



Fakulta zemědělská
a technologická
Faculty of Agriculture
and Technology

Jihočeská univerzita
v Českých Budějovicích
University of South Bohemia
in České Budějovice

JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH FAKULTA ZEMĚDĚLSKÁ A TECHNOLOGICKÁ

Katedra techniky a kybernetiky

Autoreferát dizertační práce

Využití genetických algoritmů k optimalizaci činnosti
zemědělských strojů v systémech precizního zemědělství

Autor práce: Roman Bumbálek

Vedoucí práce: doc. RNDr. Petr Bartoš, Ph.D.

České Budějovice
2024

Abstrakt

Metaheuristické metody, inspirované fyzikálními, biologickými, chemickými, sémantickými i sociálními jevy, jsou aplikovány pro optimalizaci úloh s rozsáhlou množinou možných řešení v širokém spektru oborů včetně zemědělství, přičemž významnou část tvoří evoluční výpočty, z nichž jsou pro potřeby precizního zemědělství využívány především genetické algoritmy. Tato práce se zabývá jejich implementací v rámci problematiky plánování tras pojezdu zemědělské techniky s cílem snížení délky trajektorie pohybu na souvratích i ve vnitřní části pozemku. Vytvořený algoritmus se skládá z několika částí, kdy nejprve dochází k výpočtu souřadnic dílčích tras a následně aplikací genetických algoritmů k optimalizaci otáčení souprav na souvratích vhodnou kombinací jejich průjezdů s ohledem na vstupní parametry zahrnující poloměr otáčení a záběr nástroje. Kvalitu získaných výsledků ovlivňuje mnoho faktorů jako velikost populace, počet generací či zvolený typ selekce, kdy se zvyšujícím se množstvím chromozomů v populaci i generací dochází k vygenerování lepších řešení, umožňujících zkrácení vzdálenosti pojezdu při otáčení na souvratích o více než 37 %, což může přímo vést k úsporám pracovního času, pohonných hmot a nižšímu zhutnění půdy.

Klíčová slova: genetické algoritmy; metaheuristické metody; plánování pojezdových tras; optimalizace trajektorie pohybu; otáčení zemědělských strojů na souvratích

Abstract

Metaheuristic methods, inspired by physical, biological, chemical, semantic and social phenomena, are used to optimise problems with a large number of possible solutions in a wide range of fields, including agriculture, with a significant part of evolutionary computation, of which genetic algorithms are mainly used for precision agriculture. This paper deals with their implementation in the context of the problem of planning the routes of agricultural machines with the aim of reducing the length of the trajectory of movement both on the headlands and in the inner part of the plot. The developed algorithm consists of several parts, where first the coordinates of the partial routes are calculated and then genetic algorithms are applied to optimise the rotation of the implements on the headlands through a suitable combination of their passes with respect to the input parameters, including the turning radius and the tool sweep. The quality of the results obtained is influenced by many factors, such as the size of the population, the number of generations or the type of selection chosen, with better solutions being generated as the number of chromosomes in the population and generations increases, allowing a reduction of more than 37 % in the distance travelled when turning on headlands, which can directly translate into savings in working time, fuel and reduced soil compaction.

Keywords: Genetic algorithms; metaheuristic methods; route planning; trajectory optimisation; headland turning of agricultural machine

Obsah

Úvod.....	5
1 Literární rešerše.....	7
1.1 Metaheuristické metody v zemědělství	7
1.1.1 Algoritmus mravenčí kolonie (ACO).....	9
1.1.2 Simulované žihání (SA)	9
1.1.3 Harmony search	9
1.1.4 Algoritmus optimalizace pomocí roje částic (PSO).....	10
1.1.5 Tabu Search.....	10
1.2 Genetické algoritmy	11
1.2.1 Struktura GA	11
1.2.2 Selektce	12
1.2.3 Křížení.....	13
1.2.4 Mutace.....	14
2 Cíl práce	15
3 Algoritmus pro optimalizaci pohybu zemědělské techniky po pozemku s implementací GA.....	16
3.1 Funkce genetického algoritmu	17
3.2 Funkce fitness k ohodnocení jednotlivých řešení.....	20
3.3 Funkce pro výpočet délky otočky.....	21
3.4 Funkce selektce	23
4 Vybrané výsledky a diskuse.....	26
4.1 Analýza výsledků z hlediska vlivu velikosti populace.....	27
4.2 Analýza výsledků s ohledem na vliv typu selekční metody.....	32
4.3 Analýza výsledků s ohledem na vliv typu a pravděpodobnosti křížení	34
Závěr	36
Seznam použité literatury.....	37

Úvod

Zemědělská půda je nepostradatelným statkem, bez kterého by nebyla možná produkce potravin nejen rostlinného, ale potažmo také živočišného původu. I přesto jsme svědky významného zabírání zemědělské půdy pro nezemědělské účely a jejího dalšího znehodnocování v důsledku použití nevhodných technologických postupů. Jedním z nejvýznamnějších typů půdní degradace je zhutnění půdy (Shah et al., 2017). V současnosti je zhutněním ohroženo až 68 milionů hektarů půdy a z toho připadá 33 milionů ha na Evropu (Právělie, 2021), přičemž hlavním faktorem zodpovědným za tento stav je především její vysoké mechanické zatížení způsobené pojezdem zemědělské techniky po pozemku (Mileusnić et al., 2022). Současné situaci nepřispívá ani zvyšující se hmotnost zemědělských strojů, která se za posledních několik desetiletí výrazně zvýšila (Shabeb et al., 2021; Sivarajan et al., 2017).

Zhutnění půdy je doprovázeno řadou nežádoucích jevů, jako je zvyšování objemové hustoty půdy, snížení velikost pórů, propustnosti nebo dostupnosti živin, které mají za následek snížení zemědělské produkce (Carla et al, 2022; Cárceles Rodríguez et al., 2022). V důsledku zhutnění klesá schopnost půdy zadržet vodu, čímž se zvyšuje povrchový odtok a riziko vodní eroze (de Lima et al, 2017; Centeri, 2022). Se zhutněním půdy jde ruku v ruce také zvýšení energetické náročnosti obdělávání půdy a snížení jeho kvality (Kumhála et al., 2013).

Mezi významné technologické postupy vedoucí k eliminaci zhutnění půdy patří řízený pohyb zemědělských strojů po pozemcích, tzv. Controlled Traffic Farming (CTF) (Bulgakov et al., 2022). Principiálně je možno CTF charakterizovat tak, že pohyb zemědělských strojů je sveden do předem stanovených drah (Hussein, 2022; Tamirat et al., 2022), které optimálním způsobem pokrývají celý pozemek. Vhodnou volbou trajektorie zemědělských strojů je možno výrazně redukovat míru zhutnění pozemku v důsledku pojezdu zemědělské techniky. Například Edwards et al. (2017) prokázali, že optimalizované dráhy mohou snížit délku tras zemědělských strojů o 18 %, přičemž při využití strojů se stejným rozvorem kol je možno dosáhnout hodnoty až 30 % (Kumhála et al., 2013). Marinello F. et al. (2017) ve své práci konstatuje, že díky řízenému pohybu zemědělské mechanizace může být očekáváno zvýšení výnosů plodin o více než 10 %.

Pohyb zemědělské techniky po pozemku lze rozdělit do dvou částí na pojezdy organizovaných dílčích tras ve vnitřní oblasti pole a otáčení na souvrati nutné pro

změnu směru a jejich průjezd, přičemž pro snížení vzdálenosti celkové trajektorie je třeba se zaměřit na optimalizaci pohybu v obou oblastech (Utamima et Djunaidy, 2021). He et al. (2023) uvádí, že snížení pojezdové vzdálenosti při otočkách na souvratích je pro minimalizaci délky kompletní dráhy pohybu velice důležité. Techniky plánování optimálních pojezdových tras zahrnují rozličné přístupy včetně metaheuristických metod zaměřených na hledání optimálních výsledků u problematik s rozsáhlým prostorem možných řešení jako optimalizace rojením částic, optimalizace pomocí mravenčí kolonie či genetické algoritmy (Santos et al., 2020).

V softwarovém inženýrství se pojmem genetický algoritmus označuje takový postup, kdy se opakovaně vybírá, kříží a mutuje populace (data) za účelem vytvoření nové generace, která bude představovat vhodnější řešení daného problému než původní (rodičovská) generace (Han et al., 2017). Součástí rozhodovacího procesu je také stanovení podmínky, při které je možno výpočet ukončit s tím, že bylo nalezeno „dostatečně vhodné“ řešení dané úlohy.

1 Literární rešerše


1.1 Metaheuristické metody v zemědělství

Metaheuristika je kombinace heuristických metod, jejímž cílem je efektivně podpořit průzkum prohledávaného prostoru, čímž je možné předejít uvíznutí v lokálním minimu ve složitém prostoru. Metaheuristika je inspirována několika tématy, z nichž lze vyzdvihnout například analogii s fyzikálními, chemickými, biologickými, sémantickými a sociálními jevy. (Kaur et al. 2020). Klasifikace heuristických metod se u mnohých autorů liší (Ikeda et Inoue, 2016; Kurnia et al., 2018). Darwish et al. (2020), Dhiman a Kumar (2017) a Khishe a Mosavi (2020) používají čtyři základní skupiny: evoluční výpočetní techniku, inteligenci roje, techniku inspirovanou člověkem a společností a fyzikální techniku. Francik et al. (2020) ve svém přehledu současných výzkumných trendů v oblasti systémů obnovitelných zdrojů energie rovněž zařadili skupiny nazvané evoluční výpočty a rojová inteligence. Na základě podrobné analýzy dostupné literatury zabývající se metaheuristickými metodami a jejich klasifikací je na obrázku 1.1 uveden ucelený přehled důležitých metaheuristických metod. Nejdůležitější metaheuristické metody používané v precizním zemědělství jsou barevně zvýrazněny a podrobně popsány níže. Uvedené metaheuristické metody byly rozděleny do čtyř skupin na evoluční výpočty, rojovou inteligence, algoritmy založené na fyzikálních jevech a algoritmy inspirované člověkem.

