

e-ISSN: 2345-0592 Online issue Indexed in <i>Index Copernicus</i>	Medical Sciences Official website: www.medicosciences.com	
--	--	---

Artificial intelligence and nutrition assessment: a literature review

Paulina Judzinskytė¹, Kristė Maldauskaitė¹, Aušrinė Budrytė²

¹Lithuanian University of Health Sciences, Academy of Medicine, Faculty of Medicine, Kaunas, Lithuania

²Lithuanian University of Health Sciences, Department of Family Medicine, Kaunas, Lithuania

Abstract

Introduction. Artificial intelligence (AI) is becoming an increasingly relevant technology that allows the effective analysis of complex and large-scale data. In nutritional science, this technology opens up opportunities for more accurate assessment of dietary habits and the creation of personalized recommendations, which are important for both clinical practice and public health. **Aim of the study.** To evaluate the application of AI in dietary assessment and clinical practice. **Methods.** An analysis of publications from 2015 to 2025 was conducted using information search system "PubMed". The studies were analyzed using relevant keywords and their combinations. **Results.** In nutritional assessment, AI is most commonly applied using machine learning (ML) and deep learning (DL) methods adapted to analyze large volumes of nutritional and visual data. Image recognition-based systems allow the automatic recording of food consumption, assessment of portion sizes, and calculation of energy and nutritional value, achieving 74–99 % recognition accuracy. In clinical practice, AI solutions are used to assess the risk of malnutrition, determine nutrient intake and predict the risk of nutrition-related diseases. **Conclusions.** AI demonstrates potential as a supportive tool in dietary assessment, however, due to the lack of standardized guidelines, its use in clinical practice should be supervised by healthcare professionals.

Keywords: artificial intelligence, nutritional assessment, food intake monitoring.

Dirbtinis intelektas ir mitybos vertinimas: literatūros apžvalga

Paulina Judzinskytė¹, Kristė Maldauskaitė¹, Aušrinė Budrytė²

¹Lietuvos sveikatos mokslų universitetas, Medicinos akademija, Medicinos fakultetas, Kaunas, Lietuva

²Lietuvos sveikatos mokslų universitetas, Šeimos medicinos klinika, Kaunas, Lietuva

Santrauka

Įvadas. Dirbtinis intelektas (DI) tampa vis aktualesne technologija, leidžiančia efektyviai analizuoti sudėtingus ir didelės apimties duomenis. Mitybos moksluose šios technologijos atveria galimybes tikslesniam mitybos įpročių vertinimui ir personalizuotų rekomendacijų kūrimui, reikšmingų tiek klinikinei praktikai, tiek visuomenės sveikatai. **Tyrimo tikslas.** Įvertinti DI taikymą mitybos vertinime ir jo galimybes klinikinėje praktikoje. **Tyrimo metodai.** Atlikta 2015 – 2025 m. publikuotų mokslinių šaltinių analizė, naudojant informacinę paieškos sistemą „PubMed“. Darbai išanalizuoti vartojant reikšminius žodžius ir jų derinius. **Rezultatai.** Mitybos vertinime DI dažniausiai taikomas naudojant mašininio (MM) ir giliojo mokymosi (GM) metodus, pritaikytus didelės apimties mitybos duomenims ir vaizdams analizuoti. Vaizdų atpažinimu pagrįstos sistemos leidžia automatiškai fiksuoti suvartojamus maisto produktus, įvertinti porcijų dydžius ir apskaičiuoti energinę bei maistinę vertę, pasiekiant 74–99 proc. atpažinimo tikslumą. Klinikinėje praktikoje DI sprendimai taikyti nepakankamos mitybos rizikos vertinimui, maistinių medžiagų suvartojimo nustatymui ir su mityba susijusių ligų rizikos prognozavimui. **Išvados.** DI gali būti naudojamas kaip pagalbinė mitybos vertinimo priemonė, tačiau dėl standartizuotų gairių stokos jo taikymas klinikinėje praktikoje turėtų vykti su specialisto priežiūra.

Raktažodžiai: dirbtinis intelektas, mitybos vertinimas, maisto suvartojimo stebėjimas.

