

Pokročilé systémy počítačového vidění a robotiky v precizním zelinářství: Technologická analýza, evoluce a budoucí směry

1. Úvod: Strukturální transformace zemědělství a imperativ automatizace

Současný globální zemědělský sektor se nachází v kritickém bodě zlomu, který je definován konvergencí demografických tlaků, environmentálních limitů a technologických možností. Projekce Organizace spojených národů naznačují, že do roku 2050 světová populace překročí hranici 10 miliard lidí, což vyvolá potřebu zvýšit globální produkci potravin o 50 % oproti současnému stavu.¹ Tento imperativ naráží na fyzické limity planety a zejména na akutní nedostatek lidského kapitálu v primárním sektoru. V rozvinutých ekonomikách, jako jsou Spojené státy americké, pracuje v zemědělství méně než 2 % populace a predikce růstu zaměstnanosti v tomto odvětví stagnují na úrovni 1 % pro dekádu 2019–2029.¹ Tato diskrepance mezi rostoucí poptávkou po potravinách a klesající dostupností pracovní síly vytváří bezprecedentní tlak na automatizaci procesů.

Tradiční model extenzivního zemědělství, založený na uniformním ošetřování velkých ploch, naráží na limity udržitelnosti a efektivity. Odpovědí na tyto výzvy je koncept **Zemědělství 4.0** (Smart Agriculture), který představuje paradigmatický posun od mechanizace k digitalizaci a automatizaci. Jádrem této revoluce není pouhé nahrazení svalové síly stroji, ale nahrazení lidského smyslového vnímání a kognitivního rozhodování umělou inteligencí (AI). Klíčovou technologií, která tento přechod umožňuje, je **počítačové vidění (Computer Vision - CV)**. Zemědělci, kteří po staletí využívali své smysly k hodnocení stavu plodin, nyní musí rozšířit své schopnosti pomocí senzorů, které jim umožní "vidět" za hranice lidského oka a spravovat pole s miliony rostlin na úrovni individuální péče.¹

Tato výzkumná zpráva se specificky zaměřuje na aplikaci pokročilých systémů počítačového vidění v oblasti pěstování zeleniny (specialty crops). Na rozdíl od polních plodin, jako je pšenice nebo kukuřice, je prostředí zelinářství charakteristické vysokou mírou nestrukturovanosti, biologické variability a nutností jemné manipulace s křehkými produkty. Zpráva syntetizuje poznatky z více než 130 technických zdrojů a analyzuje technologický vývoj od tradičních metod zpracování obrazu až po nejnovější architektury hlubokého učení, jako jsou Vision Transformers a základní modely (Foundation Models), v kontextu let 2024 a 2025.

1.1 Ekonomické a socio-technické determinanty robotizace

Nasazení robotických systémů v zelinářství není motivováno pouze technologickým pokrokem, ale především tvrdými ekonomickými daty. Analýzy nákladů a přínosů (Cost-Benefit Analysis) robotických systémů, jako jsou autonomní plečky nebo sklízecí roboty, ukazují, že navzdory vysokým počátečním kapitálovým výdajům (CAPEX) dochází k výraznému snížení provozních nákladů (OPEX). Studie z francouzských vinic a dánských řepných polí prokázaly, že autonomní systémy mohou snížit spotřebu herbicidů až o 90 % díky preciznímu bodovému postřiku (spot spraying) nebo jejich úplné náhradě mechanickou či laserovou likvidací.² V kontextu pěstování zeleniny, kde manuální plení a sklizeň představují největší nákladovou položku, nabízí technologie jako **Stout Smart Cultivator** snížení mzdových nákladů na plení až o 96 %.⁴

Ekonomická proveditelnost je však silně závislá na intenzitě využívání strojů. Zatímco u vysoce hodnotných plodin (high-value crops) je návratnost investice (ROI) atraktivní, u komoditních plodin s nižší marží je adopce pomalejší. Klíčovým faktorem je zde také spolehlivost a rychlost detekce. Systémy, které nedosahují alespoň 95% přesnosti detekce plevelů v reálném čase, nejsou komerčně životaschopné, protože riziko poškození plodiny převyšuje úspory na pracovní síle.⁵

2. Teoretický rámec a evoluce algoritmů počítačového vidění

Historie aplikace počítačového vidění v zemědělství je příběhem postupného přechodu od rigidních, pravidly svázaných systémů k flexibilním, daty řízeným modelům umělé inteligence. Tento vývoj lze rozdělit do tří distinktivních fází, které se v současné praxi často prolínají.

2.1 Éra tradičního zpracování obrazu a extrakce příznaků

V počátcích automatizace zemědělství se spoléhalo na techniky klasického zpracování obrazu (Digital Image Processing - DIP). Tyto metody byly založeny na předpokladu, že cílové objekty (plodiny) lze odlišit od pozadí (půda, plevel) pomocí explicitně definovaných pravidel.