Tabulka 1.1: Přehled nejvyužívanějších metaheuristických metod pro optimalizaci pojezdových tras a problematiku logistiky v zemědělství.

Zkratka metody	Název metody
GA	Genetické algoritmy
ACO	Algoritmus mravenčí kolonie
SA	Simulované žíhání
HS	Harmony Search
PSO	Algoritmus optimalizace pomocí roje částic
TS	Tabu Search

Z tabulky 1.1 je patrné, že pro řešení problémů plánování tras pojezdu a logistiky zemědělských polí bylo v literatuře využito několik metaheuristických metod (Bochtis et Vougioukas, 2008). Nejčastější algoritmy aplikované na tento problém jsou genetické algoritmy, algoritmus mravenčí kolonie, simulované žíhání, harmony search, optimalizace pomocí roje částic a tabu search.



Obrázek 1.1: Klasifikace metaheuristických optimalizačních metod

1.1.1 Algoritmus mravenčí kolonie (ACO)

Feng (2020) se zabýval logistickým modelem potenciálně použitelným v precizním zemědělství na základě algoritmu mravenčí kolonie, jehož hlavními výhodám řadil univerzálnost a absenci potřeby počáteční trasy. Dále také uvádí, že ACO není závislý na volbě dílčí počáteční trasy a také ji není třeba v procesu vyhledávání ručně upravovat. Algoritmus mravenčí kolonie lze využít také v případě elektrických vozidel, jejichž význam v zemědělství v budoucnu výrazně vzroste (Mavrovouniotis et al., 2018), například Joo a Lim (2018) představili efektivní metodu energeticky účinného směřování s využitím ACO pro maximalizaci energetické účinnosti (Alaiso et al., 2013). Optimalizací efektivity přepravy produktů na konkrétní místa a zlepšením manipulační kapacity se zabývali Mutar et al. (2020), jejichž výzkum prokázal značný potenciál navržené ACO metody, vzhledem k získání lepších výsledků než u jiných algoritmů (např. SA).

1.1.2 Simulované žíhání (SA)

V precizním zemědělství se také stávají populární malá bezpilotní letadla a drony, jež vyžadují sofistikované plánování letové dráhy, které lze též pomocí SA optimalizovat (Behnck et al., 2015). Simulované žíhání bylo také úspěšně použito pro monitorování zemědělství. Například Leitold et al. (2018) navrhli metodiku založenou na Simulovaném žíhání pro přiřazení dalších senzorů k dynamickým monitorovacím systémům. Bochtis a Vougioukas (2008) navrhli přístup založený, který využili k řešení problému plánování trasy pro aplikaci herbicidů, celková ujetá vzdálenost po vybraném pozemku byla 335,767 m a vzdálenost ujetá na souvratích 95,767 m. Metoda navržená Conesou-Muñozem et al. (2016) ukázala celkovou ujetou vzdálenost na stejném pozemku 334,439 m a vzdálenost ujetou na souvratích 94,439 m. Porovnáním obou výsledků lze konstatovat, že rozdíly mezi vypočtenými vzdálenostmi jsou menší než 1,4 %.

1.1.3 Harmony search

Pravděpodobně nejčastější využití HS v zemědělství nachází při plánování pojezdových tras, například Utamina et al. (2019) použili tento algoritmus pro řešení problému optimální trajektorie pohybu zemědělské techniky v rámci logistiky na poli. Stejně jako jiné heuristiky byl i algoritmus Harmony Search aplikován pro optimalizaci pohybu bezpilotních letounů v rámci řízení precizního zemědělství a plánování tras v robotice (Valente et al., 2013; Muhalej et Mirroshandel, 2018). Výzkumníci vynakládají

velké úsilí na zdokonalení stávajících algoritmů HS. Například Liu et al. (2020) představili metodu využívající algoritmus HS založený na kódování pomocí přirozených čísel pro problematiku plánování tras, jenž při zpracování přirozených čísel dosáhla vysoké účinnosti a poskytla lepší výsledky ve srovnání s jinými testovanými typy algoritmu HS. Valente et al. (2013) vyvinuli postup využívající algoritmus Harmony Search k optimalizaci letových drah, jenž vykázal lepší výsledky při optimalizaci trasy ve srovnání s metodou prezentovanou Barrientosem et al. (2011) díky snížení počtu otáčení v trajektoriích pokrývajících pozemek a dodržení stanovené výchozí a cílové polohy. Výpočetní čas je ve srovnání s předchozím přístupem delší, to však lze považovat za přijatelnou nevýhodu vzhledem k tomu, že cílem vytvořeného plánovače tras není práce v reálném čase.

1.1.4 Algoritmus optimalizace pomocí roje částic (PSO)

Metodu optimalizace pomocí roje částic lze využít v zemědělství 4.0 například pro plánování kapacity servisních služeb pro zemědělské stroje (Hu et al., 2020) a také pro trasy bezpilotních letounů. Mukherjee et al. (2020) použili rojovou optimalizaci v úlohách náročných na zpracování, jako je vizuální identifikace zemědělských pozemků a sledování zdravotního stavu či růstu plodin. Pravděpodobně nejdůležitější oblastí s přesahem do precizního zemědělství, kde se PSO využívá, je robotika. Das et Jena (2020) a Li et al. (2020) použili algoritmus PSO pro plánování dráhy mobilních robotů.

1.1.5 Tabu Search

Stejně jako jiné algoritmy je pravděpodobně nejčastější použití algoritmu Tabu Search v zemědělství spojeno s problémem plánování zemědělských tras. Například Utamima et al. (2019) použili algoritmus TS společně s algoritmem HS pro plánování pojezdu techniky v polní logistice. He et al. (2018) sestavili operační model pro stanovení optimálního rozvržení sklízecích mlátiček pro nespojitě zemědělské pozemky. Ke stanovení optimálního plánu pro dosažení minimalizace celkové doby sklizně i doby sklizně na jednotlivých pozemcích použili hybridní metodu Tabu Search. Hybridní algoritmus využívající jak adaptivní prohledávání velkého okolí, tak Tabu Search byl také použit ke snížení nepracovní vzdálenosti v polní logistice pro heterogenní sklízecí stroje.

1.2 Genetické algoritmy

Genetické algoritmy se řadí mezi heuristické metody. Jejich základní myšlenka je inspirována biologickou evolucí, fungují tedy na principu mechanismu přirozeného výběru a genetiky (Ferreira Neto et al., 2011, Ikeda a Inoue, 2016, Kurnia et al., 2018). Vývoj genetických algoritmů započal již v šedesátých letech 20. století a je spojen s osobností J. Hollanda (Lamini et al., 2018, Elhoseny et al., 2018). Za milník této problematiky je považován rok 1975, kdy J. Holland předložil svůj výzkum v publikaci *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence* (Qiongbing a Lixin, 2016, Sales et al., 2018). V současné době jsou genetické algoritmy využívány pro optimalizaci modelů a hledání optimálních řešení rozsáhlých a složitých problémů (Alipour et al., 2018, Mohammed et al., 2017) v mnoha oblastech, jako strojírenství, informační technologie, ekonomie a řízení dodavatelských řetězců (Dao et al., 2017, Sales et al., 2018). Také v zemědělství je možné tyto algoritmy uplatnit, například pro optimalizaci pojezdu zemědělské techniky po pozemku (Neungmatcha et al., 2013, Tong et al., 2017, Gracia et al., 2013), rozčlenění pozemku (Ferreira Neto et al., 2011, Sales et al., 2018) a modelování predikce a optimalizace výnosů (Ali et al., 2018, Hilal et al., 2018). Mohammed et al. (2017) uvádí, že genetické algoritmy lze efektivně využít na hledání optimálního řešení, pokud je prostor všech řešení příliš velký a lineární programování nedokáže nalézt teoretické řešení ve vyhovujícím čase a na řešení problémů s více omezeními. Mezi hlavní výhody patří možnost optimalizovat problémy s mnoho řešeními, využívání paralelního výběru dat, což eliminuje uvíznutí v lokálně optimálním řešení, a dobrá srozumitelnost algoritmu (Ngoc et al., 2014).

1.2.1 Struktura GA

Lamini et al. (2018) uvádí, že genetický algoritmus obsahuje pět základních částí:

- Výběr hodnot proměnných parametrů genetického algoritmu, jako velikost populace, pravděpodobnost křížení, pravděpodobnost mutace a kritérium k zastavení algoritmu
- Vhodné kódování dat
- Metodu generování počáteční populace
- Funkci fitness sloužící k vyhodnocení kvality každého potenciálního řešení
- Genetické operátory, které upravují genetické složení rodičovských chromozomů k vytvoření nových chromozomů (potomstva)

V prvním kroku procesu genetického algoritmu probíhá kódování dat do chromozomů a vygenerování náhodné populace. Chromozomy mohou být tvořeny binárním kódem (Elhoseny et al., 2018, Yi et al., 2016), celými i reálnými čísly (Tong et al., 2017, Han et al., 2017, Alipour et al., 2018, Ikeda a Inoue, 2016, Amal et al., 2018, Kurnia et al., 2018, Sun et al., 2018), což je dle Elferchichi et al. (2009) pro reálné hodnoty dat vhodnější způsob než binární kódování, protože proces kódování potřebuje velké množství počítačové paměti a mnoho výpočetního času. Data v jednotlivých chromozomech mohou být také reprezentovány souřadnicemi bodů (Nazarahari et al., 2019, Lee et al., 2018, Kwaśniewski a Gosiewski, 2018).