1. Įvadas

Dirbtinis intelektas (DI) šiandien laikomas viena sparčiausiai progresuojančių technologijų, turinčių reikšmingą įtaką įvairioms mokslo ir praktikos sritims. DI esmė – kurti sistemas, gebančias atlikti užduotis, kurios įprastai siejamos su žmogaus kognityvinėmis funkcijomis, tokiomis kaip mokymasis, informacijos apdorojimas, samprotavimas ir sprendimų priėmimas [1]. Pagal veikimo pobūdį DI skirstomas į siaurąjį ir bendrąjį, tačiau praktiniame taikyme – ypač sveikatos moksluose – šiuo metu naudojamas siaurasis DI. Jis skirtas aiškiai apibrėžtoms užduotims atlikti, pavyzdžiui, kalbos ar vaizdų apdorojimui, diagnostinių modelių kūrimui ar duomenų analizei. Šiuos DI sprendimus įgalina pažangūs algoritminiai metodai – mašininis mokymasis (MM), gilusis mokymasis (GM), natūralios kalbos apdorojimas (NKA) ir kompiuterinė rega (KR). Šios technologijos leidžia apdoroti didelės apimties duomenis bei suteikia galimybę DI sistemoms veikti tiksliai ir efektyviai [2]. Sparčiai vystantis DI technologijoms, jos vis plačiau integruojamos į įvairias mokslo ir klinikinės praktikos sritis. DI metodai jau pritaikomi medicinoje, padeda analizuoti vaizdinius duomenis, automatizuoti diagnostikos procesus ir gerinti klinikinių sprendimų tikslumą [3]. DI metodai leidžia analizuoti didelės apimties, nelinearius duomenis, todėl gali atskleisti dėsningumus, kurie tradiciniais analizės metodais būtų sunkiai identifikuojami [4–6]. Pastaraisiais metais DI vis dažniau taikomas ir mitybos moksluose: naudojamas maisto atvaizdų atpažinimui, suvartotų maistinių medžiagų įvertinimui, mitybos elgsenos analizei bei personalizuotų rekomendacijų kūrimui [7]. Šios technologijos tampa svarbia priemone vertinant tiek klinikinių pacientų, tiek bendrosios populiacijos mitybos įpročius, siekiant sudaryti sąlygas tikslesnei mitybos analizei.

Šios literatūros apžvalgos tikslas – apžvelgti DI taikymą mitybos vertinime ir jo galimybes klinikinėje praktikoje.

2. Metodika

Mokslinės literatūros apžvalga buvo rengiama remiantis PRISMA (Preferred Reporting Item for Systematic Review and Meta-Analyses) sisteminės apžvalgos reikalavimais. Atlikta per paskutiniuosius 10 metų publikuotų mokslinių straipsnių analizė. Paieškai pasirinkta kompiuterinė bibliografinė medicininė duomenų bazė „PubMed“. Paieška atlikta naudojant šių raktinių žodžių kombinacijas: nutrition, artificial intelligence, diet, dietary assessment. Duomenų bazėje naudoti filtrai: 10 years, english. Paieškai buvo naudojami šie įtraukimo kriterijai:

1. Mokslinėje publikacijoje pateikta informacija nors apie vieną tyrimui reikalingą temą: DI, jo taikymą mitybos srityje, mitybos įpročių vertinimą ar su DI pagrįstą mitybos technologijų naudojimą.
2. Mokslinės publikacijos išleidimo data yra 2015-01-01 – 2025-12-14.
3. Mokslinė publikacija gali būti iš visų pasaulio šalių.
4. Mokslinė publikacija parašyta anglų kalba.

Atmetimo kriterijai:

1. Mokslinės publikacijos savo turiniu neatitinkančios nagrinėjamos temos.
2. Negauta prieiga iš LSMU kompiuterių tinklo.

Į duomenų bazę suvedus raktinių žodžių derinius iš viso gauti 4834 bibliografiniai įrašai. Mokslinės publikacijos buvo atrenkamos trimis etapais. Pirmojo etapo metu atmesti straipsniai, išleisti seniau nei prieš 10 metų ir parašyti ne anglų kalba bei dublikatai. Tuomet atsižvelgiant į pavadinimą ir santrauką, įtrauktos publikacijos potencialiai atitinkančios įtraukimo kriterijus. Paskutinio etapo metu, perskaitytas pilnas tekstas, atlikta jo analizė ir atmestos nustatytų atrankos kriterijų neatitinkančios

publikacijos. Į literatūros apžvalgą buvo įtrauktos 36 publikacijos.