- **Segmentace na základě barvy:** Nejrozšířenější metodou bylo využití barevných indexů, jako je ExG (Excess Green), který zvýrazňuje zelenou složku obrazu a potlačuje červenou a modrou. Prahováním tohoto indexu bylo možné oddělit vegetaci od půdy. Další přístupy využívaly transformace do barevných prostorů jako HSV nebo OHTA, které jsou méně citlivé na změny intenzity osvětlení než standardní RGB prostor.⁶
- **Morfologické operace:** Pro analýzu tvaru listů nebo plodů se využívaly operace eroze a dilatace, detekce hran (Canny, Sobel) a Houghova transformace pro detekci kruhových tvarů (např. rajčata, citrusy).
- **Limity tradičních metod:** Ačkoli byly tyto algoritmy výpočetně nenáročné a snadno implementovatelné na starším hardwaru, selhávaly v reálných polních podmínkách. Jejich

hlavní slabinou byla neschopnost generalizace. Změna světelných podmínek (zataženo vs. slunečno), vrhání stínů nebo překryv listů vedly k dramatickému poklesu přesnosti. Kvantitativní srovnání ukazují, že v komplexních scénářích (např. plevel v řádku plodiny) dosahovaly tradiční metody přesnosti (accuracy) stěží 70–80 %, což je pro autonomní systémy nedostatečné.⁷

2.2 Revoluce Hlubokého učení (Deep Learning) a architektury CNN

Nástup hlubokých konvolučních neuronových sítí (CNN) po roce 2012 znamenal pro zemědělskou robotiku koperníkovský obrat. Namísto ručního definování toho, jak vypadá list ("je zelený a má oválný tvar"), se neuronová síť učí tyto charakteristiky sama z velkého množství anotovaných dat.

2.2.1 Detekce objektů: Dominance rodiny YOLO

V oblasti detekce v reálném čase (Real-Time Object Detection) se de facto standardem staly algoritmy rodiny **YOLO (You Only Look Once)**. Na rozdíl od dvoufázových detektorů (two-stage detectors) jako Faster R-CNN, které nejprve generují návrhy regionů a poté je klasifikují, YOLO zpracovává obraz v jediném průchodu sítí. To přináší zásadní výhodu v rychlosti inference, která je kritická pro roboty pohybující se po poli.

Vývoj v letech 2024–2025 přinesl verze **YOLOv8** a **YOLOv10**, které integrují pokročilé mechanismy pro zlepšení přesnosti na malých objektech (typický problém při detekci plevelů v rané fázi růstu):

- **Architektura:** YOLOv8 využívá C2f moduly v páteřní síti (backbone), které zlepšují tok gradientů a extrakci příznaků. Důležitým posunem je přechod na "anchor-free" detekci, což eliminuje nutnost ručního ladění kotevních boxů (anchor boxes) pro různé typy plodin.⁹
- **Výkonnost:** Experimentální validace na datasetu chorob zeleniny (15 000 snímků) ukázala, že model YOLOv8 dosahuje střední průměrné přesnosti (**mAP@0.5**) na úrovni **95,6 %**, což představuje zlepšení o 6,4 procentního bodu oproti předchozím baseline modelům. Inferenční čas se pohybuje kolem **18,6 ms** na snímek, což umožňuje zpracování videa rychlostí přes 50 FPS.⁹ Srovnávací studie potvrzují, že řada YOLO překonává Faster R-CNN v rychlosti, aniž by docházelo k významné ztrátě přesnosti, což ji činí ideální pro nasazení na edge zařízeních.¹¹

2.2.2 Instanční segmentace (Instance Segmentation)

Pro úlohy vyžadující přesnou lokalizaci a manipulaci (např. uchopení plodu) nestačí objekt pouze orámovat (bounding box). Je nutné klasifikovat každý pixel obrazu. Architektury jako **Mask R-CNN** a nověji **YOLOv8-seg** umožňují přesnou segmentaci instancí, což je klíčové pro oddělení překrývajících se plodů a identifikaci stopky (peduncle) pro bezpečný řez.¹²

2.3 Nástup Vision Transformers (ViT) a Základních modelů

Zatímco CNN dominovaly poslední dekadě, roky 2024 a 2025 jsou ve znamení nástupu architektur založených na **Transformerech** (původně vyvinutých pro zpracování jazyka) a tzv. **Foundation Models**.

2.3.1 Vision Transformers (ViT) v zemědělství

CNN mají ze své podstaty omezené receptivní pole (receptive field), což znamená, že se soustředí primárně na lokální textury a tvary. Vision Transformers naproti tomu rozdělují obraz na sekvenci "patchů" a využívají mechanismus **Self-Attention** k modelování globálních vztahů mezi nimi.