Poté je každý chromozom ohodnocen pomocí funkce fitness, která na základě vybraného kritéria nebo více kritérií vypočítá kvalitu chromozomu, označovanou také jako hodnotu fitness, jenž je důležitým kritériem pro další krok, což je výběr (selekce). Mařík et al. (2001) uvádí, že úkolem selekce je upřednostňovat kvalitnější jedince před horšími. Z vybraných chromozomů (rodiče) vznikne využitím dalších genetických operátorů, což je křížení a mutace, nová generace chromozomů (potomci), pro něž je vypočítána kvalita, následně jejich zařazením vzniká nová generace populace. Tento proces se opakuje, dokud nenastane zlepšení kvality, které by splňovalo optimalizační kritérium (Koca et al., 2018). Dle Ferreira Neto et al. (2011) typický cyklus genetického algoritmu obsahuje 50 až 500 generací, avšak může být i vyšší. Populace na konci tohoto cyklu obsahuje jeden nebo více chromozomů s vysokou kvalitou.

1.2.2 Selekcce

Selekcce je velmi důležitým genetickým operátorem, používaným k výběru chromozomů, které budou mít v následujícím křížení roli rodiče, jenž poslouží ke vzniku nových chromozomů, potomků, kteří budou součástí další generace (Mařík et al., 2001, Elhoseny et al., 2018). Pravděpodobnost výběru je vyšší u kvalitních, dobře hodnocených chromozomů, což může zlepšit průměrnou kvalitu nové generace populace. Vybraný způsob selekce má tedy přímý vliv na výsledky genetického algoritmu, a proto je podstatné poskytnout vhodný selekční tlak, jelikož v opačném případě může nastat zastavení vývoje populace nebo ztráta její rozmanitosti (Lamini et al., 2018, Han et al., 2017, Qiongbing a Lixin, 2016). Selekcčních metod vyžívaných v genetických algoritmech je více, mezi nejpoužívanější patří:

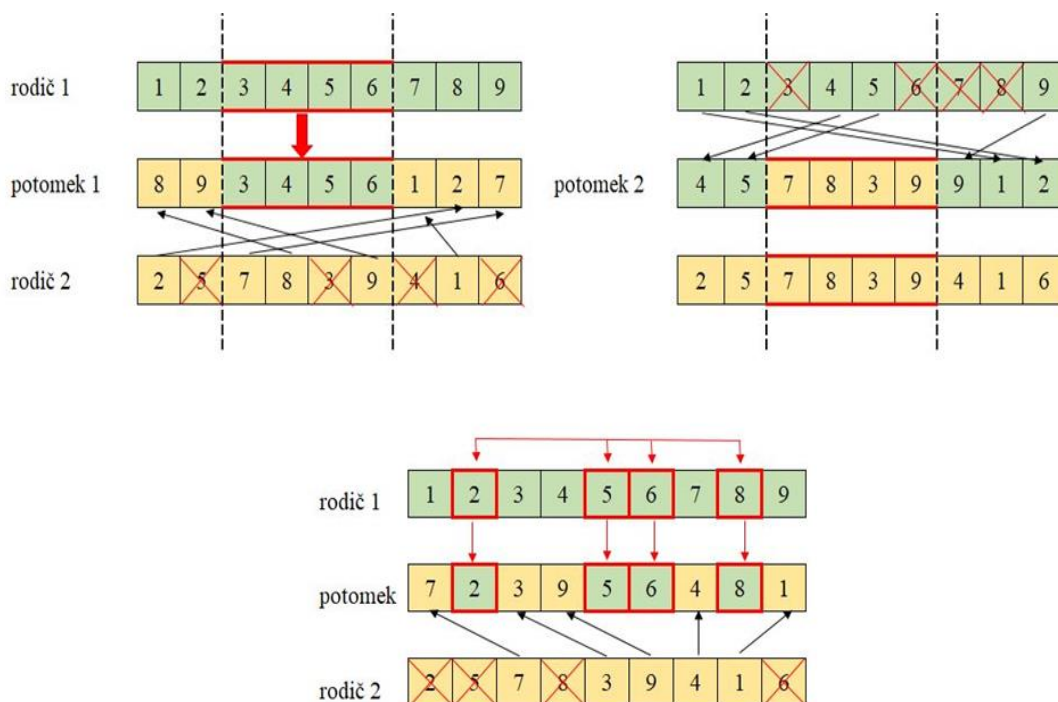
- Pořadová selekcce,
- Elitářský výběr,

- Turnajová metoda,
- Stochastické univerzální vzorkování,
- Mechanismus ruletového kola.

1.2.3 Křížení

Křížení slouží k vytvoření chromozomů, takzvaných potomků, s novou kombinací genů pomocí smísení genetických informací tradičně dvou vybraných rodičovských chromozomů ze stávající populace. Tento proces udržuje rozmanitost a zvyšuje kvalitu možných řešení. Hlavním cílem křížení je vytvořit kvalitnější jedince a tím vést populaci chromozomů k přiblížení se k optimálnímu výsledku (Elhoseny et al., 2018, Nazahari et al., 2019, Assaf a Saleh, 2017). Metod křížení existuje poměrně značné množství, k hlavním z nich se řadí:

- Jednobodové křížení
- Dvoubodové a vícebodové křížení
- Fúzní křížení
- Křížení se zachováním pořadí
- Uniformní křížení
- Křížení na základě pozice



Obrázek 1.1: Vizualizace křížení se zachováním pořadí a křížení na základě pozice

1.2.4 Mutace

Tento genetický operátor následuje za křížením a provádí náhodné změny jednoho či více genů nebo úpravy jejich pořadí v chromozomech. Výběr genu určeného k mutaci se řídí pravděpodobností mutace P_m (Neungmatcha et al., 2013, Kurnia et al., 2018, Wiczorek a Ignaciuk, 2018). Pomocí mutace je možné zajistit v generacích rozmanitost řetězců chromozomů, snížit míru konvergence a předejít problému s řešením vyskytujícím se v oblasti lokálního optima (Amal et al., 2018, Tong et al., 2017). Často implementované metody mutace jsou následující:


- Náhodná mutace,
- Mutace výměnou,
- Posuvná mutace,
- Aritmetická mutace,
- Uniformní mutace.

2 Cíl práce

Hlavním cílem dizertační práce je navrhnout a rozpracovat matematický model trajektorie pohybu zemědělské techniky po pozemku zaměřený na nalezení optimálních pojzdových tras aplikací genetických algoritmů, přičemž důraz bude kladen především na otáčení techniky v oblasti souvratí. V rámci práce bude provedena numerická realizace modelu pro zvolené vstupní parametry, přičemž na základě vygenerovaných dat dojde k porovnání implementovaných metod genetických algoritmů. Obsažen bude také přehled mapující využití metaheuristických přístupů při činnosti zemědělských strojů v systémech precizního zemědělství, a to především se zřetelem na využití genetických algoritmů.

3 Algoritmus pro optimalizaci pohybu zemědělské techniky po pozemku s implementací GA

Struktura algoritmu se skládá ze tří hlavních částí, které se rozvětvují do dílčích skriptů jednotlivých funkcí. První část je zaměřena na zpracování vstupních bodů ohraničení pozemku, vytvoření optimálních souvratí s ohledem na daný poloměr otáčení, a především nalezení nejkratších pojezdových tras po pozemku. V části druhé podstupují prvky nejlepšího vygenerovaného řešení proces zpracování pomocí genetických algoritmů pro získání optimální kombinace průjezdů dílčími trasami za účelem snížení pojezdové vzdálenosti při otáčkách na souvratích, zahrnující hodnotící funkci fitness, četné metody selekce i vhodné postupy křížení a mutace nově vzniklých kombinací, z nichž je ta, která vykazuje nejlepší výsledky, v poslední části vizualizována. Na obrázku 3.1 je ukázáno stručné schéma jednotlivých částí, které jsou dále rozpracovány.




Obrázek 2.1: Schéma algoritmu pro optimalizaci pohybu zemědělské techniky po pozemku