3. Rezultatai

3.1. Dirbtinis intelektas

Medicinoje DI taikyme pagrindinį vaidmenį atlieka mašininis mokymasis (MM), apibrėžiamas kaip metodų visuma, leidžianti modeliams mokytis iš turimų duomenų ir gerinti savo prognozes be tiesioginio programavimo kiekvienam atvejui [8]. Pagal mokymosi principą MM paprastai skirstomas į prižiūravimo ir neprižiūravimo mokymosi metodus. Prižiūravimo mokymosi metodu naudojami pažymėti duomenų rinkiniai, kuriuose kiekvienam įrašui yra žinoma teisinga išvestis, todėl algoritmai mokomi klasifikuoti ir prognozuoti pagal pateiktus pavyzdžius. Šiai grupei priskiriami tokie plačiai taikomi metodai kaip neuroniniai tinklai, atraminių vektorių mašina ar atsitiktinių miškų algoritmas. Medicinoje jie naudojami ligų rizikai įvertinti, pacientų rizikos grupėms išskirti ir klinikinėms baigtims prognozuoti [9–11]. Neprižiūravimo mokymosi metodai taikomi tada, kai duomenys nėra pažymėti – algoritmai patys ieško pasikartojančių raštų, klasterių ar paslėptų struktūrų. Tipinis pavyzdys yra klasterizavimo metodai, leidžiantys suskirstyti dideles duomenų aibes į tarpusavyje panašias grupes ir taip atskleisti ryšius, kurie tradiciniais statistiniais metodais gali likti nepastebėti [12,13]. MM posritis – gilusis mokymasis (GM) – paremtas giliųjų neuroninių tinklų architektūromis. Jis ypač tinkamas nestruktūrizuotiems, didelės apimties duomenims (vaizdams, signalams, tekstui) analizuoti, todėl plačiai taikomas sudėtingose biomedicininėse ir mitybos tyrimų užduotyse, kur reikalingas didelis atpažinimo ir prognozavimo tikslumas [8–13]. GM pagrindu kuriamos ir KR sistemos, leidžiančios iš vaizdų automatiškai atpažinti maisto produktus, įvertinti porcijos dydį ir apskaičiuoti suvartotų

maistinių medžiagų kiekį [14]. Taigi, medicinoje taikomi DI būdai sudaro metodologinį pagrindą sudėtingų biomedicininėse ir mitybos duomenų analizei, leidžiančiai efektyviau identifikuoti dėsningumus ir prognozuoti klinikinės baigtis.

3.2. Mitybos vertinimo metodai

Tradiciskai suvartojamas maistas yra vertinamas pasitelkiant maisto dienoraščius, maisto vartojimo klausimynus ir kitus būdus, kurie reikalauja didelių atsakančiojo pastangų, o tai gali lemti netikslų duomenų pateikimą [15]. Įvykus proveržiui vaizdų atpažinimo ir GM metodų srityje, DI yra praktiskai panaudojamas mitybos vertinime kasdienybėje su įrankiais, kurie atpažįsta maisto produktus iš nuotraukų ir automatiškai registruoja valgius, vertina porcijas, apskaičiuoja kalorijas, maistingumą bei atpažįsta valgymo proceso judesius, naudojant nešiojamus įrenginius (pvz., išmaniuosius laikrodžius), taip sumažindami neregistruojamų valgytų skaičių. GM metodu bei vaizdo atpažinimu pagrįstos mitybos vertinimo programėlės maisto produktus atpažįsta maždaug 74–99 proc. tikslumu, o kaloringumą bei maistingumą su maždaug 10–18 proc. vidutine paklaida kontroliuojamuose bandymuose [15–17]. Įrenginiuose esančios maisto atpažinimo sistemos gali aptikti kelis skirtingus produktus viename vaizde ir sėkmingai įvertinti maisto porcijas, tokį praktinį automatinio valgio registravimo pritaikymą pademonstravo klasikinės išmaniųjų telefonų sistemos [18]. Šiuolaikiniai metodai geba gaunamus vaizdus susieti su struktūrizuotomis mitybos duomenų bazėmis. Tokie metodai su mažesne paklaida nei klasikinės mitybos programėlės gali apskaičiuoti ne tik suvartojamo maisto kaloringumą ir pagrindines maistines medžiagas, bet ir įvertinti gaunamų vitaminų ir mineralų kiekį [19]. Nepriklausomi tyrimai rodo, kad vaizdo atpažinimu pagrįstos programėlės dažniausiai atitinka svorto

