modeli omogućuju nedestruktivnu kontrolu kvalitete te smanjuju ovisnost o subjektivnoj procjeni operatera. Sličan smjer razvoja vidljiv je u radovima koji koriste kamere i algoritme detekcije objekata za praćenje riba i izdvajanje obrazaca ponašanja kao ranih pokazatelja stresa ili bolesti (Kupsa i sur., 2025).

Primjena strojnog učenja osobito je značajna za dobrobit riba. Fandiño Pelayo i sur. (2025) prikazuju sustav koji kombinira niskotroškovne senzore pH vrijednosti, otopljenog kisika i temperature s modelima klasifikacije zdravstvenog stanja riba; u njihovoj usporedbi random forest postiže najvišu točnost klasifikacije. Takvi rezultati upućuju na mogućnost razvoja autonomnih sustava ranog upozorenja, no treba naglasiti da visoka točnost u jednom eksperimentalnom sustavu ne jamči opću robusnost u drugim vrstama riba, gustoćama nasada, klimama i konfiguracijama opreme.

Modeli umjetne inteligencije mogu pridonijeti i optimizaciji proizvodnje, primjerice predviđanju biomase, prinosa i rasta usjeva. Međutim, njihova primjena zahtijeva standardizirane podatke, pravilno označene skupove slika, kontinuiranu kalibraciju senzora i provjeru modela u različitim radnim uvjetima. Bez toga postoji rizik da algoritam detektira lokalne obrasce specifične za jedan sustav, a ne opće važeće biološke odnose.

Digitalni blizanci i sustavi potpore odlučivanju

Digitalni blizanac predstavlja virtualni model fizičkog sustava koji se ažurira podacima iz stvarnog sustava. U akvaponskim sustavima je njegova vrijednost u tome što omogućuje testiranje scenarija bez ugrožavanja živih organizama. Ghandar i sur. (2021) prikazuju digitalni blizanac u urbanom akvaponskom sustavu kao alat za planiranje proizvodnje i donošenje odluka u decentraliziranoj urbanoj poljoprivredi. Reyes Yanes i sur. (2022) razvijaju digitalni blizanac hidroponskih gredica u inteligentnom akvaponskom sustavu koji prati pH, električnu vodljivost, temperaturu vode, relativnu vlažnost, temperaturu zraka i intenzitet svjetlosti te omogućuje vizualizaciju i povratnu kontrolu sustava u stvarnom vremenu.

Noviji pregled Xu i sur. (2024) dodatno proširuje ovu perspektivu naglašavajući da digitalni blizanci u akvaponskim tvornicama mogu povezati nadzor, dijagnostiku, predviđanje, optimizaciju i kontrolu. Ipak, autori ističu da postoje otvoreni izazovi vezani uz arhitekturu modela, kvalitetu podataka, integraciju bioloških procesa i primjenjivost digitalnog blizanca izvan eksperimentalnih uvjeta. Stoga digitalni blizanac u akvaponskim sustavima treba promatrati kao razvojni most između senzorskog nadzora i istinske autonomne optimizacije.

Sustavi potpore odlučivanju dodatno koriste ontologije i modele znanja. AquaONT, koji razvijaju Abbasi, Martinez i Ahmad (2022), povezuje koncepte potrošačkog proizvoda, proizvodnog sustava, okoliša, kvalitete proizvoda i kontekstualnih podataka. Takvo semantičko povezivanje važno je jer podaci iz akvaponskih sustava dolaze iz heterogenih izvora: senzora, kamera, zapisa operatera, baza podataka i bioloških opažanja. Bez ontologije i standardizirane strukture značenja, autonomni sustav može mjeriti mnogo varijabli, ali teško iz tih podataka izvodi stabilne i objašnjive odluke.

Robotika i fizička autonomija

U užem smislu, autonomni sustavi uključuju robote i mehatroničke uređaje za sadnju, berbu, doziranje hraniva, hranjenje riba, premještanje biljnih nosača, čišćenje i inspekciju. U hidroponskim i akvaponskim sustavima robotika ima potencijal smanjiti potrebu za rad-

nom snagom i povećati ponovljivost operacija, osobito u kontroliranim okolišima i vertikalnim farmama (Dennison i sur., 2025). Ipak, stvarna primjena robotike u akvaponskim sustavima sporija je nego u konvencionalnoj automatizaciji vode i okoliša, ponajprije zbog cijene, tehničke složenosti i potrebe da robotska rješenja rade sigurno u vlažnom, biološki aktivnom i prostorno ograničenom okruženju.

U tom je smislu važno razlikovati autonomnu mehanizaciju od digitalne autonomije. Veći dio dostupne literature opisuje digitalno nadzirane i djelomično automatizirane sustave, dok potpuno autonomni robotski akvaponski sustavi ostaju istraživački i prototipni. Pregledi Wei i sur. (2019), Debroy i sur. (2025) i Dennison i sur. (2025) upućuju da su prioriteti za širu primjenu integracija kontrolnih sustava, automatizirano doziranje, energetski učinkovita oprema, upravljanje nutrijentima, pouzdani senzori i razvoj ekonomski opravdanih rješenja.