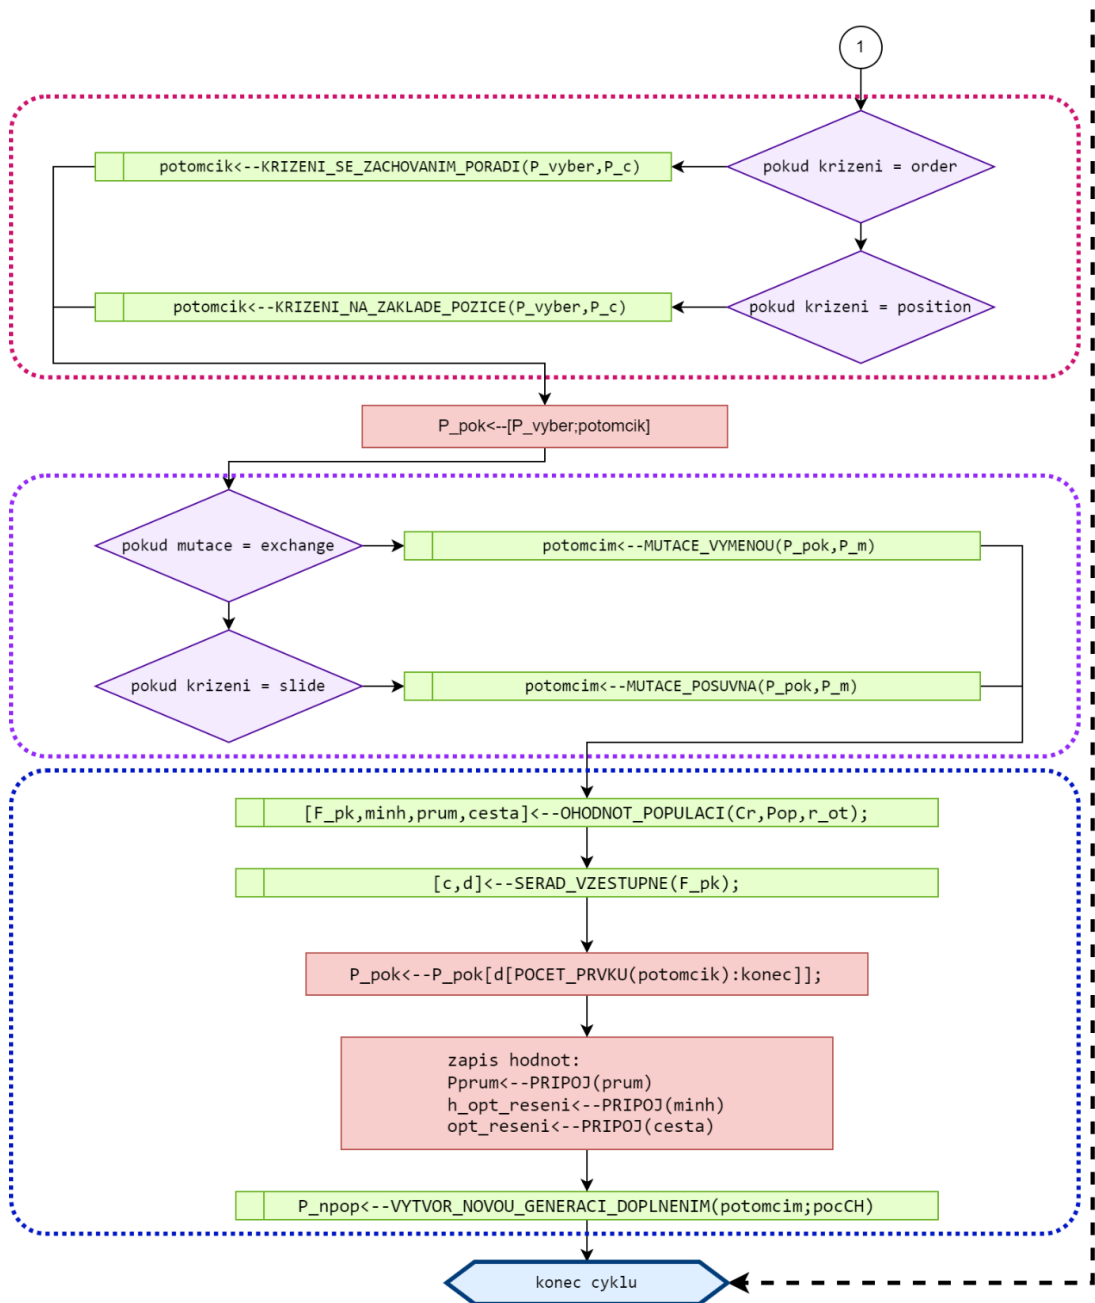
K vstupním parametrům algoritmu patří také záběr operačních prvků vybrané techniky, počet generací, po které bude genetický algoritmus probíhat, počet chromozomů v jedné populaci, tedy počet možných řešení zpracovaných během každé generace, a pravděpodobnost křížení a mutace určující průběh těchto operací. Aplikované algoritmy popisované v rámci následujících částí jsou napsány v programovacím jazyku MATLAB.

3.1 Funkce genetického algoritmu

Vstupy tvoří pole dvojic mezních bodů dílčích rovnoběžných tras pojezdu po pozemku, Cr , o velikosti $1 \times \text{počet_bodů}/2$, přičemž každá buňka je matice o rozměru 2×2 nesoucí v horním řádku informace o souřadnicích x a spodním řádku o souřadnicích y daných bodů, poloměr otáčení, r_ot , počet epoch či tzv. generací, Gen , počet vstupních řešení průjezdů dílčích tras představujících soubor možných řešení tzv. populace nebo také chromozom, $pocCH$, pravděpodobnost křížení, P_c , pravděpodobnost mutace, P_m , typ selekce, sel , typ křížení, $cross$, a typ mutace, mut . K výstupům se řadí list obsahující délky nejkratších tras pojezdu při otáčení z celé populace získané během každé epochy, h_opt , list bodů dílčích tras seřazených v pořadí, ve kterém dosahuje pojezd při otáčení nejmenší délky z celé populace, v němž jsou zahrnuta nejlepší řešení pro každou epochu, opt , a list zaznamenávající průměrné hodnoty délek všech řešení každé jednotlivé epochy, $Pprum$. Na počátku algoritmu je nejprve pomocí inicializační funkce vytvořena skupina prvotních řešení o stanoveném počtu, kdy délka každého řešení odpovídá počtu prvků vstupního pole bodů. Hlavní část se skládá z *for* cyklu opakovaného dle zvoleného počtu epoch, z nichž v každé proběhne generování a úprava prvků skupiny možných řešení, přičemž v generaci 0 je zpracována populace vzniklá při inicializaci, v dalších generacích je operováno s populací vzniklou spojením poloviny nejlepších výstupu z generace $n - 1$ a nově vygenerovaných řešení, tzv. jedinců. Nejprve dochází k ohodnocení vstupních řešení hodnotící funkcí f_GAp02_fit , následně je z nich aplikací selekční funkce vybrána polovina pro další úpravy. Na obrázcích 3.2 a 3.3 je pro lepší orientaci znázorněn vývojový diagram implementovaného genetického algoritmu s popisky ve stylu pseudokódu.



Obrázek 3.2: Vývojový diagram implementovaného genetického algoritmu – část 1



Obrázek 3.3: Vývojový diagram implementovaného genetického algoritmu – část 2

V algoritmu je implementováno devět typů selekce:

- elitářský výběr s pořadovou selekcí,
- elitářský výběr s ruletovou selekcí,
- pořadová selekce,
- pořadová exponenciální,
- pořadová lineární,
- ruletová,
- stochastická univerzální metoda,

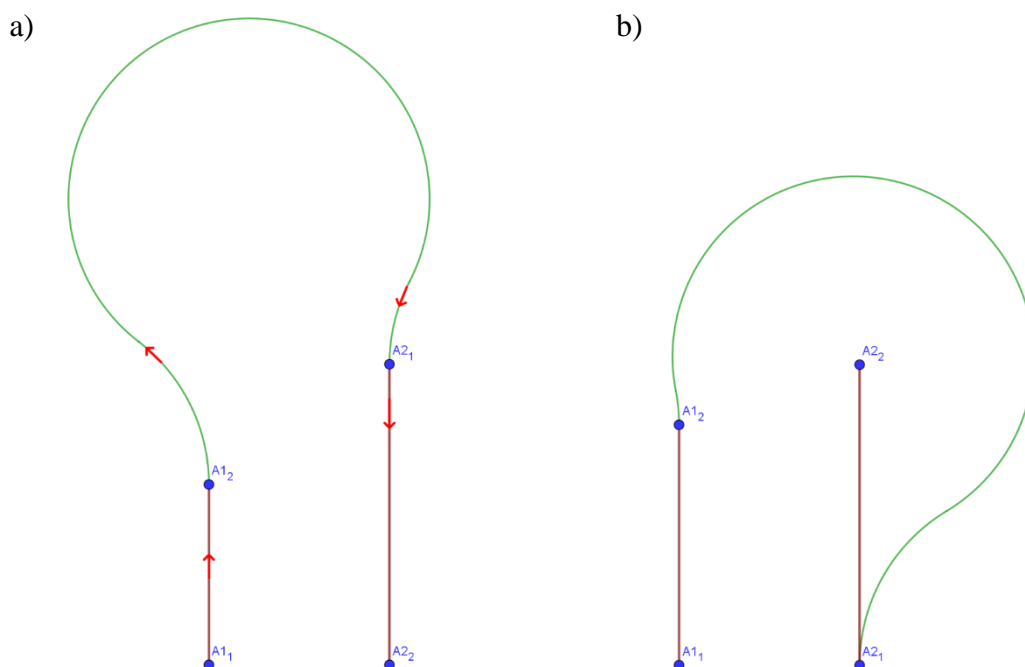
-
- h) turnajová s výběrem dvou jedinců,
 - i) turnajová s výběrem dvou jedinců.

Vybraní jedinci jsou zpracováni metodou křížení, kdy dochází k vytvoření dvou nových kombinací tzv. potomků ze dvou původních, rodičů. Vzhledem k tomu, že se v rámci celé trasy nesmí body opakovat vícekrát, byly vybrány pouze dva typy křížení, v rámci kterých riziko takové situace nehrozí, a to křížení se zachováním pořadí a křížení na základě pozice. Po této operaci jsou vzniklí potomci sloučeni s populací získanou selekcí a celý soubor je podstoupen mutaci, u níž pro výběr metod platí stejná podmínka jako u křížení, implementována je tedy mutace výměnou a posuvná mutace. V dalším kroku je populace znovu ohodnocena a jako základ pro novou populaci je vybrána polovina všech jedinců s nejlepším hodnocením, která je poté pomocí funkce *f_GAp02_fit* doplněna o nově vygenerovaná řešení tak, aby nově vzniklá skupina měla zvolený počet řešení.