maisto duomenis, tačiau nepakankamai įvertina ar pervertina maisto suvartojimą, ypač paklaidos didėja vartojant dideles porcijas ar gėrimus. Šią problemą padeda spręsti vartotojo galimybė koreguoti suvartojamus produktus bei porcijas [20]. DI pagalba naudojant kelis nešiojamus įrenginius, kurie aptinka kramtymą, rijimą ir gestus (ranka prie burnos), galima pasyviai sekti suvartojamo maisto kiekį beveik 80–95 proc. tikslumu. Vienas iš įrenginių yra išmanusis laikrodis, kuris judesio jutiklių pagalba gali atpažinti, kada žmogus valgo ir sujungęs su kitais duomenimis gali labai tiksliai nustatyti valgymo laikotarpius [21]. Naudodami elektromiografiją, optinius ar pjezoelektrinius jutiklius išmanieji akiniai gali atpažinti kramtymo veiksmus. Laboratorijos sąlygomis, tai atlieka daugiau nei 90 proc. tikslumu, o bendrojoje populiacijoje tikslumas siekia maždaug 77–95 proc. Taip pat šis įrenginys padeda sekundžių tikslumu nustatyti kada prasideda ir baigiasi valgymas [22–24]. Apžvalginiai tyrimai rodo, kad šios priemonės, lyginant su maisto dienoraščiais ir 24 valandų prisiminimo metodais, sumažina atminties sukeltas klaidas bei atsakančiųjų apkrovą [25,26]. Derinant vaizdų atpažinimą grįstą programėlę kartu su nešiojamu detektoriumi (išmaniuoju laikrodžiu, akiniais) šiuo metu galima gauti išsamiausią ir tiksliausią maisto suvartojimo stebėjimą [27,28]. Taigi, DI grįsti mitybos vertinimo metodai leidžia reikšmingai sumažinti saviregistracijos klaidas ir respondentų apkrovą, užtikrinant tikslesnę ir išsamesnę maisto suvartojimo stebėjimą kasdienėje aplinkoje.

3.3. Mitybos vertinimo metodai klinikinėje praktikoje

Analizuojami tyrimai rodo, kad DI gali turėti svarbų vaidmenį ir klinikinėje praktikoje. Salinari ir kt. nustatė, jog DI gali padėti prognozuoti ligų išsivystymą, gerinti pacientų priežiūrą ir optimizuoti

gydymo procesus. Autoriai pabrėžia, kad šių technologijų integravimas į sveikatos priežiūros praktiką gali prisidėti prie greitesnės diagnostikos, personalizuotos medicinos taikymo, ligų vertinimo ir stebėsenos efektyvumo bei sveikatos priežiūros kaštų mažinimo [29]. Papathanail ir kt. pasiūlė alternatyvų mitybos vertinimo metodą, paremtą paciento suvartoto maisto fiksavimu prieš valgį ir po, siekiant identifikuoti nepakankamos mitybos riziką vyresnio amžiaus pacientams. Tyrime DI pagrįstos sistemos rezultatai buvo lyginami tiek su slaugos personalo vertinimais, atliktais pagal įprastą ligoninės praktiką, tiek su kontroliniu vertinimu, kurį atliko du dietologai ir medicinos studentas. Nustatyta, kad DI sistema makroelementų suvartojimą įvertino su mažesne nei 15 proc. paklaida, o energijos suvartojimą – su 11,64 proc. paklaida, tuo tarpu slaugos personalo vertinimų paklaida viršijo 30 proc. ir 31,45 proc. [30]. MM metodai taip pat gali būti pritaikyti siekiant prognozuoti su mityba susijusią širdies bei kraujagyslių ligų riziką. Retrospektyviniame kohortiniame tyrime, apimančiame 12 130 asmenų ir 14 m. stebėjimo laikotarpį, DI modelis gebėjo prognozuoti širdies bei kraujagyslių ligų riziką susijusią su mitybos įpročiais. Prognozavimo tikslumas buvo įvertintas AUROC (*angl. area under the receiver operating characteristic curve*) - 0,82, tai rodo gerą gebėjimą atskirti asmenis, turinčius didesnę ir mažesnę ligos riziką, o didžiausią reikšmę turėję mitybos veiksniai buvo natrio, alkoholio ir kofeino suvartojimas [31]. 2020 m. Australijoje atliktame tyrime panaudotas DI virtualus asistentas „Paola“, kuris buvo pritaikytas gyvenimo būdo keitimo programoje, apimančioje Viduržemio jūros dietos principais grįstas mitybos rekomendacijas ir fizinio aktyvumo tikslų formavimą. Tyrime dalyvavo 31 asmuo, 45–75 m. amžiaus, kurie 12 savaičių laikotarpiu naudojo virtualaus asistento teikiamomis rekomendacijomis. Stebėjimo

