

# Umělá inteligence v zemědělství

## Precision agriculture

Václav Sobotka

3. prosince 2019

## 1 Abstrakt

Práce se zabývá zapojením uměle inteligentních systémů, respektive technologií vnímaných jako formu umělé inteligence, v prostředí zemědělství.

V první části práce bude představen pojem *precision agriculture*, jeho stručná historie a dále problematiky, kterých se dotýká. Následně budou krátce diskutovány dopady nasazení pokročilých technologií v zemědělství, a to jak z pohledu současných výsledků v oboru, tak ze strany jeho budoucích potřeb.

Druhá část práce bude věnována konkrétním existujícím projektům, technologiím a aplikacím z oblasti *precision agriculture*. Důraz bude kladen především na uměle inteligentní prvky systémů a na standardní postupy uplatňované při implementaci řešení pro popisované problémy.

## 2 Precision agriculture

Pojem *precision agriculture* (dále jen PA) obecně označuje (stejně tak jako pojmy *satellite farming*, *site specific crop management* nebo *precision farming*) přístup k procesu zemědělské produkce. Termín jako takový je definován poměrně vágně, je tak příhodnější ho představit souborem jeho klíčových charakteristik.

### 2.1 Charakteristické znaky PA

Nejvýraznějším rysem PA je zapojení moderní technologie (a to především výpočetní techniky) do všech fází zemědělské činnosti za účelem zvýšení výnosů (popř. i snížení zbytečné ekologické zátěže prostředí) [Sch]. Následně jsou takto zapojené technologie využívány k tomu, aby potřebné zásahy (zavlažování, hnojení, aplikace pesticidních nebo herbicidních látek atp.) probíhaly co možná nejcíleněji - a to jak ve smyslu místa, času, tak i rozsahu (odtud *precision agriculture* a *site specific crop management*).

Konkrétněji je pro PA typický průběžný sběr a následné zpracování dat o půdě a samotných pěstovaných rostlinách. Sběr dat probíhá snímáním polí satelity (odtud *satellite farming*) nebo drony, detailní informace o půdě (vlhkost, pH faktor, teplota, množství živin...) se průběžně získávají pomocí k tomu určených senzorů [soi]. Takto získané informace slouží ke zmiňovanému cílení zásahů nebo ke zefektivnění celkového zemědělského procesu (např. výběr vhodných plodin pro osev nebo vytipování nejvhodnější doby pro sklizeň).

Druhou velkou oblastí využití technologie v zemědělství jsou stroje, respektive zvyšování efektivity jejich práce. Typické aplikace v této oblasti se pak týkají problémů typu plánování logistiky přesunů zemědělských strojů mezi pozemky, asistenci řízení stroje při práci nebo dokonce plné automatizaci pro optimální pohyb (z hlediska omezení opakovaných průjezdů

stejným místem) stroje po poli. Výstupy těchto aplikací přichází typicky v podobě snížení nákladů za provoz techniky nebo snížením zátěže půdy [con].

## 2.2 Historie PA

Počátky PA sahají do druhé poloviny osmdesátých let v USA [MK15]. Navzdory tomu, že stěžejní principy a jejich výhody PA byly známy už v této době (cílené hnojení, zavlažování nebo analýza leteckých snímků), se tato koncepce zemědělství neprosadila do praxe tak rychle, jak by se dalo očekávat. Důvodem byla především nedostupnost a nerentabilita nasazení PA do běžného provozu [MK15]. Tento koncept tak zůstal až do začátku tisíciletí spíše v teoreticky-experimentální rovině. Zásadní impuls PA zaznamenává až v souvislosti se spuštěním systému GPS v celosvětovém měřítku v polovině devadesátých let (leden 1994) [gps]. To umožnilo komerční rozvoj PA technologií (systémy řízení zemědělských strojů na polích, půdní senzory lokalizované pomocí GPS...), čímž se začaly postupně stávat dostupnějšími.

## 2.3 Současnost a budoucnost PA

Prudký rozvoj technologií využívaných v PA - zejména pak zdokonalení a zvýšení dostupnosti výpočetní techniky - umožnil širší nasazení již dříve známých technik do praxe. Navzdory tomuto trendu ale nejsou ani zdaleka všechny výtobytky PA v současné době masově používány [LDE].

Poměrně hojného rozšíření se dočkaly zejména systémy na bázi GPS - např. asistenti řízení zemědělských strojů [LDE]. Ty jsou v dnešní době již poměrně dobře zavedené (i v ČR) a mnohdy dostupné v rámci standardní výbavy zemědělských strojů (např. traktory John Deere jsou běžně vybaveny systémy asistence řízení) . Hlavní roli v masovějším rozšiřování těchto technologií hraje fakt, že jsou zaváděny do běžné praxe jako inovace stávající zemědělské techniky. Zavedení výrobci tak můžou nové technologie zavádět snadněji, než kdyby se pokoušeli prodávat kompletně nové koncepty.