3.2 Funkce fitness k ohodnocení jednotlivých řešení

Tato funkce slouží k ohodnocení jednotlivých řešení ze skupin (chromozomů) vzniklých v rámci každého kola cyklu (generace) algoritmu. Hlavní část funkce se skládá ze dvou for cyklů, kdy v rámci vnějšího cyklu dochází k průchodu všech členů souboru vstupních řešení, přičemž jsou pokaždé prvky v poli bodů průjezdu seřazeny dle konkrétního řešení, na konci cyklu dochází k záznamu celkové délky pojezdu po souvraťích pro každé ze vstupních řešení a zápis jednotlivých souborů buněk bodů průjezdu s novým pořadím. Vnitřní cyklus operuje postupně se všemi dvojicemi bodů průjezdu, jež jsou reprezentovány v každé buňce pole, dle daného pořadí, přičemž dochází k výběru dvou po sobě jdoucích buněk A_1, A_2 . První bod buňky A_1 je brán jako bod vstup do první z vybraných dílčích tras, druhý bod, bod A_{1_2} je výstupní, tedy počátek otočky, v prvním bodu buňky A_2 , bodu A_{2_1} je konec otočky a zároveň vstup do druhé z vybraných dílčích tras. Ke správnému provedení otočky musí být vstupní i výstupní bod otočky ve shodné poloze vůči zbývajícím krajním bodům vybraných tras, tedy má-li souřadnice y bodu A_{1_2} větší hodnotu než souřadnice y bodu A_{1_1} , musí mít souřadnice y bodu A_{2_1} větší hodnotu než souřadnice y bodu A_{2_2} , tato situace je znázorněna na obrázku 4.3 a). V případě, že má souřadnice y bodu A_{1_2} větší hodnotu než souřadnice y bodu A_{1_1} a zároveň souřadnice y bodu A_{2_1} menší hodnotu, než souřadnice y bodu A_{2_2} , je třeba pořadí bodů v buňce A_2 převrátit, protože by jinak došlo k vynechání části trasy pojezdu a otočka by zasahovala do vnitřní části pozemku, viz

obrázek 4.3 b). Odpovídající podmínka platí i pro situaci, kdy poloha otočka opačná, tedy mezní body otočky mají souřadnice y s nižší hodnotou než zbylé krajní body vybraných tras. Dále je zjištěna poloha otočky vůči trasám pojezdu, zda se nachází nad či pod body průjezdu, a následně je pomocí funkce $f_So_ot_vz1$ zjištěna délka celé otočky. V rámci algoritmu je proveden součet délek všech otoček provedených během průjezdu pozemku a uložen pro každé zkoumané řešení, zároveň jsou také zapsány jednotlivé soubory buněk bodů průjezdu s upraveným pořadím. Nakonec dochází k ohodnocení každého ze vstupních řešení, výpočtu průměrné vzdálenosti pojezdu po souvratích, nalezení nejlepšího řešení s nejkratší délkou pojezdu v rámci otoček a zápisu bodů trasy průjezdů nejlepšího řešení včetně jejich upraveného pořadí v rámci dílčích tras pojezdu po pozemku.



Obrázek 4.3: Vizualizace průjezdu krajních bodů dvou dílčích tras pojezdu

3.3 Funkce pro výpočet délky otočky

Vstupními parametry této funkce jsou proměnné x_B , y_B , ve kterých jsou zapsány souřadnice dvou sousedních bodů průjezdu pojezdové trasy, $B1$ a $B2$, tak, že x_B obsahuje hodnotu souřadnic na ose x a y_B na ose y . Proměnná r_{ot} je poloměr otáčení techniky a sm vyznačuje, zda je otočka situována nad body průjezdu či pod, tedy zda y -ové složky souřadnic bodů otočky jsou větší než nejmenší y -ové hodnoty vstupních bodů či naopak. Výstupem je délka celé otočky. Po načtení vstupních hodnot jsou nejprve

body seřazeny tak, aby bod $B1$ měl menší souřadnici x než bod $B2$, což zjednodušuje správné vypočítání hodnot středů kružnic, jež jsou součástí dráhy otočky, s ohledem na typ možné situace polohy bodů průjezdu v souvislosti s poloměrem otáčení a směrem průjezdu. Následně je vypočítána horizontální vzdálenost v mezi vstupními body, která slouží jako hlavní část podmínky k výpočtu délky otočky. Pokud je menší a zároveň vzdálenost vstupních bodů je větší než dvojnásobek poloměru otáčení, tak je třeba posunout souřadnici y toho bodu, u kterého má tato souřadnice v absolutní hodnotě nižší hodnotu, blíže k souřadnici y druhého bodu tak, aby vzdálenost bodů byla rovna dvojnásobku poloměru otáčení. V případě, že je otočka nad body průjezdu, tak je bod situovaný níže posunut nahoru ve směru osy y , v opačném případě zase dolů, velikost tohoto posunu, tedy vzdálenost rovna rozdílu mezi původní a novou hodnotou bodu, musí být započítána do celkové délky otočky. Pokud je vzdálenost $|B1B2| > 2r$, otočka směřuje nad body průjezdu a $y_{B1} > y_{B2}$, je tedy třeba posunout bod $B2$ tak, aby $|B1B2'| = 2r$, přičemž bod $B2'$ má souřadnice $[x_{B2}, y_{B2}']$. Novou hodnotu y_{B2}' lze vypočítat jako

$$y_{B2}' = y_{B1} - \sqrt{4r^2 - (x_{B2} - x_{B1})^2}, \quad (3.1)$$

přičemž velikost posunutí, tedy vzdálenost v_{z_0} , je rovno absolutní hodnotě rozdílu souřadnic y původního a posunutého bodu y_{B2}' a y_{B2} .

Postup výpočtu délky celé otočky je rozdělen na tři situace, kdy polovina horizontální vzdálenosti v je menší, rovna či větší než poloměr otáčení. Pokud je vzdálenost mezi vstupními body na ose x je menší než poloměr otáčení, tak se trasa otočky skládá ze tří částí tvořených oblouky, kdy levý a pravý oblouk otočky mají střed v bodech $S1$, $S2$ a střední oblouk v bodu $S0$. V rámci algoritmu jsou vypočítány souřadnice bodů $S1$, kdy x_{S1} je rovno rozdílu x_{B1} a r_{ot} , y_{S1} je rovno y_{B1} , a $S2$, jehož souřadnice x_{S2} je rovna součtu x_{B2} a r_{ot} , y_{S2} je rovno y_{B2} . Střed úsečky $|S1S2|$, bod M se souřadnicemi $\left[\frac{x_{S1}+x_{S2}}{2}, \frac{y_{S1}+y_{S2}}{2}\right]$, je vzor bodu $S0$, který vznikne posunutím ve směru vektoru \vec{n}_u o vzdálenost rovnou délce úsečky $|S0M|$, jenž lze vyjádřit jako

$$|S0M| = \sqrt{(2r)^2 - \left(\frac{|S1M|}{2}\right)^2}, \quad (3.2)$$

kde

$$|S1M| = \sqrt{(x_M - x_{S1})^2 + (y_M - y_{S1})^2}. \quad (3.3)$$

Vektor $\vec{n}_u = (-u_2; u_1)$ je normálovým vektorem ke směrovému vektoru \vec{u} přímky procházející body $S1$ a $S2$, velikost a směr translace M do $S0$ je dán součinem prvků \vec{n}_u s podílem délky úsečky $|S0M|$ a jeho velikosti, tedy

$$S0 = M + \vec{n}_u \frac{|S0M|}{|\vec{n}_u|}. \quad (3.4)$$

V dalším kroku jsou vypočítány souřadnice inflexních bodů $P1$ a $P2$, ve kterých dochází k přechodu mezi oblouky kruhových výsečí tvořícími částí pojezdové trasy, a velikosti příslušných středových úhlů t_0 , t_1 a t_2 v radiánech, jenž odpovídají odchylkám vektorů ramen těchto úhlů vyjádřeným jako

$$\cos\varphi = \frac{\vec{u}\vec{v}}{|\vec{u}||\vec{v}|}, \varphi \in (0^\circ; 180^\circ), \quad (3.5)$$

přičemž pro úhel t_1 lze místo vektorů dosadit $\vec{u} = B1 - S1$ a $\vec{v} = P1 - S1$, a tak

$$t_1 = \arccos\left(\frac{((x_{B1} - x_{S1})(x_{P1} - x_{S1}) + (y_{B1} - y_{S1})(y_{P1} - y_{S1}))}{\sqrt{(x_{B1} - x_{S1})^2 + (y_{B1} - y_{S1})^2} \sqrt{(x_{P1} - x_{S1})^2 + (y_{P1} - y_{S1})^2}}\right). \quad (3.6)$$

Analogicky je dopočítána velikost úhlu t_2 i t_0 , avšak u něj je třeba zjištěnou velikost odečíst od 2π , protože se jedná o konkávní úhel tvořící doplněk spočítaného konvexního úhlu $\sphericalangle S2S0S1$, což vyplývá z vlastností vzorce 3.5. Celková délka otočky činní suma délek jednotlivých obloukových částí trasy, které jsou vyjádřeny součinem poloměru otáčení a velikostí příslušného úhlu, a vzdálenosti vz_0 nabývající hodnoty 0 při zachování vertikální polohy obou bodů, či nenulové hodnoty v případě, že $|B1B2| > 2r$.

3.4 Funkce selekce

Implementované selekční funkce mají podobné, v některých případech i stejné, části zdrojového kódu zaměřeného na výběr jedinců k dalšímu zpracování, a tak u první popisované funkce zaměřené na pořadovou selekci bude ukázán kompletní zdrojový kód a funkce bude popsána podrobněji, u dalších již jen rozdílné části. Vstupní parametry jsou pro všechny funkce stejné, jedná se o soubor chromozomů *populace* o velikosti N_p a list zahrnující jejich ohodnocení *fit*. Výstupem je skupina vybraných chromozomů *P_vyber* s polovičním počtem prvků oproti vstupnímu souboru. V rámci funkce je nejprve získán počet vybíraných chromozomů, jež je roven $\frac{N_p}{2}$, poté je seřazen list *fit* obsahující hodnoty získané hodnotící funkcí, přičemž funkce *sort* provede řazení hodnot se zachováním informace o původním pořadí každého

prvku, které jsou zaznamenány do listu por . Poté je vygenerován list hodnot $p_rank = \{N_p, N_p - 1, N_p - 2, \dots, 1\}$ v posloupnosti klesající o 1 v rozmezí hodnoty počtu členů N_p až 1, ze které je vydělením každého členu listu sumou hodnot všech členů, dle vzorce 3.7, získán list pravděpodobností výběru úměrných hodnotě nového pořadí seřazených chromozomů p_v , na základě jehož členů je sestavena stupnice r tvořící nedílnou součást samotného výběru chromozomů.

$$p_{v_i} = \frac{p_{rank_i}}{\sum_{j=0}^{N_p} p_{rank_j}}, i = \{1, \dots, N_p\}, \quad (3.7)$$

Sestavení stupnice pro výběr probíhá pomocí *for* cyklu, kdy proměnná i nabývá hodnot od 2 do počtu prvků listu p_v , přičemž hodnota prvku stupnice je rovna součtu i posledních prvků p_v , viz vzorec 3.8, po skončení cyklu je na konec škály přidána 0.

$$r_{j-1} = \sum_{i=j}^{N_p} p_{v_i}, j = \{2, \dots, N_p\}, \quad (3.8)$$

Následně jsou v cyklu *for* probíhajícího n -krát, kdy n je rovno polovině počtu vstupních řešení, vybírány chromozomy pomocí náhodně vygenerované hodnoty a z rozmezí $\langle 0; 1 \rangle$, přičemž je tato hodnota porovnávána se členy stupnice a dochází k hledání nejmenší hodnoty stupnice, která je větší nebo rovna hodnotě a , avšak zaznamenána není nalezená hodnota ale její poloha (pořadí) r_m na stupnici. Finální výběr probíhá nalezením hodnoty v listu por s indexem r , která poslouží jako index vybíraného řešení v rámci vstupní populace.