Ograničenja autonomnih akvaponskih sustava

Najvažnije ograničenje autonomnih akvaponskih sustava nije nedostatak pojedinačnih tehnologija, nego njihova integracija u cjelinu. Senzori mogu biti netočni zbog taloženja, biofilma i potrebe za kalibracijom. Aktuatori mogu raditi pouzdano u kratkim pokusima, ali zakazati tijekom dugotrajnog rada. Algoritmi strojnog učenja mogu biti osjetljivi na promjenu osvjetljenja, kamere, vrste usjeva ili gustoće riba. Digitalni blizanci mogu biti korisni za simulaciju, ali su ograničeni ako ne obuhvaćaju biološku varijabilnost, nelinearne povratne petlje i pragove sustava.

Drugo ograničenje odnosi se na ekonomiku i primjenu u praksi. Zamnuri i sur. (2024) naglašavaju da mali proizvođači trebaju jednostavne, jeftine i pouzdane IoT sustave, dok Debroy i sur. (2025) ističu važnost procjene troškova, edukacije i tehničke izvedivosti. Visoka cijena naprednih senzora, kamera, računalne infrastrukture i održavanja može poništiti dio koristi ako sustav nije projektiran prema stvarnim potrebama proizvođača. Autonomija stoga ne bi trebala značiti maksimalno dodavanje tehnologije, nego razumnu kombinaciju mjerenja, kontrole i odlučivanja koja smanjuje rizik i povećava stabilnost proizvodnje.

Zaključak

Autonomni akvaponski sustavi predstavljaju ključan razvojni smjer za prijelaz od eksperimentalnih i ručno nadziranih sustava prema stabilnoj, skalabilnoj i podatkovno vođenoj proizvodnji hrane. Pregled literature pokazuje da su najzrelije komponente autonomije povezane s IoT nadzorom, senzorskim mjerenjem kvalitete vode, upravljanjem osnovnim aktuatorima i nadzornim pločama za prikaz podataka. Napredniji slojevi, poput računalnog vida, strojnog učenja, digitalnih blizanaca i ontologija, omogućuju prijelaz prema prediktivnom upravljanju i potpori odlučivanju, ali još uvijek zahtijevaju validaciju u različitim proizvodnim uvjetima.

Najveći doprinos autonomnih sustava nije samo smanjenje potrebe za radnom snagom, nego i povećanje stabilnosti biološko-tehničkog ekosustava. Pravodobno otkrivanje odstupanja u vodi, okolišu, rastu biljaka ili ponašanju riba može smanjiti proizvodne gubitke, poboljšati dobrobit organizama i pridonijeti učinkovitijem korištenju resursa. Ipak, potpuna autonomija akvaponskih sustava još nije ostvarena jer većina postojećih rješenja optimizira pojedine podsustave, a ne cjelokupnu interakciju riba, biljaka, mikroorganizama, vode, hraniva i opreme. Osim toga, pri razvoju autonomnih sustava potrebno je uzeti u obzir i energetski otisak same digitalne infrastrukture, uključujući neprekidan rad senzora, prijenos i pohranu podataka u oblaku te treniranje i primjenu modela umjetne inteligencije. Stoga buduća autonomija mora uspostaviti ravnotežu između uštede vode, energije, hraniva i rada u proizvodnom procesu te potrošnje energije koju zahtijeva digitalna infrastruktura.

Buduća istraživanja trebala bi se usmjeriti na:

- razvoj interoperabilnih IoT standarda i arhitektura prilagođenih akvaponskim sustavima;
- energetski učinkovite senzorske mreže s mogućnošću autonomne kalibracije i pouzdanog dugotrajnog rada;
- objašnjive modele umjetne inteligencije prilagođene biološkoj varijabilnosti riba, biljaka i mikroorganizama;
- standardizirane javne skupove podataka za treniranje, validaciju i usporedbu prediktivnih modela;
- razvoj digitalnih blizanaca koji pouzdano povezuju stvarno stanje sustava s prediktivnim scenarijima;
- ekonomski prihvatljiva i tehnički održiva rješenja za male, urbane i lokalne proizvođače.

Tek takav pristup može pretvoriti akvaponske sustave 4.0 iz skupa pojedinačnih digitalnih alata u funkcionalan, održiv i autonomno upravljan proizvodni sustav.