- **Aplikace:** Tato schopnost "vidět celek" je neocenitelná při detekci chorob, kde příznaky mohou být rozptýřeny po celé rostlině v subtilních vzorech. Studie ukazují, že modely kombinující ViT s mechanismem "Mixture of Experts" (MoE) dosahují o **20 % vyšší přesnosti** než standardní ViT a prokazují výrazně lepší generalizaci při přenosu mezi doménami (např. trénink na laboratorních datech a testování na poli).¹³
- **Srovnání:** Na klasifikačních úlohách multispektrálních snímků dosahují ViT modely přesnosti přes 93 %, čímž překonávají tradiční CNN architektury jako ResNet nebo EfficientNet.¹⁵

2.3.2 Segment Anything Model (SAM) a Generativní AI

Revolučním krokem je adaptace modelu **SAM (Segment Anything Model)** od společnosti Meta. SAM je tzv. "promptable segmentation system", který dokáže segmentovat jakýkoli objekt na základě bodu nebo textového promptu, aniž by na něj byl explicitně trénován (zero-shot learning).

- **Adaptace:** Pro specifické zemědělské úlohy, jako je segmentace hustého porostu, však základní SAM často selhává. Výzkum se proto soustředí na vývoj adaptérů (např. **SAM-Agri** nebo **SAMConvFormer**), které integrují doménově specifické znalosti do architektury SAM.¹⁶
- **Výsledky:** Využití SAM jako prvního kroku v detekčních pipelinech zvyšuje přesnost následné klasifikace chorob o přibližně 10 %.¹⁸ Generativní modely (GenAI) a multimodální LLM (Large Language Models) otevírají cestu k systémům, které umožní farmářům komunikovat s roboty přirozeným jazykem a získávat komplexní analytické zprávy.¹⁹

2.4 Kvantitativní srovnání přístupů

Následující tabulka shrnuje klíčové rozdíly mezi diskutovanými přístupy v kontextu zemědělské robotiky:

Parametr	Tradiční CV (DIP)	Hluboké učení	Vision Transformers	Foundation Models (SAM)
----------	-------------------	---------------	---------------------	-------------------------

		(CNN/YOLO)	(ViT)	
Mechanismus učení	Ruční definice pravidel	Učení z dat (lokální příznaky)	Učení z dat (globální kontext)	Zero-shot / Few-shot
Závislost na datech	Minimální	Vysoká (tisíce snímků)	Extrémní (miliony snímků)	Předtrénováno (obří korpus)
Odolnost vůči změnám	Nízká (selhává při změně světla)	Vysoká (při dobré augmentaci)	Velmi vysoká (robustní)	Velmi vysoká
Výpočetní nároky	Zanedbatelné (CPU)	Střední (GPU Edge)	Vysoké (Server/High-end Edge)	Extrémní (vyžaduje optimalizaci)
Inferenční čas	< 5 ms	10–30 ms (YOLOv8)	50–200 ms	500+ ms (bez destilace)
Typická aplikace	Kontrolované osvětlení, třídění	Detekce plevelů, navigace	Klasifikace chorob, fenotypování	Interaktivní segmentace, anotace

3. Senzorická infrastruktura a multimodální fúze dat

Schopnost autonomního systému vnímat prostředí je determinována kvalitou a diversitou jeho senzorů. Moderní zemědělská robotika opouští paradigma "jedné kamery" a směřuje k multimodální fúzi dat, která kombinuje prostorové, spektrální a vizuální informace.

3.1 RGB a RGB-D: Základní stavební kameny

Standardní barevné (RGB) kamery jsou sice levné a dostupné, ale pro robotickou manipulaci postrádají kritickou dimenzi – hloubku. Bez informace o vzdálenosti nemůže robotické rameno bezpečně uchopit plod. Proto se standardem stávají **RGB-D** systémy, které poskytují barevný obraz (RGB) zarovnaný s hloubkovou mapou (Depth - D).

- **Stereo Vision:** Využívá dvě kamery k výpočtu hloubky na základě disparity (posunu) obrazu, podobně jako lidské oči. Je to pasivní metoda, která funguje dobře na slunci, ale selhává na površích bez textury (např. bílé stěny skleníků).²¹

- **Time-of-Flight (ToF) a Structured Light:** Aktivní metody (např. senzory v Microsoft Azure Kinect nebo Intel RealSense), které vysílají infračervené světlo a měří dobu letu paprsku nebo deformaci promítaného vzoru. Poskytují vysokou přesnost na krátkou vzdálenost, což je ideální pro navádění koncových efektorů (eye-in-hand).²²

3.2 LiDAR: Páteř autonomní navigace

Pro navigaci mobilních platforem v řádcích plodin je **LiDAR (Light Detection and Ranging)** nenahraditelný. Na rozdíl od kamer není závislý na okolním osvětlení (funguje v noci i na přímém protisvětle) a poskytuje přesnou 3D reprezentaci geometrie okolí.