Selekce pořadová lineární i exponenciální se liší od standardní pořadové pouze ve způsobu vytvoření listu p_v , přičemž jeho prvky vytvořeny dle vzorce 3.9 a 3.10, u lineární pořadové selekce je zaveden parametr SP představující selektivní tlak nabývající hodnot z intervalu $\langle 1; 2 \rangle$ a u exponenciální se zde vyskytuje parametr c ovlivňující rozložení pravděpodobnosti výběru jednotlivých řešení, pro který platí $0 < c < 1$.

$$p1_i = 2 - SP + \frac{2(SP - 1)(P_{rank_i} - 1)}{|P_{rank}| - 1} \quad (3.9)$$

$$p1_i = \frac{c^{|P_{rank}| - P_{rank_i}}}{\sum_{j=0}^{|P_{rank}|} c^{|P_{rank}| - P_{rank_j}}} \quad (3.10)$$

Ruletová selekce je založena na stejném principu jako selekce pořadové, s tím rozdílem, že pravděpodobnost výběru je přímo ovlivněna hodnotou fit nikoliv jejím pořadím vůči celku, hodnoty prvků listu p_v jsou rovny podílu odpovídajících hodnot fit a součtu všech hodnot fit, viz vzorec 3.11.

$$p1_i = \frac{fit_i}{\sum_{j=0}^N fit_j}. \quad (3.11)$$


V algoritmu je také implementován elitářský výběr ve dvou variantách, při kterém probíhá výběr stanovené části chromozomů s nejvyšším ohodnocením, tedy n nejlepších řešení, následně je počet zbývajících do poloviny velikosti celé populace $\frac{N_p}{2} - n$ vybrán pomocí pořadové či ruletové selekce.

Stochastická univerzální metoda pracuje se stejnou pravděpodobností výběru jako ruletová selekce, rozdíl je však ve způsobu výběru, kdy je nejprve vygenerována náhodná hodnota u z intervalu $\langle 0; \frac{\sum_{j=0}^N fit_j}{N_{pop}/2} \rangle$, přičemž hodnoty v , na jejichž základě probíhá výběr, jsou vypočítány dle vzorce 3.12

$$v_i = \left(\frac{N_{pop}}{2} - i \right) * \frac{\sum_{j=0}^N fit_j}{\frac{N_{pop}}{2}} + u, i = \left\{ 1, \dots, \frac{N_{pop}}{2} \right\}. \quad (3.12)$$

4 Vybrané výsledky a diskuse


Aplikací implementovaných algoritmů byly v rámci stanovených vstupních parametrů generovány kombinace pořadí průjezdu dílčích tras pojezdu techniky po pozemku za účelem nalezení optimálního řešení, při kterém bude délka pojezdu v rámci otáčení na souvratích minimalizována. Porovnání metod zahrnutých do genetického algoritmu, tedy typů selekce, křížení a mutace, a zvolených proměnných v podobě počtu generací, velikosti populace, pravděpodobnosti mutace či křížení, bylo provedeno na vygenerovaném pozemku znázorněném včetně dílčích tras člunkového pojezdu na obrázku 4.1, zvolená hodnota pro záběr pracovního nástroje byla 3,5 m a poloměr otáčení 5 m. Všechny získané hodnoty jsou průměrem padesáti opakování, tedy dále často zmiňovaná hodnota „Minimální celková délka tras při otáčení“ je průměrem minimálních hodnot získaných během jednotlivých epoch každého z padesáti průběhů celého algoritmu, zároveň je v každé generaci vypočítán průměr ze všech řešení, chromozomů, v populaci a tato hodnota je znovu průměrována vzhledem k opakovaným cyklům.




Obrázek 4.1: Znázornění vygenerovaného testovacího pozemku s trajektorií člunkového pojezdu

4.1 Analýza výsledků z hlediska vlivu velikosti populace

Pro sledování vlivu velikosti populace a počtu generací byla zvolena pořadová selekce, křížení na základě pozice s pravděpodobností 0,9 a posuvná mutace s pravděpodobností 0,2. Výpočty probíhaly až do 1000 generací, přičemž velikost populace charakterizovaní počtem chromozomů, kdy jeden chromozom představuje možné řešení průjezdu dílčích tras, nabývá hodnot 50, 100, 200, 500, 1000, 2000, 3000, 5000, 10000. Z grafu 4.1 zobrazujícího minimální celkovou délku tras při otáčení, je patrné, že během generací dochází k nalezení optimálnějších řešení s menší hodnotou délky pojezdu u populací všech testovaných velikostí, k nejrychlejší konvergenci vzhledem k minimální hodnotě v generaci 1000 dochází u populace s 10000 chromozomy, jenž dosahuje také nejlepšího řešení z testovaných velikostí populací, nejhorších výsledků dosahuje populace nejmenší. Nejstrmější průběh křivky lze sledovat v rozmezí generací 0 až 200 napříč všemi uvedenými počty chromozomů, například v rámci prvních 100 epoch klesla hodnota u největší populace o více než 30 % a při tisíci chromozomech téměř o 36 %. Ve výřezu oblasti grafu 4.1 o intervalu $\langle 900; 1000 \rangle$ na ose y a $\langle 0; 60 \rangle$ na ose x červenou přerušovanou čarou vynesena celková délka otoček při člunkovém pohybu techniky, která pro zkoumaný pozemek činí 966,747 m, tuto hodnotu překonávají řešení s počtem 500-10000 chromozomů již před generací 10 a nejmenší populace dosahuje stabilně lepších výsledků od 30. epochy.



Obrázek 4.2: Znárodnění vygenerovaného testovacího pozemku s optimální trajektorií získanou v rámci populace velikosti 10000 v generaci 1000



Graf 4.1: Minimální celková délka tras při otáčení v průběhu generací 0 až 1000 pro vybrané velikosti populace, selekce pořadová, křížení na základě pozice s pravděpodobností 0,9, posuvná mutace s pravděpodobností 0,2 [m]

Tabulka 4.1 ukazuje hodnoty minimální celkové délky tras při otáčení ve vybraných generacích, kdy s rostoucím počtem chromozomů dochází k získání lepších výsledků, což může být spojeno s vyšší diverzitou u větších populací vedoucí k možnému zvýšení pravděpodobnosti nalezení lepšího řešení. Vygenerované výsledky se zlepšují také s počtem generací, což odpovídá principu fungování genetických algoritmů. Nejvyšší hodnoty, 1146,27 m, což je 118,57 % délky člunkového pojezdu viz tabulka

4.2, dosahuje populace s 50 chromozomy v generaci 0, naopak největší populace dosáhla nejnižší hodnoty, 599,49 m, v poslední generaci. Z hlediska rozdílu hodnot v generaci 1000 je největší rozdíl u menších populací, kdy velikostně po sobě jdoucí populace mají rozdíl pohybující se okolo 3 % vůči populaci předchozí, u populace 1000 a 2000 chromozomů dochází ke snížení rozdílu k 1,5 %, mezi generacemi 2000 a 3000 je rozdíl nepatrný a následně se pohybuje v rozmezí 0,5-1 %.

Tabulka 4.1: Minimální celková délka tras při otáčení v průběhu vybraných generací z rozsahu 0 až 1000 pro vybrané velikosti populace, selekce pořadová, křížení na základě pozice s pravděpodobností 0,9, posuvná mutace s pravděpodobností 0,2 [m]

P _{CH} ¹	Generace								
	0	100	200	300	400	500	600	800	1000
50	1146,27	845,95	786,04	753,02	733,92	726,36	716,63	699,66	689,76
100	1123,36	783,26	729,32	711,36	701,41	690,81	681,73	674,27	667,08
200	1083,85	730,63	695,00	678,34	667,61	662,04	657,21	652,00	647,40
500	1063,76	697,17	663,22	650,07	643,18	637,92	634,60	629,54	627,95
1000	1041,19	667,68	640,99	631,36	626,50	623,10	622,11	619,76	618,47
2000	1017,24	651,64	624,13	617,18	614,35	613,08	611,76	610,34	609,84
3000	1016,90	647,40	620,31	615,97	613,06	612,16	611,00	610,40	609,87
5000	999,85	646,06	615,76	609,76	608,31	607,37	606,90	605,65	605,36
10000	978,98	636,74	606,18	601,93	601,47	600,92	600,30	599,98	599,49
Čl. p. ²	966,747								

V porovnání s člunkovým pojezdem nedochází k nalezení lepšího řešení během nulté generace v žádné populaci, avšak v generaci 100 je tento způsob pojezdu překonán o více než 12 % u nejmenší populace a o téměř 35 % u populace největší, úplně nejlepší řešení vykazuje v poslední generaci o 37,99 % menší délku pojezdu. Z tabulky 4.2 je rovněž zjevné, že úsporu 30 % a více zajistí všechny populace obsahující alespoň 100 chromozomů, přičemž jejich počet má důležitý vliv na počet epoch potřebných k dosažení této hodnoty, kdy se u větších populací objevují lepší hodnoty při nižším počtu generací než u populací s menším počtem chromozomů.