laikotarpiu nustatytas statistiškai reikšmingas kūno svorio (–1,3 kg) ir liemens apimties sumažėjimas (–2,1 cm). Kitaip tariant, DI pagrįstas skaitmeninis asistentas gali būti veiksminga priemonė palaikant mitybos ir fizinio aktyvumo pokyčius [32]. Vis dėlto dauguma šių sprendimų šiuo metu turėtų būti vertinami kaip pagalbinės priemonės, papildančios įvairių specialybių gydytojų ar dietologų klinikinį sprendimą, nes ilgalaikių intervencinių klinikinių tyrimų, vertinančių jų poveikį klinikinėms baigtims, vis dar trūksta [33]. Niszczota ir kt. atliko tyrimą, kuriame vertintas „ChatGPT“ gebėjimas generuoti mitybos planus, atsižvelgiant į saugumą ir tikslumą. Buvo analizuoti 56 patiekalai, kuriuos DI sukūrė fiktyviai, maisto alergijų turinčiai, moteriai. Nustatyta, kad 4 patiekaluose buvo alergenų, nepaisant aiškiai nurodytų apribojimų. Taip pat sąmoningai pasirinkus energiška nepakankamą dietą, modelis nepateikė jokio perspėjimo, o kai kuriuose patiekaluose neteisingai apskaičiavo energinę vertę. Nors „ChatGPT“ rekomendacijos formaliai atitiko bendrąsias mitybos gaires, autoriai pabrėžė, kad tokios klaidos kelia riziką neprofesionaliems naudotojams [34]. Dar vieną tyrimą apie DI atliko Sun ir kt., kuriame buvo vertinamas „ChatGPT“ ir „ChatGPT-4“ potencialas kaip DI pagrįsto mitybos specialisto, daugiausia dėmesio skiriant 2 tipo cukriniam diabetui. Nustatyta, kad mitybos žinių tikslumas siekė 60,5 proc. („ChatGPT“) ir 74,5 proc. („ChatGPT-4“), o ketogeninės dietos klausimais atsakymai 80,7 proc. sutapo su ekspertų vertinimais. Kitaip tariant, dauguma atsakymų buvo įvertinti kaip geri (48,81 proc.) arba priimtini (47,62 proc.), tačiau dalis – kaip kliniškai nepriimtini (3,57 proc.). Nors modelis sėkmingai išlaikė Kinijos registruoto dietologo egzaminą, autoriai pažymėjo, kad klinikiniai tyrimai, vertinantys realų poveikį pacientų sveikatos baigtims, nebuvo atlikti, todėl generatyvus DI turėtų būti naudojamas tik kaip pagalbinė, o ne

savarankiška mitybos konsultavimo priemonė [35]. Dauguma DI pokalbių robotų naudoja įtikinimo ir santykio kūrimo strategijas, kurios gali didinti naudotojų įsitraukimą, tačiau kartu kelia riziką, jog pateikiama informacija bus priimama nekritiškai, ypač neturint specialisto priežiūros [35, 36]. Taigi, klinikinėje praktikoje DI šiuo metu labiausiai pagrįstas kaip pagalbinė mitybos vertinimo ir ligų rizikos prognozavimo priemonė, tačiau jo taikymas reikalauja kritinio vertinimo ir specialisto priežiūros.