O poznání horší je už situace v oblasti technologií pro cílení zemědělských zásahů [LDE]. Navzdory podloženým a praxí ověřeným výhodám (výzkumy Johna Hummela 1985 [MK15]) je rozšířenost a povědomí mezi zemědělci obecně výrazně nižší než u technologií pro asistenci řízení strojů [EBB<sup>+</sup>19, s. 20]. Reálná rozšířenost (vzhledem k obdělávané ploše) se tak pohybuje okolo 20 % v zemích, které jsou v PA na světové špičce (USA, Kanada, Austrálie) [LDE]. V evropském zemědělství je rozšířenost ještě nižší, Francie jakožto evropský lídr dosahuje rozšířenosti technologií cílení mezi méně než 10 % zemědělských podniků.

Z výše zmiňovaného je jasné, že v současnosti není největší brzdou pro rozvoj PA nedostačující technologický pokrok, ale nedostatečná motivace na straně zemědělců, mnohdy i nízká informovanost o existujících možnostech. Právě motivací a mírou informovanosti ze intenzivně zabývají studie EU [CKR], respektive dlouhodobější evropské strategie pro zemědělství, které s PA do budoucna agrárního sektoru významně kalkulují. Tendence směřování zemědělství k širšímu zapojení PA je logická i z hlediska výzev, kterým bude sektor do budoucna čelit. Rostoucí populace a s ní související poptávka po potravinách, problém s omezenou plochou použitelnou pro pěstování plodin a pro zemědělství potenciálně nepříznivé klimatické podmínky jsou přesvědčivými důvody pro postupné zapojování PA do běžné praxe.

## 2.4 Rozdělení PA technologií

Technologie PA se dělí do třech hlavních podoblastí (viz ilustrace). Po řadě to jsou tzv. *guidance*, *recording* a *reacting* technologie. [EBB<sup>+</sup>19, s. 14]

Oblast guidance technologií se orientuje na systémy zjednodušující (*driver assistance*) nebo rovnou automatizující (*machine guidance*) pohyb zemědělských strojů po poli. Poslední v ilustraci zmíněný pojem – *controlled traffic farming* – svým způsobem zastřešuje předešlé dva pojmy – souhrnně označuje technologie, které minimalizují (nebo dokonce eliminují) opakované přejezdy zemědělské techniky po stejných místech na poli. Ty běžně vznikají v důsledku lidské nepřesnosti a mohou být omezeny právě nasazením asistenčních nebo rovnou samořídících systémů. To má za následek nejen snížení provozních nákladů za provoz strojů (např. díky snížení spotřeby paliva), ale také zmírnění dopadů těžké techniky na kvalitu (a to zejména propustnost) půdy [con].

Recording systémy se zaměřují na průběžný sběr dat - a to jak o půdě, tak o samotných rostlinách nebo o hustotě sklizně v jednotlivých částech pole. *Canopy sensing* systémy používají senzory instalované přímo na traktory, za pomoci kterých získávají informace o obsahu dusíkatých látek v jednotlivých rostlinách (senzory fungují na principu měření množství odražených paprsků od listů rostliny, z toho se dále vyvozují obsahy chlorofylu, které úzce souvisí hojností dusíkatých látek) [can]. Tyto informace je možné buďto přímo v reálném čase využívat - např. pro cílené hnojení bezprostředně po měření, nebo je možné je využít pro pozdější analýzu za účelem sestavování map úrodnosti půdy, přípravu plánu hnojení nebo predikci předpokládaného výnosu při sklizni. Pojmy *soil mapping* a *soil moisture sensing* jsou opět spjatý s vlastnostmi půdy. Soil moisture sensing se zaměřuje na kvalitu půdy v kontextu schopnosti přijímat a držet v sobě vodu, data se typicky získávají ze senzorů umístěných přímo v půdě. Soil mapping se zabývá sestavováním profilových map půdy v širším záběru - počínaje obsahem minerálů, přes velikost půdních částic až po živé složky půdy [EBB<sup>+</sup>19, s. 16]. Ze získávaných vzorků se mapy vytvářejí s využitím statisticky založených metod (např. ve formě strojového učení). Výsledné mapy následně slouží k lepšímu porozumění heterogenní povahy půdy a využití této znalosti ke zvýšení výnosů.