- **Aplikace v praxi:** Společnost **Naïo Technologies**, přední výrobce zemědělských robotů (modely Oz, Orio, Ted), integruje 3D LiDARy pro detekci konce řádků, vyhýbání se překážkám a bezpečnostní certifikaci. LiDAR umožňuje robotům vytvářet mapu prostředí a lokalizovat se v ní s centimetrovou přesností, což je nezbytné pro mechanické plečkování, kde odchylka o pár centimetrů může zničit plodinu.²³

3.3 Hyperspektrální a multispektrální zobrazování (HSI/MSI)

Zatímco RGB a LiDAR vidí to, co vidí člověk (tvar a barvu), **hyperspektrální zobrazování** odhaluje chemické a fyziologické procesy uvnitř rostliny. HSI senzory snímají odražené světlo ve stovkách úzkých spektrálních pásem, pokrývajících viditelné (VIS), blízké infračervené (NIR) a krátkovlnné infračervené (SWIR) spektrum.

- **Princip:** Každá choroba, škůdce nebo fyziologický stres (sucho) mění buněčnou strukturu a obsah vody v listech, což se projeví změnou odrazivosti v specifických vlnových délkách (spektrální signatura). Například plíseň bramborová (*Phytophthora infestans*) je detekovatelná v pásmech 556 nm a 709 nm dříve, než jsou viditelné symptomy.²⁵
- **Využití:** HSI se využívá pro nedestruktivní hodnocení kvality (cukernatost, vnitřní hniloba) a včasnou detekci chorob. Výzvou zůstává obrovský objem dat (hyperspektrální kostky) a nutnost redukce dimenzionality (např. pomocí PCA nebo 3D-CNN) pro zpracování v reálném čase.²⁶

3.4 Senzorová fúze

Kombinace těchto modalit je klíčem k robustnosti. Algoritmy fúze dat (např. Kalmanovy filtry nebo moderní neuronové sítě pro fúzi) integrují data z LiDARu (geometrie), RGB kamery (textura) a HSI (chemie). Příkladem je systém **Stout Smart Cultivator**, který využívá fúzi vizuálních dat a vlastní AI model k rozlišení plodiny od plevelu a řízení mechanických čepelí.⁴

4. Výpočetní hardware a Edge Computing

Zpracování dat z výše uvedených senzorů generuje obrovské datové toky (v řádu gigabitů za sekundu). Vzhledem k tomu, že zemědělské oblasti často postrádají spolehlivé

vysokorychlostní připojení (5G), musí zpracování probíhat přímo na robotu – na hraně sítě (**Edge Computing**).

4.1 Dominance platformy NVIDIA Jetson

V letech 2024–2025 se platforma **NVIDIA Jetson** stala de facto standardem pro vestavěnou AI v robotice.

- **Jetson AGX Orin:** Tento modul představuje vrchol současné nabídky pro mobilní robotiku. S výkonem až **275 TOPS** (trillions of operations per second) a architekturou GPU Ampere (2048 jader) přináší výkon serverové třídy do kompaktního, energeticky efektivního balení (spotřeba 15–60 W).
- **Význam pro zelinářství:** Tento výkon je kritický pro běh moderních modelů jako Vision Transformers nebo YOLOv8 v reálném čase. AGX Orin poskytuje až 8x vyšší výkon než předchozí generace (Xavier), což umožňuje robotům zpracovávat simultánně více video streamů (např. z 6 kamer pro 360° rozhled) a provádět komplexní úkony jako SLAM, detekci a plánování pohybu současně.²⁹

4.2 Alternativní architektury

Kromě GPU se v specifických aplikacích uplatňují i jiné akcelerátory:

- **FPGA (Field-Programmable Gate Arrays):** Například Xilinx Kria. Nabízejí extrémně nízkou latenci a deterministické zpracování, což je vhodné pro řízení motorů a předzpracování signálu ze senzorů. Jejich nevýhodou je složitější vývoj.³¹
- **TPU (Tensor Processing Units):** Google Coral Edge TPU. Poskytují vysokou efektivitu na watt pro inferenci modelů TensorFlow Lite, vhodné pro lehčí úlohy (např. detekce přítomnosti plodu) s minimální spotřebou energie.³¹

5. Aplikace I: Robotická sklizeň a manipulace

Robotická sklizeň (Robotic Harvesting) je technologicky nejnáročnější disciplínou v precizním zelinářství. Vyžaduje bezchybnou koordinaci mezi viděním, plánováním pohybu a fyzickou interakcí.