4. Išvados

1. Dirbtinis intelektas mitybos vertinime sudaro galimybes tiksliau fiksuoti maisto suvartojimą, įvertinti porcijų dydžius ir apskaičiuoti energinę bei maistinę vertę, taip sumažinant saviregistracijos sukeltas klaidas.
2. Tyrimų duomenys rodo, kad dirbtinio intelekto metodai gali būti pritaikomi mitybos būklės vertinimui ir su mityba susijusių ligų rizikos prognozavimui klinikinėje praktikoje, tačiau jų taikymui dar nėra standartizuotų gairių.
3. Dirbtinis intelektas gali būti naudojamas kaip pagalbinė mitybos vertinimo priemonė, papildanti specialisto sprendimų priėmimą, tačiau neturėtų būti laikomas savarankišku klinikiu įrankiu.

Literatūros šaltiniai

1. Boden MA. Ai: Its Nature and Future. 2016 [cited 2025 Dec 13]. Available from: <https://philpapers.org/rec/BODAIN>
2. Sak J, Suchodolska M. Artificial Intelligence in Nutrients Science Research: A Review. *Nutrients*. 2021 Feb 1 [cited 2025 Dec 13];13(2):1–17. Available from: <https://pubmed.ncbi.nlm.nih.gov/33499405/>
3. Yasaka K, Abe O. Deep learning and artificial intelligence in radiology: Current

applications and future directions. *PLoS Med* [Internet]. 2018 Nov 1;15(11). Available from: <https://pubmed.ncbi.nlm.nih.gov/30500815/>

4. Devika NT, Raman K. Deciphering the metabolic capabilities of Bifidobacteria using genome-scale metabolic models. *Scientific Reports* 2019 9:1 [Internet]. 2019 Dec 3 [cited 2025 Dec 13];9(1):18222-. Available from: <https://www.nature.com/articles/s41598-019-54696-9>

5. Shima H, Masuda S, Date Y, Shino A, Tsuboi Y, Kajikawa M, et al. Exploring the Impact of Food on the Gut Ecosystem Based on the Combination of Machine Learning and Network Visualization. *Nutrients* [Internet]. 2017 Dec 1 [cited 2025 Dec 13];9(12). Available from: <https://pubmed.ncbi.nlm.nih.gov/29194366/>

6. Mohammed A, Guda C. Application of a hierarchical enzyme classification method reveals the role of gut microbiome in human metabolism. *BMC Genomics* [Internet]. 2015 Jun 11 [cited 2025 Dec 13];16 Suppl 7(Suppl 7). Available from: <https://pubmed.ncbi.nlm.nih.gov/26099921/>

7. Handelman GS, Kok HK, Chandra R V., Razavi AH, Lee MJ, Asadi H. eDoctor: machine learning and the future of medicine. *J Intern Med* [Internet]. 2018 Dec 1 [cited 2025 Dec 13];284(6):603–19. Available from: <https://pubmed.ncbi.nlm.nih.gov/30102808/>

8. Jo T. Machine learning foundations: Supervised, unsupervised, and advanced learning. *Machine Learning Foundations: Supervised, Unsupervised, and Advanced Learning*. 2021 Feb 12;1–391.

9. Vilorio A, Herazo-Beltran Y, Cabrera D, Pineda OB. Diabetes Diagnostic Prediction Using Vector Support Machines. *Procedia Comput Sci* [Internet]. 2020 Jan 1 [cited 2025 Dec 13];170:376–81. Available from:

<https://www.sciencedirect.com/science/article/pii/S1877050920305020>

10. Pal M, Parija S. Prediction of Heart Diseases using Random Forest. *J Phys Conf Ser*. 2021 Mar 15;1817(1).

11. Wang J, Yu H, Hua Q, Jing S, Liu Z, Peng X, et al. A descriptive study of random forest algorithm for predicting COVID-19 patients outcome. *PeerJ* [Internet]. 2020 Sep 9 [cited 2025 Dec 13];8:e9945. Available from: <https://peerj.com/articles/9945>

12. Quito B, Esmahi L. Compare and Contrast LiDAR and Non-LiDAR Technology in an Autonomous Vehicle: Developing a Safety Framework. *Open Journal of Safety Science and Technology*. 2023 Jan 1;13(03):101–31.