Poslední podoblastí PA jsou tzv. reacting technologie - ty také uzavírají pomyslný kruh konceptu PA. Za využití informací získaných z dat nasbíraných recording systémy a s dopomocí guidance technologií (polo)automatizovaného řízení zemědělské techniky je možné provádět cílené zemědělské zásahy. Technologie cílených zásahů se souhrnně označují jako *variable rate technologies* (dále jen VRT), přičemž zmiňované zásahy se týkají aplikace hnojiv, pesticidních a herbicidních látek na rostliny, zavlažování nebo procesu setby [EBB<sup>+</sup>19, s. 16]. Pokud je cílení opravdu přesné, vede ke snížení spotřeby zmiňovaných látek (z toho plyne i snížení ekologického dopadu jejich aplikace) a umožňuje maximální využití potenciálu půdy.

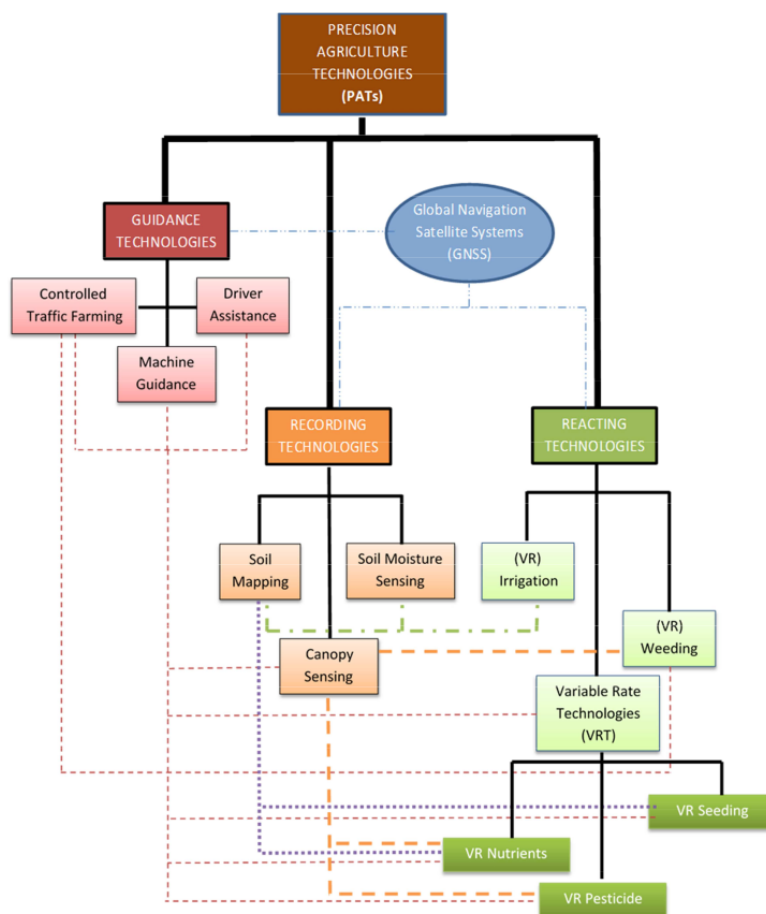
### 3 Aplikace umělé inteligence v rámci PA

Po obecnějším úvodu do problematiky a zasazení PA do širšího kontextu se bude práce soustředit na jednotlivé podoblasti PA technologií. Ty budou demonstrovány na příkladech současných aplikací s důrazem na přiblížení samotných uměle inteligentních prvků těchto technologií.

Je zjevné, že z technologického hlediska tvoří výpočetní technika (a s ní spjatý software - případná "umělá inteligence") jen část problematik PA. Aby bylo vůbec možné vytvářet "chytrou" zemědělskou techniku nebo analyzovat a sestavovat mapy kvality půdy, je zapotřebí značného množství elektrické a mechanické techniky (půdní senzory, dálkově říditelné drony, VRT zavlažovače atd.). Právě data získávaná skrze tento specializovaný hardware jsou naprostým základem jakékoli umělé inteligence v PA.

Prezentované technologie budou vždy krátce uvedeny, poté budou popsány jejich uměle inteligentní aspekty. Pokud půjde o obecnější koncept s široce používanými a osvědčenými postupy řešení, bude toto uvedeno, pokud bude diskutován komerční systém (u kterého se

Obrázek 1: Dělení technologií PA [EBB<sup>+</sup>19, s. 15]



implementační detaily obvykle dohledat nedají), bude předložen princip, na kterém systém pravděpodobně pracuje.

### 3.1 Umělá inteligence a guidance systémy

Guidance systémy budou představeny na příkladech produktů *AutoTrac* a *MachineSync* od firmy John Deere [aut] [mac].

#### 3.1.1 AutoTrac

AutoTrac je systém automatického řízení zemědělské techniky podporující controlled traffic farming (viz [Rozdělení PA technologií](#)). První prototypy systému vznikly v roce 1997 díky spolupráci John Deere s univerzitou ve Stanfordu [May]. AutoTrac je v prodeji od roku 2002, podle výrobce je 60 až 70 % půdy v Severní Americe obděláváno za pomoci AutoTrac nebo podobných technologií. V Austrálii má dosahovat rozšířenost až 90 % [May].