¹ Počet chromozomů v populaci

² Člunkový pojezd

Tabulka 4.2: Poměr minimální celkové délky tras při otáčení v průběhu generací 0 až 1000 pro vybrané velikosti populace vůči délce otoček při člunkovém pojezdu [%]

P _{CH}	Generace								
	0	100	200	300	400	500	600	800	1000
50	118,57	87,51	81,31	77,89	75,92	75,13	74,13	72,37	71,35
100	116,20	81,02	75,44	73,58	72,55	71,46	70,52	69,75	69,00
200	112,11	75,58	71,89	70,17	69,06	68,48	67,98	67,44	66,97
500	110,04	72,11	68,60	67,24	66,53	65,99	65,64	65,12	64,96
1000	107,70	69,06	66,30	65,31	64,81	64,45	64,35	64,11	63,97
2000	105,22	67,41	64,56	63,84	63,55	63,42	63,28	63,13	63,08
3000	105,19	66,97	64,16	63,72	63,42	63,32	63,20	63,14	63,09
5000	103,42	66,83	63,69	63,07	62,92	62,83	62,78	62,65	62,62
10000	101,27	65,86	62,70	62,26	62,22	62,16	62,09	62,06	62,01

S rostoucí velikostí populace je spojena i zvyšující se časová náročnost výpočtů, což je přímo spojeno s vyšším počtem provedených operací. Nejmenší průměrný čas potřebný pro průběh 100 generací je 1,71 s při skupině řešení o 50 chromozomech, největší skupina potřebuje pro vygenerování stejného počtu generací 382,83 s, trend růstu potřeby výpočetního času je úměrný také množství provedených epoch, viz tabulka 4.3.

Tabulka 4.3: Celkový čas potřebný k výpočtu minimální délky pojezdových tras při otáčení pro zvolený počet generací a velikost populace [s]

P _{CH}	Generace								
	0	100	200	300	400	500	600	800	1000
50	0,0170	1,71	3,41	5,11	6,80	8,50	10,20	13,59	16,99
100	0,0322	3,25	6,48	9,70	12,92	16,14	19,36	25,81	32,25
200	0,0640	6,46	12,86	19,25	25,65	32,05	38,44	51,24	64,03
500	0,1559	15,74	31,33	46,92	62,51	78,10	93,69	124,86	156,04
1000	0,3048	30,78	61,26	91,74	122,22	152,70	183,18	244,13	305,09
2000	0,5587	56,43	112,30	168,17	224,04	279,91	335,78	447,51	559,25
3000	0,9282	93,75	186,58	279,40	372,22	465,05	557,87	743,52	929,17
5000	1,5045	151,96	302,41	452,86	603,31	753,77	904,22	1205,12	1506,03
10000	3,7904	382,83	761,88	1140,92	1519,96	1899,00	2278,05	3036,13	3794,22

Vzhledem ke značným rozdílům výpočetního času napříč populacemi i generacemi a méně enormní diverzity minimálních vzdáleností je třeba zvolit optimální nastavení parametrů nalezení vyváženosti mezi kvalitou výsledků a časovou náročností. Tabulky 4.4 a 4.5 znázorňují bodové ohodnocení optimální kombinace počtu generací a velikosti populace s ohledem na výpočetní čas a minimální vzdálenost pojezdu při stanovených váhách. Posouzení jednotlivých variací bylo provedeno na základě propojení tabulky 4.2 a tabulky 4.3 převedené do procentuálních hodnot, kdy je hodnota buňky $b_{m,n}$ v nové tabulce na místě m, n rovna součtu součinu hodnoty buňky $t_{m,n}$ z upravené tabulky 4.3 a váhy u a součinu $s_{m,n}$ z tabulky 4.2 a váhy $100 - u$, viz vzorec 4.1.

$$b_{m,n} = t_{m,n}u + s_{m,n}(100 - u), u \in \langle 0; 100 \rangle \quad (4.1)$$

Pokud je při výpočtu dána priorita době jeho trvání, tak $u > 50$, v případě přiřazení vyššího důrazu kvalitě výsledků nabývá váha u hodnot nižších, neoptimálnější jsou konfigurace s nejnižší hodnotou v tabulce. Z tabulky 4.4 vyplývá, že i při vyšší potřebě krátkého výpočetního času, kdy poměr vah 90 ku 10 ve prospěch času, není nejrychlejší varianta optimální, ale nejvhodnější volbou je populace o počtu 200 chromozomů za průběhu 200-400 generací. Dle tabulky 4.5, kde je kladen důraz především na získání vysoké kvality řešení s nízkým ohledem na čas v poměru, se nachází nejvíce optimální nastavení také při volbě 2000 chromozomů se zpracováním po 300-600 epoch.

Tabulka 4.4: Bodové ohodnocení znázorňující optimální konfigurace počtu generací a velikosti populace pro váhové ohodnocení 90:10

P _{CH}	Generace							
	100	200	300	400	500	600	800	1000
50	8,79	8,21	7,91	7,75	7,72	7,65	7,56	7,53
100	8,18	7,70	7,59	7,56	7,53	7,51	7,59	7,64
200	7,71	7,49	7,47	7,51	7,61	7,71	7,96	8,08
500	7,58	7,60	7,84	8,14	8,45	8,79	9,47	9,84
1000	7,64	8,08	8,71	9,38	10,07	10,78	12,20	12,92
2000	8,08	9,12	10,37	11,67	12,98	14,29	16,93	18,25
3000	8,92	10,84	13,00	15,17	17,36	19,55	23,95	26,15
5000	10,29	13,54	17,05	20,60	24,16	27,73	34,85	38,42
10000	15,67	24,34	33,29	42,28	51,26	60,25	78,22	87,21


Tabulka 4.5: Bodové ohodnocení znázorňující optimální konfigurace počtu generací a velikosti populace pro váhové ohodnocení 10:90

P _{CH}	Generace							
	100	200	300	400	500	600	800	1000
50	78,76	73,19	70,12	68,34	67,64	66,74	65,17	64,59
100	72,93	67,91	66,25	65,33	64,35	63,52	62,84	62,60
200	68,04	64,74	63,20	62,22	61,72	61,28	60,83	60,58
500	64,94	61,83	60,64	60,04	59,59	59,33	58,94	58,91
1000	62,24	59,83	59,02	58,65	58,41	58,40	58,34	58,34
2000	60,81	58,40	57,90	57,78	57,81	57,84	58,00	58,10
3000	60,52	58,24	58,08	58,05	58,22	58,35	58,79	59,02
5000	60,55	58,12	57,96	58,22	58,53	58,88	59,56	59,95
10000	60,29	58,44	59,04	60,00	60,95	61,89	63,86	64,82

4.2 Analýza výsledků s ohledem na vliv typu selekční metody

Data pro porovnání selekčních metod byla získána při nastavení velikosti populace 1000 chromozomů, křížení na základě pozice s pravděpodobností 0,9 a posuvné mutace s pravděpodobností 0,2, celý proces probíhal po 1000 generací. Nejlepších výsledků dosahovala turnajová selekce v obou variantách, viz graf 4.2, přičemž při výběru porovnáním dvou chromozomů konvergovala pomaleji než při porovnání tří, například v generaci 200 vykazovala o 11,33 % vyšší hodnoty, avšak v generaci 400 činil rozdíl nepatrných 0,31 % a v poslední epoše již vygenerovala 0,31 % lepší řešení. Selektce pořadová, elitní v kombinaci s pořadovou i ruletovou a pořadová lineární vykazovaly taktéž obstojné výsledky lišící se v generaci 1000 od turnajové metody o 2,10-2,76 %, ale průběh pořadové lineární selekce byl až do generace 500 rozdílný z hlediska rychlosti poklesu hodnot, kdy ještě v generaci 200 má nalezená minimální trasa o 14,20 % větší délku než v případě selekce pořadové. Pořadová exponenciální má zajímavý průběh během prvních 50 generací, kdy překonává ostatní testované typy, výrazný pokles hodnot se však rychle zpomaluje a od epochy 126 je zcela zastaven, což je pravděpodobně dáno vysokou hodnotou základu exponentu 0,9 z intervalu (0; 1), v případě volby nižšího základu by měl být očekávaný průběh křivky méně strmý. Ruletová selekce se neprokázala jako vhodná volba pro řešenou problematiku, dosahovala jednoznačně nejhorších výsledků, které ani po uplynutí 1000 generací nepřekonaly člunkový pojezd, což může být zapříčiněno menšími rozdíly po ohodnocení


mezi jednotlivými chromozomy vstupní populace, čímž může docházet k náhodnému výběru nevhodných řešení. Tento problém je u ostatních typů selekce ošetřen, například nahrazením hodnoty fitness hodnotou pořadí, přičemž jsou i menší rozdíly po ohodnocení pořadím zvýrazněny, nebo výběrem části nejlepších chromozomů.



Graf 4.2: Minimální celková délka tras při otáčení v průběhu generací 0 až 1000 pro vybrané typy selekce, velikost populace 1000, křížení na základě pozice s pravděpodobností 0,9, posuvná mutace s pravděpodobností 0,2 [m]

4.3 Analýza výsledků s ohledem na vliv typu a pravděpodobnosti křížení


Pro porovnání vybraných typů křížení a ověření vztahu mezi velikostí pravděpodobnosti křížení P_c a kvalitou výsledných řešení byla data vygenerována pro populaci 1000 chromozomů, pořadovou selekci a posuvnou mutaci s pravděpodobností 0,2.