13. Alashwal H, El Halaby M, Crouse JJ, Abdalla A, Moustafa AA. The Application of Unsupervised Clustering Methods to Alzheimer's Disease. *Front Comput Neurosci* [Internet]. 2019 May 24 [cited 2025 Dec 13];13. Available from: <https://pubmed.ncbi.nlm.nih.gov/31178711/>

14. Sun M, Liu Q, Schmidt K, Yang J, Yao N, Fernstrom JD, et al. Determination of food portion size by image processing. *Annu Int Conf IEEE Eng Med Biol Soc* [Internet]. 2008 [cited 2025 Dec 13];2008:871–4. Available from: <https://pubmed.ncbi.nlm.nih.gov/19162795/>

15. Chrintz-Gath G, Daivadanam M, Matta L, McKeever S. Image-Based Dietary Assessment Using the Swedish Plate Model: Evaluation of Deep Learning-Based You Only Look Once (YOLO) Models. *JMIR Form Res* [Internet]. 2025 [cited 2025 Dec 13];9. Available from: <https://pubmed.ncbi.nlm.nih.gov/40812290/>

16. Raju VB, Imtiaz MH, Sazonov E. Food Image Segmentation Using Multi-Modal Imaging Sensors with Color and Thermal Data. *Sensors (Basel)* [Internet]. 2023 Jan 1 [cited 2025 Dec

- 13];23(2). Available from: <https://pubmed.ncbi.nlm.nih.gov/36679357/>
17. Shao W, Min W, Hou S, Luo M, Li T, Zheng Y, et al. Vision-based food nutrition estimation via RGB-D fusion network. *Food Chem [Internet]*. 2023 Oct 30 [cited 2025 Dec 13];424. Available from: <https://pubmed.ncbi.nlm.nih.gov/37207601/>
18. Zhang W, Yu Q, Siddiquie B, Divakaran A, Sawhney H. “Snap-n-Eat”: Food Recognition and Nutrition Estimation on a Smartphone. *J Diabetes Sci Technol [Internet]*. 2015 May 1 [cited 2025 Dec 13];9(3):525–33. Available from: <https://pubmed.ncbi.nlm.nih.gov/25901024/>
19. Yan R, Luo H, Lu J, Liu D, Posluszny H, Dhaliwal MP, et al. DietAI24 as a framework for comprehensive nutrition estimation using multimodal large language models. *Communications medicine [Internet]*. 2025 Dec 1 [cited 2025 Dec 13];5(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/41193610/>
20. Zhang L, Misir A, Boshuizen H, Ocké M. A Systematic Review and Meta-Analysis of Validation Studies Performed on Dietary Record Apps. *Advances in Nutrition [Internet]*. 2021 Nov 1 [cited 2025 Dec 13];12(6):2321–32. Available from: <https://pubmed.ncbi.nlm.nih.gov/34019624/>
21. Zhang B, Deng K, Shen J, Cai L, Ratitch B, Fu H, et al. Enabling Eating Detection in a Free-living Environment: Integrative Engineering and Machine Learning Study. *J Med Internet Res [Internet]*. 2022 Mar 1 [cited 2025 Dec 13];24(3). Available from: <https://pubmed.ncbi.nlm.nih.gov/35230244/>
22. Stankoski S, Kiprijanovska I, Gjoreski M, Panchevski F, Sazdov B, Sofronievski B, et al. Controlled and Real-Life Investigation of Optical Tracking Sensors in Smart Glasses for Monitoring Eating Behavior Using Deep Learning: Cross-Sectional Study. *JMIR Mhealth Uhealth [Internet]*. 2024 [cited 2025 Dec 13];12. Available from: <https://pubmed.ncbi.nlm.nih.gov/39325528/>
23. Farooq M, Sazonov E. Segmentation and Characterization of Chewing Bouts by Monitoring Temporalis Muscle Using Smart Glasses With Piezoelectric Sensor. *IEEE J Biomed Health Inform [Internet]*. 2017 Nov 1 [cited 2025 Dec 13];21(6):1495–503. Available from: <https://pubmed.ncbi.nlm.nih.gov/28113335/>
24. Zhang R, Amft O. Retrieval and Timing Performance of Chewing-Based Eating Event Detection in Wearable Sensors. *Sensors (Basel) [Internet]*. 2020 Jan 2 [cited 2025 Dec 13];20(2). Available from: <https://pubmed.ncbi.nlm.nih.gov/31968532/>
25. Zheng J, Wang J, Shen J, An R. Artificial Intelligence Applications to Measure Food and Nutrient Intakes: Scoping Review. *J Med Internet Res [Internet]*. 2024 [cited 2025 Dec 13];26(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/39608003/>
26. Mortazavi BJ, Gutierrez-Osuna R. A Review of Digital Innovations for Diet Monitoring and Precision Nutrition. *J Diabetes Sci Technol [Internet]*. 2023 Jan 1 [cited 2025 Dec 13];17(1):217–23. Available from: <https://pubmed.ncbi.nlm.nih.gov/34467803/>
27. Bell BM, Alam R, Alshurafa N, Thomaz E, Mondol AS, de la Haye K, et al. Automatic, wearable-based, in-field eating detection approaches for public health research: a scoping review. *NPJ Digit Med [Internet]*. 2020 Dec 1 [cited 2025 Dec 13];3(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/32195373/>
28. Boushey CJ, Spoden M, Zhu FM, Delp EJ, Kerr DA. New mobile methods for dietary assessment: review of image-assisted and image-based dietary assessment methods. *Proc Nutr Soc [Internet]*. 2017 Aug 1 [cited 2025 Dec 13];3(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/32195373/>