K analýze technologie bude potřeba si odpovědět na následující otázky:

1. Co systém přesně dělá?
2. Jaké vstupy má k dispozici pro svou činnost?
3. V jakém prostředí pracuje?
4. Na jakém principu systém pracuje?

AutoTrac je schopen (polo)autonomního řízení např. traktoru při zemědělských pracích. V duchu principů controlled traffic farming při řízení vozidla minimalizuje nebo dokonce eliminuje opakované přejezdy vozidla po stejných místech na poli.

Hlavní zdroj informací pro AutoTrac jsou GPS a pohybové senzory (např. gyroskop), kterými jsou vozidla vybavená. Zároveň musí systém dopředu znát hranice území, po kterém se bude pohybovat. V kteroukoli chvíli taky musí mít řidič možnost převzít manuální kontrolu nad strojem.

Systém se pohybuje v jasně ohraničeném prostředí s žádnými (nebo s naprosto minimálními) nedeterministickými prvky (které by měl za úkol sám řešit). Prostředí se v průběhu práce nemění, respektive dochází pouze ke změnám, které stroj sám provádí (např. orající traktor mění stav prostředí).

Vzhledem k poměrně vstřícným podmínkám, ve kterých systém funguje, může pracovat s několika předpoklady. Za prvé má možnost si celou činnost rozplánovat dopředu (rozplánování "vodících linek") a to v důsledku předpokladu neměnnosti prostředí, které je navíc systému předem známo. Za druhé není třeba vymýšlet pro optimální pokrytí pole žádné složité trasy - v principu stejně technika projíždí systematicky polem vzájemně rovnoběžnými pásy. Ve chvíli, kdy má samořídící systém rozplánovaný systematický průjezd polem, musí řešit dva hlavní problémy. Prvním z nich je potřeba umět držet co nejpřesněji směr při cestě z jedné strany pole na druhou. Druhá výzva potom čeká na konci pole, kde se musí stroj zvládnout otočit a srovnat do nového pruhu.

Udržování stroje v předem určeném pásu probíhá především na základě GPS informací o poloze. V praxi se potom nejedná výhradně o GPS, ale i o jiné globální systémy určování polohy (GNSS). Navíc se pro další zpřesnění používají přijímače, které zvládají zpracovávat více frekvencí (běžné přijímače např. v mobilních zařízeních pracují obvykle jen s jednou frekvencí GPS signálu). Kromě řízení přes družicové technologie je zapotřebí, aby bylo vozidlo schopno reagovat např. na terénní nerovnosti. Vstupy pro tyto jemnější korekce získává systém z ostatních senzorů - např. pomocí zmiňovaných gyroskopů nebo světelných snímačů.

Problematika otáčení se na konci pole už nebývá předmětem plánování pohybu stroje - funguje na poloautomatické bázi. Obsluha stroje tak má možnost volit změnu vodící linky, po které vozidlo jede. Po odsouhlasení požadavku vypočítá palubní počítač plynulý obloukový manévr, kterým dostane stroj na novou vodící linku.

### 3.1.2 MachineSync

MachineSync je technologie pro součinnost více zemědělských strojů při práci na jednom poli. V první řadě umožňuje kooperativní plánování pohybu po celé ploše, svým způsobem tak jde o nadstavbu nad AutoTrac pro více strojů. Zároveň umožňuje při sklizni sdílet informace o plnosti kombajnů, díky tomu plánovat pohyb traktorů, které od nich úrodu přebírají, a tak omezovat čas, který by musely kombajny trávit v nečinnosti v důsledku plných zásobníků. MachineSync navíc automatizuje proces předávání úrody mezi kombajnem a traktorem - traktor je po celou dobu přečerpávání úrody řízen automaticky a kopíruje pohyb kombajnu (a to i při zatáčení). Právě tato schopnost se dá považovat za hlavní "inteligentní" prvek MachineSync.

Problematika synchronizace pohybu s jiným strojem v reálném čase (kombajn může být řízen poloautomaticky pomocí AutoTrac nebo manuálně řidičem) spočívá v potřebě okamžitě reagovat na změnu jeho směru, respektive v udržování tempa s ním. Situace je o něco jednodušší při přímé jízdě, při zatáčení je navíc potřeba řešit rozdílnou délku oblouků zatáčení (a z toho plynoucí nutnost rozdílné rychlosti).

Co se vstupů týká, stroje mají k dispozici stejné vstupy jako AutoTrac, navíc mají možnost své znalosti o prostředí a svých stavech vzájemně sdílet. Právě toto sdílení je klíčové pro možnost synchronizace pohybu.