5.1 Výzva detekce stopky (Peduncle Detection)

Pro většinu plodové zeleniny (rajčata, papriky, lilky, okurky) nestačí detekovat pouze plod. Robot musí identifikovat **stopku (peduncle)** a přesně lokalizovat bod řezu (cutting point). Pokud by robot zatáhl za plod, mohl by vytrhnout celou rostlinu nebo poškodit plod v místě úponu, což vede k hnilobě.

- **Řešení:** Moderní algoritmy využívají pokročilou instanční segmentaci (YOLOv8-seg, Mask R-CNN) k oddělení plodu, stopky a hlavního stonku. Výzkum se zaměřuje na řešení variability orientace stopky a její vizuální podobnosti se stonkem. Úspěšnost lokalizace bodu řezu se pohybuje kolem 75–85 %, což je stále oblast vyžadující zlepšení pro plně

autonomní provoz.³²

5.2 Vizuální servořízení (Visual Servoing) a Aktivní percepce

Navedení koncového efektoru k cíli probíhá v uzavřené smyčce zvané vizuální servořízení.

- **Eye-in-Hand:** Kamera je umístěna přímo na robotickém rameni. Jak se rameno přibližuje k plodu, zvyšuje se rozlišení a přesnost zaměření.
- **Aktivní percepce (Active Perception):** V hustém porostu jsou plody často skryty (okluze). Robotické systémy nové generace nejsou pasivními pozorovateli. Pokud systém detekuje částečnou okluzi, naplánuje pohyb kamery do nového úhlu (Viewpoint Planning) nebo dokonce využije rameno k jemnému odsunutí listů. Experimentální robot pro sklizeň jahod z Washington State University využívá kombinaci silikonových prstů a proudy vzduchu k odhalení skrytých plodů, čímž zvyšuje úspěšnost detekce na 93 %.²²

5.3 Měkká robotika a fúze taktilních dat

Zelenina je měkká a snadno se poškodí. Tradiční rigidní chapadla jsou nahrazována **měkkou robotikou (Soft Robotics)**.

- **Soft Grippers:** Využívají poddajné materiály (silikon) a pneumatický nebo hydraulický pohon k jemnému obejmutí plodu. Tvarově se přizpůsobí variabilitě zeleniny.³⁸
- **Vizuálně-taktilní fúze:** Samotný zrak nestačí k určení, jak pevně plod držet. Moderní senzory, jako je **FingerVision**, kombinují kameru uvnitř průhledné silikonové kůže chapadla. To umožňuje robotu "vidět" texturu a deformaci povrchu plodu při dotyku (taktilní zpětná vazba) a upravit sílu stisku v reálném čase, aby nedošlo k pohmoždění. Fúze vizuálních a taktilních dat také pomáhá při odhadu zralosti (tvrdosti) plodu.³⁹

6. Aplikace II: Precizní ochrana a fenotypování

6.1 Revoluce v likvidaci plevelů (Weeding)

Zatímco sklizeň je stále ve fázi rané komercializace, automatizované plení je již plně komerčně dostupné a transformuje ekonomiku farem.

- **Laserové plení (Laser Weeding):** Průkopníkem je společnost **Carbon Robotics** se strojem **LaserWeeder**. Tento systém využívá 42 kamer s vysokým rozlišením a palubní superpočítač k identifikaci plevelů v reálném čase. Následně CO2 lasery s sub-milimetrovou přesností zacílí na meristém (růstový vrchol) plevelu a tepelně ho zničí. Systém eliminuje až 5 000 plevelů za minutu s 99% přesností, bez použití chemie a bez narušení půdy.⁴¹
- **Mechanická kultivace:** Společnost **Stout Industrial Technology** vyvinula **Smart Cultivator**, který využívá AI k řízení mechanických čepelí. Systém "True Vision" rozlišuje plodinu od plevelu a aktivně navádí čepele kolem rostlin. Jeden stroj nahradí práci 25 lidí.⁴

6.2 3D Rekonstrukce a Fenotypování

Pro šlechtění a detailní monitoring růstu se využívají pokročilé metody 3D rekonstrukce.

- **NeRF vs. 3D Gaussian Splatting:** Tradiční fotogrammetrie je nahrazována neuronovými sítěmi. **NeRF (Neural Radiance Fields)** umožňuje vysoce detailní rekonstrukci rostlin, ale je výpočetně náročná. Novější technologie **3D Gaussian Splatting (3DGS)** (2024) přináší revoluci v rychlosti – umožňuje renderování fotorealistických 3D modelů rostlin v reálném čase. To otevírá cestu k automatizovanému měření objemu biomasy, počítání plodů a analýze architektury rostlin s nebývalou přesností.⁴⁶

7. Datová výzva: Nedostatek dat a simulace

Klíčovou bariérou pro vývoj robustních AI modelů je nedostatek kvalitních anotovaných dat (Data Scarcity). Získat miliony snímků specifické choroby nebo plevelů v různých fázích růstu a světelných podmínkách je v reálném světě téměř nemožné.