Literatura

Abbasi, R. (2022) *An intelligent framework for quality inspection and control in aquaponics, based on computer-vision, artificial intelligence, and knowledge modeling. Doktorska disertacija. Edmonton: University of Alberta.*

Abbasi, R., Martinez, P., Ahmad, R. (2022) *An ontology model to represent aquaponics 4.0 system's knowledge. Information Processing in Agriculture, 9 (4), 514-532. DOI: 10.1016/j.inpa.2021.12.001*

Debroy, P., Majumder, P., Majumdar, P., Das, A., Seban, L. (2025) *Analysis of opportunities and challenges of smart aquaponic system: a summary of research trends and future research avenues. Sustainable Environment Research, 35, 18. DOI: 10.1186/s42834-025-00255-z*

Dennison, M.S., Kumar, P.S., Wamyil, F., Meji, M.A., Ganapathy, T. (2025) *The role of automation and robotics in transforming hydroponics and aquaponics to large scale. Discover Sustainability, 6, 105. DOI: 10.1007/s43621-025-00908-4*

Fandiño Pelayo, J.S., Mendoza Castellanos, L.S., Cazes Ortega, R., Hernández-Rojas, L.G. (2025) *AI-driven monitoring for fish welfare in aquaponics: a predictive approach. Sensors, 25, 6107. DOI: 10.3390/s25196107*

Ghandar, A., Ahmed, A., Zulfiqar, S., Hua, Z., Hanai, M., Theodoropoulos, G. (2021) *A decision support system for urban agriculture using digital twin: a case study with aquaponics. IEEE Access, 9, 35691-35708. DOI: 10.1109/ACCESS.2021.3061722*

Goddek, S., Joyce, A., Kotzen, B., Burnell, G.M., ur. (2019) *Aquaponics Food Production Systems: Combined Aquaculture and Hydroponic Production Technologies for the Future. Cham: Springer. DOI: 10.1007/978-3-030-15943-6*

Kupsa, R., Abdalla, Y., Gindl, S., Anjomshoaa, A., Tauber, M. (2025) *AI-driven aquaponics: real-time computer vision and machine learning in Industry 4.0. U: NOMS 2025 - IEEE Network Operations and Management Symposium. DOI: 10.1109/NOMS57970.2025.11073591*

Rachana, V.V. (2025) *Development of IoT based automated aquaponics system for water quality monitoring and control. Magistarski rad. Kerala: Kerala Agricultural University.*

Reyes Yanes, A., Abbasi, R., Martinez, P., Ahmad, R. (2022) *Digital twinning of hydroponic grow beds in intelligent aquaponic systems. Sensors, 22, 7393. DOI: 10.3390/s22197393*

Taha, M.F., ElMasry, G., Gouda, M., Zhou, L., Liang, N., Abdalla, A., Rousseau, D., Qiu, Z. (2022) *Recent advances of smart systems and Internet of Things (IoT) for aquaponics automation: a comprehensive overview. Chemosensors, 10, 303. DOI: 10.3390/chemosensors10080303*

Wei, Y., Li, W., An, D., Li, D., Jiao, Y., Wei, Q. (2019) *Equipment and intelligent control system in aquaponics: a review. IEEE Access, 7, 169306-169326. DOI: 10.1109/ACCESS.2019.2953491*

Xu, L., Yu, H., Qin, H., Chai, Y., Yan, N., Li, D., Chen, Y. (2024) *Digital twin for aquaponics factory: analysis, opportunities, and research challenges. IEEE Transactions on Industrial Informatics, 20 (4), 5060-5073. DOI: 10.1109/TII.2023.3331135*

Zamnuri, M.A.H., Qiu, S., Rizalmy, M.A.A., He, W., Yusoff, S., Roeroe, K.A., Du, J., Loh, K.H. (2024) *Integration of IoT in small-scale aquaponics to enhance efficiency and profitability: a systematic review. Animals, 14, 2555. DOI: 10.3390/ani14172555*

Prispjelo/Received: 24.6.2026. *Prihvaćeno/Accepted: 25.7.2026.*

Review paper

Autonomous systems in aquaponic systems

Abstract

The paper reviews the role of autonomous systems in aquaponics, with emphasis on Agriculture 4.0, Internet of Things, sensor networks, artificial intelligence, digital twins and cyber-physical systems. The review shows that autonomy in aquaponics is not limited to robotics, but includes the integration of sensors, actuators, control algorithms, knowledge models and decision support systems. The most mature applications are related to monitoring water quality, environmental conditions, fish feeding and basic actuator control. Recent studies increasingly apply computer vision and machine learning for disease detection, biomass estimation, fish welfare assessment and predictive monitoring. Digital twins and ontology-based systems provide an additional layer for simulation, semantic integration and transparent decision-making. However, most existing systems still perform local control of subsystems rather than global optimization of the aquaponic ecosystem. The main limitations include sensor reliability, calibration, interoperability, cost, energy demand and the complexity of biological interactions. Future development should focus on scalable, explainable and energy-efficient autonomous architectures that integrate sensor data, digital twins and artificial intelligence into practical decision support for commercial aquaponics.

Keywords: *aquaponic systems, autonomous systems, IoT, Agriculture 4.0, digital twin*

čara
pošip



cara@posip.hr
+385 20 833 146, 833 006
posip.hr