Z hlediska traktoru, který se snaží pohybovat v synchronu s kombajnem, se jedná o ne zcela předvidatelné prostředí, které se dynamicky mění. Traktor se sice dovídá o aktuálním stavu kombajnu prakticky v reálném čase, to ale nic nemění na tom, že informaci nezískává s předstihem, a proto nemůže nic plánovat dopředu.

Co se možného řešení týká, je potřeba se dívat na dva případy. Pokud je kombajn řízen automaticky systémem AutoTrac, traktor má k dispozici díky sdílení stavu strojů možnost (až do dalšího zásahu ze strany řidiče) sledovat jeho trasu, jen s patřičným odstupem. V případě zatáček je třeba vzít navíc v potaz faktor různě dlouhých oblouků (to je ale v principu jednoduchá záležitost). Druhá (komplikovanější) možnost nastává, pokud je kombajn řízen manuálně. Potom je potřeba na každou změnu v pohybu kombajnu adekvátně a okamžitě reagovat (opět nesmíme opomenout potřebu změny rychlosti při změně směru). V obou případech také hraje roli faktor korekcí řízení v důsledku nerovností terénu a podobných vlivů - ten je také nutné ve výsledném pohybu synchronizovaného stroje zohlednit.

## 3.2 Umělá inteligence a analýza PA dat

I když to nemusí být na první pohled zjevné, v oblasti zemědělství (respektive především PA) je nemalé množství dat, ze kterých je možné získávat informace s velkou přidanou hodnotou. Jako příklad bude uvedena predikce úrody na základě vegetačních indexů za pomoci neuronových sítí. Bude představen vegetační index *NDVI* (*Normalized difference vegetation index*), následně bude popsán postup získávání NDVI map z leteckých snímků a jako příklad bude rozvedena zmiňovaná predikce úrody.

### 3.2.1 Vegetační index NDVI

Vegetační indexy slouží jako měřítko hustoty, respektive "zelenosti" vegetace na určitém území [veg]. Mapy vegetačních indexů je možné vypočítat z leteckých snímků, následně mohou sloužit jako cenný zdroj informací (ať už pro přímou interpretaci člověkem nebo pro další strojové zpracování). NDVI využívá pohlcování a odrážení charakteristických složek světla zelenou vegetací [ndva]. Tyto klíčové vlastnosti rostlin jsou vázány na přítomnost a množství chlorofylu, který je považován za dobré měřítko kvality dané vegetace (schopnost fotosyntézy je úzce spjatá s přítomností a množstvím chlorofylu).


### 3.2.2 Získávání a zpracování leteckých snímků do NDVI map

Získávání leteckých snímků obvykle probíhá za dopomoci k tomu určených dálkově řízených dronů [ndva], je možné využít i satelitních snímků (ty ale není v potřebné kvalitě a aktuálnosti zas tak jednoduché a levné získat). Při pořizování snímků záleží na k tomu použité fototechnice. Protože je zapotřebí k výpočtu NDVI znát hodnoty tzv. *blízkého infračerveného záření* (*near-infrared*, NIR), musí být kamery dronu schopny tyto frekvence do snímků zachytit. K zachycení potřebných frekvencí není možné přímo využít běžnou (tzv. RGB) fototechniku, proto je zapotřebí buďto opatřit kamery filtry, nebo použít specializované (tzv. *multispektrální*) přístroje [ndva].

Z takto získaných snímků jsou pro NDVI významné dva barevné kanály - červený a blízký infra-červený [ndva]. Klíčovou vlastností chlorofylu je schopnost odrážet větší množství blízkého infra-červeného záření a zároveň pohlcovat více červeného záření v porovnání s jinými vlnovými délkami. NDVI se počítá pro každý pixel snímku z jeho charakteristik (RGB rozšířené o blízký infra-červený kanál), hodnoty se potom pohybují mezi -1 (např. vodní povrchy) a 1 (hustá a na chlorofyl bohatá vegetace) [ndva].

Po vypočtení NDVI charakteristiky na všech pixelech snímku se typicky výsledek reprezentuje v podobě barevné mapy - tradičně se hodnoty blízké 1 zobrazují zeleně, hodnoty okolo 0 červeně a hodnoty nedaleko -1 černě. Takto vzniklá mapa může být použita k

Obrázek 2: NDVI mapa pole [und]



Obrázek 3: Výpočet NDVI [ndvb]

$$\text{NDVI} = \frac{(\text{NIR} - \text{Red})}{(\text{NIR} + \text{Red})}$$

přímé interpretaci člověkem - odhaluje například místa, kde je vegetace výrazně slabší než na zbytku pole. Zároveň je možné použít hodnoty NDVI pro další strojové zpracování, jak bude ukázáno dále.