7.1 Veřejné datasety a jejich limity

Existují snahy o vytvoření veřejných benchmarků, jako je **Vegetable Image Dataset** z Bangladéše (4319 snímků, 22 tříd zeleniny) nebo datasety z PlantVillage.⁴⁹ Tyto databáze jsou však často omezené rozsahem, variabilitou pozadí nebo kvalitou anotací. Nevyváženost tříd (mnoho zdravých listů, málo nemocných) vede k biasu modelů.⁵¹

7.2 Syntetická data a Sim-to-Real Transfer

Řešením je generování syntetických dat. Platformy jako **NVIDIA Isaac Sim** využívají technologii **Replicator** k procedurálnímu generování fotorealistických trénovacích dat. Vývojáři mohou ve virtuálním prostředí simulovat nekonečné množství variací – měnit polohu slunce, texturu půdy, hustotu plevelů či stupeň okluze.

- **Domain Randomization:** Klíčovou technikou je doménová randomizace, která "zmate" model nerealistickými variacemi v simulaci (např. fialové nebe), což paradoxně nutí neuronovou síť soustředit se na podstatné tvarové rysy objektu. To usnadňuje přenos naučeného modelu ze simulace do reality (Sim-to-Real), kde se robot setká s podmínkami, které nikdy předtím neviděl.⁵²

8. Závěr a strategický výhled

Technologický vývoj v oblasti počítačového vidění pro zemědělskou robotiku dosáhl v polovině dekády bodu zlomu. Přechod od heuristických algoritmů k robustním hlubokým neuronovým sítím a Foundation Models, podpořený výkonným edge hardwarem, umožňuje vznik strojů, které již nejsou jen akademickými kuriozitami, ale ekonomicky nutnými nástroji pro přežití farem.

Klíčové trendy pro budoucnost (2025–2030):

1. **Multimodalita:** Roboti budou běžně kombinovat vidění, hmat a spektrální analýzu v jednom rozhodovacím procesu.
2. **Swarm Robotics:** Posun od velkých strojů k flotilám menších, kooperujících robotů, kteří si sdílejí poznatky o prostředí.
3. **Human-Robot Interaction:** Díky generativní AI a vizuálně-jazykovým modelům budou farmáři moci úkolovat roboty přirozenou řečí a dostávat od nich srozumitelné reporty.

Zemědělská robotika tak přestává být pouhou náhradou lidské práce a stává se nástrojem precizní péče, který umožňuje produkovat více potravin s menšími vstupy a dopadem na životní prostředí.

Citovaná díla

1. How computer vision increases productivity and sustainability in agriculture, použito ledna 15, 2026, <https://www.therobotreport.com/how-computer-vision-increases-productivity-and-sustainability-in-agriculture/>
2. Workshop proceedings template - AgEcon Search, použito ledna 15, 2026, <https://ageconsearch.umn.edu/record/344214/files/Cost%20benefit%20analysis%20of%20robotic%20weeding%20in%20vineyards%20-%20A%20case.pdf>
3. Precision Weed Control Using Unmanned Aerial Vehicles and Robots: Assessing Feasibility, Bottlenecks, and Recommendations for Scaling - MDPI, použito ledna 15, 2026, <https://www.mdpi.com/2813-477X/3/2/10>
4. Stout Industrial Technology – Machines that think, Machines that work, použito ledna 15, 2026, <https://www.stout.ai/>
5. Agricultural robots—System analysis and economic feasibility | Request PDF, použito ledna 15, 2026, https://www.researchgate.net/publication/225527407_Agricultural_robots-System_analysis_and_economic_feasibility
6. Fruit location and stem detection method for strawberry harvesting robot - ResearchGate, použito ledna 15, 2026, https://www.researchgate.net/publication/292682264_Fruit_location_and_stem_detection_method_for_strawberry_harvesting_robot
7. Deep Learning vs. Traditional Computer Vision - arXiv, použito ledna 15, 2026, <https://arxiv.org/pdf/1910.13796>
8. A Review of Computer Vision and Deep Learning Applications in Crop Growth Management, použito ledna 15, 2026, <https://www.mdpi.com/2076-3417/15/15/8438>
9. Intelligent deep learning architecture for precision vegetable disease detection advancing agricultural new quality productive forces - Frontiers, použito ledna 15, 2026, <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2025.1611865/full>