- 13];76(3):283–94. Available from: <https://pubmed.ncbi.nlm.nih.gov/27938425/>
29. Salinari A, Machi M, Armas Diaz Y, Cianciosi D, Qi Z, Yang B, et al. The Application of Digital Technologies and Artificial Intelligence in Healthcare: An Overview on Nutrition Assessment. *Diseases* [Internet]. 2023 Sep 1 [cited 2025 Dec 13];11(3). Available from: <https://pubmed.ncbi.nlm.nih.gov/37489449/>
30. Papathanail, I.; Brühlmann, J.; Vasiloglou, M.F.; Stathopoulou, T.; Exadaktylos, A.K.; Stanga, Z.; Münzer, T.; Mougiakakou, S. Evaluation of a Novel Artificial Intelligence System to Monitor and Assess Energy and Macronutrient Intake in Hospitalised Older Patients. *Nutrients* 2021, 13, 4539.
31. Morgenstern, J.D.; Rosella, L.C.; Costa, A.P.; Anderson, L.N. Development of machine learning prediction models to explore nutrients predictive of cardiovascular disease using Canadian linked population-based data. *Appl. Physiol. Nutr. Metab. Physiol. Appl. Nutr. Metab.* 2022, 47, 529–546.
32. Maher, C.A.; Davis, C.R.; Curtis, R.G.; Short, C.E.; Murphy, K.J. A Physical Activity and Diet Program Delivered by Artificially Intelligent Virtual Health Coach: Proof-of-Concept Study. *JMIR Mhealth Uhealth* 2020, 8, e17558.
33. Sosa-Holwerda A, Park OH, Kembra Albracht-Schulte, Surya Niraula, Thompson L, Wilna Oldewage-Theron. The Role of Artificial Intelligence in Nutrition Research: A Scoping Review. *Nutrients* [Internet]. 2024 Jun 28;16(13):2066–6. Available from: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11243505/>
34. Niszczoła, P.; Rybicka, I. The credibility of dietary advice formulated by ChatGPT: Robo-diets for people with food allergies. *Nutrition* 2023, 112, 112076.
35. Sun, H.; Zhang, K.; Lan, W.; Gu, Q.; Jiang, G.; Yang, X.; Qin, W.; Han, D. An AI Dietitian for Type 2 Diabetes Mellitus Management Based on Large Language and Image Recognition Models: Preclinical Concept Validation Study. *J. Med. Internet Res.* 2023, 25, e51300.
36. Oh, Y.J.; Zhang, J.; Fang, M.L.; Fukuoka, Y. A systematic review of artificial intelligence chatbots for promoting physical activity, healthy diet, and weight loss. *Int. J. Behav. Nutr. Phys. Act.* 2021, 18, 160.