### 3.2.3 Predikce úrody na základě vegetačních indexů

Následující sekce vychází z článku *Application of Vegetation Indices for Agricultural Crop Yield Prediction Using Neural Network Techniques* [PAP10].

Účelem této studie bylo zhodnotit možnost použití a vzájemné porovnání vegetačních indexů k predikci úrody s užitím technik strojového učení (konkrétně neuronových sítí). Jako vstupy sloužily hodnoty čtyř vegetačních indexů - již zmiňovaného NDVI, GVI (*Green vegetation index*), SAVI (*Soil adjusted vegetation index*) a PVI (*Perpendicular vegetation index*). Jako cílové hodnoty byly použity reálné objemy sklizně obilí z výzkumné zemědělské oblasti v Severní Dakotě v USA, a to v letech 1998, 1999 a 2001. Trénovací a testovací vzorky byly vytvořeny rozdělením pole do čtvercových oblastí (s hranou přibližně 75 metrů), na kterých byly známy jak hodnoty jednotlivých indexů, tak výsledný výnos obilí.

Pro všechny vyvíjené neuronové sítě autoři použili standardní backpropagation algorit-

mus s architektu sítě 2-1-1 (to se může jevit jako až překvapivě minimalistická konfigurace, autoři studie ji ale označují jako optimální pro svůj účel). Vstupní data - mapy vegetačních indexů - byla pro účely trénování sítí vyjádřena pomocí statistických charakteristik v rámci jednotlivých čtverců (průměr nebo směrodatné odchyly hodnot).

V základu bylo vyvinuto 12 neuronových modelů (pro každou kombinaci roku a vegetačního indexu), trénink probíhal přímo na výše popisovaných datech. Tyto modely byly použity pro počáteční porovnání vhodnosti jednotlivých indexů. Nejvhodnějším indexem pro predikci úrody se ukázal být PVI, to se ostatně potvrdilo i u dalších pokusů.

V další vlně vznikaly modely, které autoři trénovali na normalizovaných, případně i transformovaných vstupech. Například pro PVI byla použita logaritmická transformace vstupů (a následně i výstupů) v kombinaci s normalizací takto vzniklých hodnot. Zároveň také autoři trénovali modely pro data kombinovaná napříč zmiňovanými lety.

V celkovém shrnutí a závěru studie jsou modely založené na PVI s logaritmickou transformací vstupů prezentovány jako nejpřesnější ze všech srovnávaných možností, přičemž jsou uváděny průměrné hodnoty přesnosti přesahující 90 % (pro všechny tři zkoumané roky zvláště i napříč lety). Zajímavý je pak výkyv minimální přesnosti v jednom ze zkoumaných roků, ten autoři přičítají vlivům nezachyceným ve snímcích - jmenovitě například kvalitě půdy, možným kalamitám škůdcům proběhlým mezi pořízením snímků a sklizní atp. Na stranu druhou, ve větším množství případů maximální pozorovaná přesnost predikce atakovala hranici 100 %.

### 3.3 Umělá inteligence v zemědělství mimo PA

Poslední oblast, kterou bude práce pokrývat, se týká aplikací umělé inteligence mimo PA. Zemědělství (a to zdaleka nejen dnešní moderní zemědělství) vyžaduje neelementární množství plánování a rozvrhování různorodých činností. Asi nejkritičtějším obdobím v cyklu zemědělských prací je doba sklizně - pokud je například možné efektivně rozplánovat logistiku přesunu strojů mezi jednotlivými poli, přinejmenším ušetříme čas (který je obzvlášť při sklizni klíčový) a náklady na pohonné hmoty pro zemědělské stroje. Jako příklad bude uvedena studie modelového logistického problému s obdobnými podmínkami, se kterými se bychom se setkali při plánování přesunu strojů mezi poli.

#### 3.3.1 Vehicle routing problem

*Vehicle routing problem* je obecnější variantou *Problému obchodního cestujícího*. Úkolem je určit optimální trasy pro flotilu vozidel při objížďení zákazníků po předem dané dopravní síti. Přitom platí, že každý zákazník musí být navštíven alespoň jedním vozidlem a určená množina tras vozidel by měla minimalizovat celkově uraženou vzdálenost (respektive cenu přesunů, ta může být obecně určena i jinak, např. jako čas).

Vzhledem k tomu, že Problém obchodního cestujícího je NP-těžký, a je speciálním případem VRP (omezení na jediné vozidlo), víme i o VRP, že patří do kategorie NP-těžkých problémů. Není ho tedy možné hrubou silou řešit už pro poměrně malé instance.