10. CMC | Free Full-Text | A Systematic Review of Deep Learning-Based Object Detection in Agriculture: Methods, Challenges, and Future Directions, použito ledna 15, 2026, <https://www.techscience.com/cmc/v84n1/61787/html>
11. Comparative performance of YOLOv8, YOLOv9, YOLOv10, YOLOv11 and Faster R-CNN models for detection of multiple weed species - ResearchGate, použito ledna 15, 2026, https://www.researchgate.net/publication/385691124_Comparative_performance_of_YOLOv8_YOLOv9_YOLOv10_YOLOv11_and_Faster_R-CNN_models_for_detection_of_multiple_weed_species
12. A review of visual perception technology for intelligent fruit harvesting robots - PMC, použito ledna 15, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12401999/>
13. Plant disease classification in the wild using vision transformers and mixture of experts, použito ledna 15, 2026, <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2025.1522985/full>
14. Plant disease classification in the wild using vision transformers and mixture of experts - NIH, použito ledna 15, 2026, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12213485/>
15. Plant Disease Detection using Vision Transformers on Multispectral Natural Environment Images - IEEE Xplore, použito ledna 15, 2026, <https://ieeexplore.ieee.org/document/10220517/>
16. liliu-avril/Awesome-Segment-Anything: This repository is for the first comprehensive survey on Meta AI's Segment Anything Model (SAM). - GitHub, použito ledna 15, 2026, <https://github.com/liliu-avril/Awesome-Segment-Anything>
17. Computer Vision in Agriculture: 2025 Landscape - Voxel 51, použito ledna 15, 2026, <https://voxel51.com/blog/computer-vision-in-agriculture-2025>
18. EMSAM: enhanced multi-scale segment anything model for leaf disease segmentation - Frontiers, použito ledna 15, 2026, <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2025.1564079/full>
19. Computer Vision Meets Generative Models in Agriculture: Technological Advances, Challenges and Opportunities - MDPI, použito ledna 15, 2026, <https://www.mdpi.com/2076-3417/15/14/7663>
20. (PDF) Computer Vision Meets Generative Models in Agriculture: Technological Advances, Challenges and Opportunities - ResearchGate, použito ledna 15, 2026, https://www.researchgate.net/publication/393508385_Computer_Vision_Meets_Generative_Models_in_Agriculture_Technological_Advances_Challenges_and_Opportunities
21. RGB-D datasets for robotic perception in site-specific agricultural operations—A survey - Diva-portal.org, použito ledna 15, 2026, <https://www.diva-portal.org/smash/get/diva2:1789608/FULLTEXT01.pdf>
22. Occlusion Handling by Pushing for Enhanced Fruit Detection - IEEE Xplore, použito ledna 15, 2026, <https://ieeexplore.ieee.org/document/10802174/>
23. 100th Oz robot sent into farm fields - Naïo Technologies, použito ledna 15, 2026, <https://www.naio-technologies.com/en/news/100th-oz-robot-sent-into-farm-fiel>

[ds/](#)

24. LiDAR technology gives Naïo robots lay of the land - SICK, použito ledna 15, 2026, <https://www.sick.com/fr/en/sick-sensor-blog/lidar-technology-gives-naio-robots-lay-of-the-land/w/blog-autonomous-tractor-farming-lidar>
25. Cucumber powdery mildew detection using hyperspectral data, použito ledna 15, 2026, <https://cdnsiencepub.com/doi/10.1139/cjps-2021-0148>
26. Advances in Hyperspectral Imaging Technology for Grain Quality and Safety Detection: A Review - MDPI, použito ledna 15, 2026, <https://www.mdpi.com/2304-8158/14/17/2977>
27. Hyperspectral Imaging and Deep Learning for Quality and Safety Inspection of Fruits and Vegetables: A Review | Journal of Agricultural and Food Chemistry - ACS Publications, použito ledna 15, 2026, <https://pubs.acs.org/doi/10.1021/acs.jafc.4c11492>
28. Hyperspectral Sensing of Plant Diseases: Principle and Methods - MDPI, použito ledna 15, 2026, <https://www.mdpi.com/2073-4395/12/6/1451>
29. Jetson AGX Orin for Next-Gen Robotics - NVIDIA, použito ledna 15, 2026, <https://www.nvidia.com/en-us/autonomous-machines/embedded-systems/jetson-orin/>
30. Top 10 Edge AI Hardware for 2025 - Jaycon Systems, použito ledna 15, 2026, <https://www.jaycon.com/top-10-edge-ai-hardware-for-2025/>
31. How to Choose the Best Edge AI Platform: Jetson, Kria, Coral and Others - Promwad, použito ledna 15, 2026, <https://promwad.com/news/choose-edge-ai-platform-jetson-kria-coral-2025>
32. Harvesting Robots for High-value Crops: State-of-the-art Review and Challenges Ahead, použito ledna 15, 2026, <https://research.wur.nl/en/publications/harvesting-robots-for-high-value-crops-state-of-the-art-review-an/>
33. Precision citrus segmentation and stem picking point localization using improved YOLOv8n-seg algorithm - Frontiers, použito ledna 15, 2026, <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2025.1655093/full>
34. A review of visual perception technology for intelligent fruit harvesting robots - Frontiers, použito ledna 15, 2026, <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2025.1646871/full>
35. Research Progress and Development Trend of Visual Detection Methods for Selective Fruit Harvesting Robots - MDPI, použito ledna 15, 2026, <https://www.mdpi.com/2073-4395/15/8/1926>
36. Researchers design robot that can pick hidden strawberries - WSU Insider, použito ledna 15, 2026, <https://news.wsu.edu/press-release/2025/09/04/researchers-design-robot-that-can-pick-hidden-strawberries/>
37. Enhanced View Planning for Robotic Harvesting: Tackling Occlusions with Imitation Learning - arXiv, použito ledna 15, 2026, <https://arxiv.org/html/2503.10334v1>