VRP také existuje v množství specializovaných variant:

- VRP s časovými okny - zákazníci mají určená časová okna, ve kterých musí být obslouženi
- VRP s omezenou kapacitou vozidla - vozidlo může obsloužit jen omezený počet zákazníků
- VRP ve verzi pickup&delivery - přemísťování zásilek mezi více sklady a cílovými lokacemi
- ...



Z nalezených verzí VRP se problému plánování pohybu strojů během sklizně nejvíce blížil *VRP s omezením na palivo s více depy*. Oproti základnímu VRP obsahuje dopravní síť navíc depa - ta slouží jako startovní a cílové pozice vozidel, zároveň také jako čerpací stanice. Navíc jsou vozidla ve svém pohybu omezena tím, že mohou mezi dvěma návštěvami dep (nebo čerpacích stanic obecně) urazit jen takovou cestu, jejíž celková cena nepřesahuje pevně nastavenou horní mez (ta reprezentuje kapacitu nádrže). V této verzi problému může vystupovat i více vozidel. V diskutované verzi popisované nalezenou studií [SVR16] navíc figurují i zjednodušující předpoklady o dopravní síti (grafu), na které je optimalizace řešena - jde především o předpoklady trojúhelníkové nerovnosti a symetričnosti délek cest (vlastnosti metriky [met]).

Autoři studie předkládají jako možný postup řešení formulaci problému jako úlohy *smíšeného celočíselného lineárního programování* a její následnou relaxaci. Po vyřešení relaxovaného problému aplikují *branch-and-cut* algoritmus - ten za dopomoci výsledků relaxovaného problému a zaváděním lineárních omezení "vyhání" postupně řešení směrem k optimu.

Oblast *lineárního programování* je oblast matematiky zabývající se minimalizací (respektive maximalizací) tzv. *účelové funkce* (tato funkce je lineární) za splnění lineárně zadaných podmínek. Obecně je tedy úkolem nalézt hodnoty pro množinu proměnných tak, aby byly splněny všechny zadané podmínky (takové hodnoty představují platné řešení problému), a zároveň byla minimalizována (či maximalizována) zadaná účelová funkce (optimální řešení) [lin].

*Celočíselné lineární programování* se liší od obecného tím, že hodnoty hledaných proměnných mohou nabývat pouze celočíselných (často pouze přirozených) hodnot [int]. Rozdíl mezi čistě celočíselným LP a smíšeným LP je ten, že ne všechny hledané hodnoty musí být celočíselné. Zmíněná relaxace problému spočívá právě v odstranění celočíselného omezení na proměnných - to je mimo jiné obecný "trik" pro převedení NP-těžkého problému celočíselného lineárního programování na polynomiální problém obecného lineárního programování. Výsledky se následně získají zaokrouhlením výsledků takto relaxovaného problému.

Přístup má dva základní nedostatky - za prvé nemusí být takto získané výsledky tak blízko optimu, jak by se mohlo na první pohled zdát, za druhé mohou nastat i situace, ve kterých zaokrouhlené výsledky nejsou ani platnými řešením dané úlohy (zaokrouhlením dojde k porušení některého omezení). Právě proto byl na takto získané výsledky aplikován *branch-and-cut* algoritmus - ten přinejmenším garantuje nalezení alespoň nějakého platného výsledku.

Autoři studie používají tento postup především za účelem porovnání dvou alternativních popisů daného problému (jeden popisuje problém přes hrany a druhý přes vrcholy grafu), přičemž počítají s tím, že se nejedná o nejlepší možný přístup k problému.

Závěrem článku jsou srovnány dvě implementace problému. Zkoumány a porovnávány byly jen instance problému s maximální velikostí 40 (tj. grafy s maximálně 40 cílovými lokacemi). Jako horní limit pro délku výpočtu autoři nastavili jednu hodinu, přičemž lepší z algoritmů řešil i největší zkoumané instance v čase do 15 minut. Míru použitelnosti výsledků se mi bohužel z textu studie nepovedlo určit kvůli neznalosti metriky využití k vyhodnocování (ta pravděpodobně vycházela z konkrétní implementace lineární optimalizace).

## 4 Závěr

Vypracování referátu mě dovedlo k poměrně zdrženlivému postoji k používání pojmu umělá inteligence. Především jsem se hned několikrát přistihl při neschopnosti určit, co to vlastně umělá inteligence je, respektive co už je a co ještě není uměle inteligentní. S tímto problémem jsem se setkal hned u systémů pro poloautomatické řízení zemědělských strojů. V těch

má totiž větší část celého "zázraku" na svědomí spíše hardware než software, na stranu druhou takto vybavený traktor zvládá něco, co bychom od běžného stroje neočekávali. Další zkoumané příklady (predikce úrody a logistická úloha) staví naopak do zajímavého světla koncepty postavené na matematice - v čem vlastně spočívá inteligence neuronové sítě nebo optimalizace lineárním programováním? Oba přístupy jsou totiž nakonec jenom explicitně daný postup s dobrým matematickým základem. To stejné ale můžeme říct o prakticky libovolném algoritmu, u kterého dokážeme, že je korektní.

## Reference

- [aut] AutoTrac. <https://www.deere.com/en/technology-products/precision-ag-technology/guidance/auto-trac/>. Accessed: 2019-11-30.
- [can] CropSpec Crop Canopy Sensors. <https://topconcare.com/en/agriculture/crop-monitoring-technology/crop-canopy-sensors/>. Accessed: 2019-11-30.
- [CKR] Daheim Cornelia, Poppe Krijn, and Schrijver Remco. Precision agriculture and the future of farming in Europe . <https://op.europa.eu/en/publication-detail/-/publication/40fe549e-cb49-11e7-a5d5-01aa75ed71a1>.
- [con] Controlled traffic farming. [https://en.wikipedia.org/wiki/Controlled\\_traffic\\_farming](https://en.wikipedia.org/wiki/Controlled_traffic_farming). Accessed: 2019-11-30.
- [EBB<sup>+</sup>19] Iria Soto Embodas, Andrew Barnes, Athanasios Balafoutis, Bert Beck, Berta Sanchez Fernandez, Jurgen Vangeyte, Spyros Fountas, Tamme Van Der Wal, Vera Eory, and Manuel Gomez Barbero. The contribution of precision agriculture technologies to farm productivity and the mitigation of greenhouse gas emissions in the EU. 2019.
- [gps] Americký družicový navigační systém NAVSTAR GPS. <https://www.czechspaceportal.cz/3-sekce/gnss-systemy/gnss-mimo-evropu/americky-navstar-gps/>. Accessed: 2019-11-30.
- [int] Integer programming. [https://en.wikipedia.org/wiki/Integer\\_programming](https://en.wikipedia.org/wiki/Integer_programming). Accessed: 2019-12-02.
- [LDE] James Lowenberg-DeBoera and Bruce Erickson. Setting the Record Straight on Precision Agriculture Adoption. <https://dl.sciencesocieties.org/publications/aj/articles/111/4/1552>. Accessed: 2019-11-30.
- [lin] Linear programming. [https://en.wikipedia.org/wiki/Linear\\_programming](https://en.wikipedia.org/wiki/Linear_programming). Accessed: 2019-12-02.
- [mac] MachineSync. <https://www.deere.com/en/technology-products/precision-ag-technology/guidance/machine-sync/>. Accessed: 2019-11-30.
- [May] Bob Mayfield. John Deere hands-free guidance system continues its evolution. <https://johndeerejournal.com/2016/03/terry-picket-first-gps-unit/>. Accessed: 2019-11-30.
- [met] Metrický prostor. [https://cs.wikipedia.org/wiki/Metrický\\_prostor](https://cs.wikipedia.org/wiki/Metrický_prostor). Accessed: 2019-11-30.

- [MK15] David Mulla and Raj Khosla. Historical Evolution and Recent Advances in Precision Farming. 2015.
- [ndva] Identifying Crop Variability with Drones. <https://blog.dronedeploy.com/identifying-crop-variability-whats-the-difference-between-ndvi-false-ndvi-and-va>. Accessed: 2019-11-30.
- [ndvb] What is NDVI (Normalized Difference Vegetation Index)? <https://gisgeography.com/ndvi-normalized-difference-vegetation-index/>. Accessed: 2019-11-30.
- [PAP10] Sudhanshu Sekhar Panda, Daniel P. Ames, and Suranjan Panigrahi. Application of Vegetation Indices for Agricultural Crop Yield Prediction Using Neural Network Techniques. *www.mdpi.com/journal/remotesensing*, pages 673–696, 2010.
- [Sch] Remi Schmaltz. What is precision agriculture? <https://agfundernews.com/what-is-precision-agriculture.html>. Accessed: 2019-11-30.
- [soi] Soil moisture sensor. [https://en.wikipedia.org/wiki/Soil\\_moisture\\_sensor](https://en.wikipedia.org/wiki/Soil_moisture_sensor). Accessed: 2019-11-30.
- [SVR16] Kaarthik Sundar, Saravanan Venkatachalam, and Sivakumar Rathinam. Formulations and algorithms for the multiple depot, fuel-constrained, multiple vehicle routing problem. 2016.
- [und] Understanding NDVI. <https://support.dronedeploy.com/docs/understanding-ndvi-1>. Accessed: 2019-11-30.
- [veg] Vegetation Index. [https://en.wikipedia.org/wiki/Vegetation\\_Index](https://en.wikipedia.org/wiki/Vegetation_Index). Accessed: 2019-11-30.