38. Application of Soft Grippers in the Field of Agricultural Harvesting: A Review - MDPI, použito ledna 15, 2026, <https://www.mdpi.com/2075-1702/13/1/55>
39. Vegetable Harvesting Robot Utilizing Visual-Tactile Handling Introduced in Plant Factory, použito ledna 15, 2026, <https://www.fingervision.jp/en/post/pr20251105>
40. A framework for the fusion of visual and tactile modalities for improving robot perception, použito ledna 15, 2026, https://www.researchgate.net/publication/310899258_A_framework_for_the_fusion_of_visual_and_tactile_modalities_for_improving_robot_perception
41. Technology | Innovate with Us - Carbon Robotics, použito ledna 15, 2026, <https://carbonrobotics.com/laserweeding-technology>
42. Carbon Robotics: First & Only Commercial LaserWeeder™, použito ledna 15, 2026, <https://carbonrobotics.com/>
43. Laser Weeding | Enhance Your Yield - Carbon Robotics, použito ledna 15, 2026, <https://carbonrobotics.com/laserweeding>
44. Stout Smart Cultivator - FIRA USA, použito ledna 15, 2026, <https://fira-usa.com/robots/stout-smart-cultivator/>
45. Stout Agtech offers smart cultivation powered by AI - The Robot Report, použito ledna 15, 2026, <https://www.therobotreport.com/stout-agtech-offers-smart-cultivation-powered-by-ai/>
46. A survey on 3D reconstruction techniques in plant phenotyping: from classical methods to neural radiance fields (NeRF), 3D Gaussian splatting (3DGS), and beyond - SPIE Digital Library, použito ledna 15, 2026, <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/13475/134750B/A-survey-on-3D-reconstruction-techniques-in-plant-phenotyping/10.1117/12.3054384.full>
47. Wheat3DGS: In-field 3D Reconstruction, Instance Segmentation and Phenotyping of Wheat Heads with Gaussian Splatting - arXiv, použito ledna 15, 2026, <https://arxiv.org/html/2504.06978v1>
48. 3D Reconstruction in Plant Phenotyping - GitHub, použito ledna 15, 2026, <https://github.com/JiajiaLi04/3D-Reconstruction-Plants>
49. Vegetable Image Dataset for Classification Models: A Bangladeshi Perspective - Mendeley Data, použito ledna 15, 2026, <https://data.mendeley.com/datasets/b9rvq4f2st/4>
50. (PDF) Smartphone-Based Multi-Criteria Vegetable Object Detection Dataset from Bangladesh - ResearchGate, použito ledna 15, 2026, https://www.researchgate.net/publication/397749860_Smartphone-Based_Multi-Criteria_Vegetable_Object_Detection_Dataset_from_Bangladesh
51. Top 4 Computer Vision Problems & Solutions in Agriculture — Part 2, použito ledna 15, 2026, <https://www.edge-ai-vision.com/2024/11/top-4-computer-vision-problems-solutions-in-agriculture-part-2/>
52. Synthetic Data Generation for Perception Model Training in Isaac Sim, použito ledna 15, 2026, <https://docs.nvidia.com/learning/physical-ai/getting-started-with-isaac-sim/latest>

</synthetic-data-generation-for-perception-model-training-in-isaac-sim/index.html>

53. Isaac Sim - Robotics Simulation and Synthetic Data Generation | NVIDIA Developer, použito ledna 15, 2026, <https://developer.nvidia.com/isaac/sim>
54. Expedite Robotics with AI-Powered Synthetic Data Generation | SoftServe, použito ledna 15, 2026, <https://www.softserveinc.com/en-us/blog/ai-powered-synthetic-data-for-robotics>