Graf 4.3: Minimální celková délka tras při otáčení v průběhu generací 0 až 1000 pro křížení se zachováním pořadí realizované s vybranými pravděpodobnostmi, velikost populace 1000, pořadová selekce, posuvná mutace s pravděpodobností 0,2 [m]

Z grafů 4.3 a 4.4 je jasně patrný trend zlepšujících se výsledků v průběhu generací, který je výraznější se zvyšující se pravděpodobností křížení u typu na základě pořadí

i na základě pozice, avšak první typ dosahuje nižších hodnot téměř při každé pravděpodobnosti v průběhu všech generací, například pro $P_c = 0,9$ v poslední generaci má minimální hodnotu 612,73 m oproti 618,47 m. Z grafu 4.3 dále vyplývá, že pro nízký počet generací při aplikaci křížení se zachováním pořadí je vhodnější zvolit druhou největší pravděpodobnost křížení, a to až do generace 110, poté je již při $P_c = 0,99$ dosaženo nižších hodnot, stejná situace nastává i u křížení na základě pozice, viz graf 4.4.



Graf 4.4: Minimální celková délka tras při otáčení v průběhu generací 0 až 1000 pro křížení na základě pozice realizované s vybranými pravděpodobnostmi, velikost populace 1000, pořadová selekce, posuvná mutace s pravděpodobností 0,2 [m]

Závěr

Aplikací genetických algoritmů při optimalizaci pojezdových tras zemědělské techniky lze dosáhnout výrazného zkrácení délky otoček realizovaných při přejezdech mezi dílčími drahami ve vnitřní části pole, kdy může dojít ke snížení vzdálenosti i o více než 37 %, což může přímo vést k úsporám pracovního času, pohonných hmot a nižšímu zhutnění půdy na souvratích. Značný vliv na kvalitu nalezeného řešení má velikost populace chromozomů, tedy skupina možných řešení, i počet generací během nichž dochází evolučním úpravám zlepšujícím výsledky, přičemž se zvyšováním těchto parametrů dochází ke generování optimálnějších řešení, avšak s tím je spojen i růst výpočetního času. Během testování implementovaných algoritmů se ukázalo, že volba nejvyšších hodnot velikosti populace i počtu provedených epoch není vždy nejvhodnější, protože získání o několik procent kratší trasy je za cenu značného navýšení času simulace. Výběr selekční metody může také do kvality výsledků zasáhnout, například ruletová selekce se prokázala jako zcela nevhodná pro využití v této problematice, naopak turnajový či pořadový typ vykazovaly velmi dobré hodnoty. Genetické algoritmy prokázaly svůj význam při řešení problematiky pohybu zemědělských strojů po pozemku, avšak oblast metaheuristických algoritmů je rozsáhlá a zahrnuje velké množství optimalizačních metod, které mají v zemědělství široké použití, z nichž lze mnohé navrhnout pro implementaci do stávajícího modelu.

Seznam použité literatury

- Alaiso, S., Backman, J., & Visala, A. (2013). Ant Colony Optimization for Scheduling of Agricultural Contracting Work. *Ifac Proceedings Volumes*, 46(18). <https://doi.org/10.3182/20130828-2-SF-3019.00041>
- Ali, H., Gong, D., Wang, M., & Dai, X. (2020). Path Planning of Mobile Robot With Improved Ant Colony Algorithm and MDP to Produce Smooth Trajectory in Grid-Based Environment. *Frontiers In Neurorobotics*, 14. <https://doi.org/10.3389/fnbot.2020.00044>
- Alipour, M. M. et al. (2018). A hybrid algorithm using a genetic algorithm and multiagent reinforcement learning heuristic to solve the traveling salesman problem. *Neural Computing and Applications*. Springer London, 30(9). <https://doi.10.1007/s00521-017-2880-4>.
- Amal, L., Son, L. H. and Chabchoub, H. (2018). SGA: spatial GIS-based genetic algorithm for route optimization of municipal solid waste collection. *Environmental Science and Pollution Research*. *Environmental Science and Pollution Research*, 25(27). <https://doi.10.1007/s11356-018-2826-0>.
- Assaf, R. and Saleh, Y. (2017). Vehicle-Routing Optimization for Municipal Solid Waste Collection Using Genetic Algorithm: The Case of Southern Nablus City. *Civil and Environmental Engineering Reports*, 26(3). <https://doi.10.1515/ceer-2017-0034>.
- Barrientos, A., Colorado, J., Cerro, J. del, Martinez A., Rossi, C., Sanz, D., Valente, J. (2011). Aerial remote sensing in agriculture: A practical approach to area coverage and path planning for fleets of mini aerial robots. *J. Field Robot.*, 28(5). <https://doi.org/10.1002/rob.20403>
- Behnck, L. P., Doering, D., Pereira, C. E., & Rettberg, A. (2015). A Modified Simulated Annealing Algorithm for SUAVs Path Planning. *Ifac-Papersonline*, 48(10). <https://doi.org/10.1016/j.ifacol.2015.08.109>
- Bochtis, D.D. et Vougioukas, S.G. (2008). Minimising the non-working distance travelled by machines operating in a headland field pattern. *Biosyst. Eng.*, 101(1). <https://doi.org/10.1016/j.biosystemseng.2008.06.008>
- Bulgakov, V., Pascuzz, S., Nadykto, V., Adamchuk, V., Kaminskiy, V., Kyurchev, V., Santoro, F. (2022). Effects of Tractor and Soil Parameters on the Depth of
-

-
- the Permanent Traffic Lanes in Controlled Traffic Farming Systems. *Applied Sciences.*, 12(13). <https://doi.org/10.3390/app12136620>
- Cárceles Rodríguez B, Durán-Zuazo VH, Soriano Rodríguez M, García-Tejero IF, Gálvez Ruiz B, Cuadros Tavira S. (2022). Conservation Agriculture as a Sustainable System for Soil Health: A Review. *Soil Systems*, 6(4). <https://doi.org/10.3390/soilsystems6040087>
- Centeri C. (2022). Effects of Grazing on Water Erosion, Compaction and Infiltration on Grasslands. *Hydrology*, 9(2). <https://doi.org/10.3390/hydrology9020034>
- Conesa-Muñoz, J. et al. (2016). Route planning for agricultural tasks: A general approach for fleets of autonomous vehicles in site-specific herbicide applications. *Computers and Electronics in Agriculture.*, 127. <https://doi.org/10.1016/j.compag.2016.06.012>
- Dao, S. D., Abhary, K. and Marian, R. (2017). A bibliometric analysis of Genetic Algorithms throughout the history. *Computers and Industrial Engineering.* Elsevier Ltd, 110. <https://doi.10.1016/j.cie.2017.06.009>.
- Darwish, A.; Hassanién, A.E.; Das, S. (2020). A survey of swarm and evolutionary computing approaches for deep learning. *Artif. Intell. Rev.*, 53. <https://doi.org/10.1007/s10462-019-09719-2>
- Das, P. K. et Jena, P. K. (2020). Multi-robot path planning using improved Particle Swarm Optimization algorithm through novel evolutionary operators. *Appl. Soft Comput. J. Elsevier B.V.*, 92. <https://doi.org/10.1016/j.asoc.2020.106312>.
- de Lima, R.P., da Silva, A.P., Giarola, N.F.B, da Silva, A.R., Rolim, M.M. (2017). Changes in soil compaction indicators in response to agricultural field traffic. *Biosystems Engineering*, 162. <https://doi.org/10.1016/j.biosystemseng.2017.07.002>.
- Dhiman, G. et Kumar, V. (2017). Spotted hyena optimizer: A novel bio-inspired based metaheuristic technique for engineering applications. *Adv. Eng. Softw.*, 114. <https://doi.org/10.1016/j.advengsoft.2017.05.014>
- Edwards, G.T.C, Hinge, J., Skou-Nielsen, N., Villa-Henriksen, A., Sørensen, C.A.G, Green, O. (2017). Route planning evaluation of a prototype optimised infield route planner for neutral material flow agricultural operations. *Biosystems Engineering*, 153. <https://doi.org/10.1016/j.biosystemseng.2016.10.007>.
-

-
- Elferchichi, A. et al. (2009). The genetic algorithm approach for identifying the optimal operation of a multi-reservoirs on-demand irrigation system. *Biosystems Engineering. IAgRE*, 102(3). <https://doi.10.1016/j.biosystemseng.2008.12.009>.
- Elhoseny, M., Tharwat, A. and Hassanien, A. E. (2018). Bezier Curve Based Path Planning in a Dynamic Field using Modified Genetic Algorithm. *Journal of Computational Science. Elsevier B.V.*, 25. <https://doi.10.1016/j.jocs.2017.08.004>.
- Feng, Z. (2020). Constructing rural e-commerce logistics model based on ant colony algorithm and artificial intelligence method. *Soft Comput. Springer Berlin Heidelberg*, 24(11). <https://doi.org/10.1007/s00500-019-04046-8>.
- Ferreira Neto, J. A. et al. (2011). Optimal subdivision of land in agrarian reform projects: an analysis using genetic algorithms. *Ciencia e investigación agraria*, 38(2). <https://doi.10.4067/rcia.v38i2.111>.
- Francik, S., Knapczyk, A., Wójcik, A., Ślipek, Z. (2020). Optimisation Methods in Renewable Energy Sources Systems—Current Research Trends. In: Wróbel, M., Jewiarz, M., Szlęk, A. (eds) *Renewable Energy Sources: Engineering, Technology, Innovation. Springer Proceedings in Energy. Springer, Cham*. https://doi.org/10.1007/978-3-030-13888-2_81
- Gracia, C., Diezma-Iglesias, B. and Barreiro, P. (2013). A hybrid genetic algorithm for route optimization in the bale collecting problem. *Spanish Journal of Agricultural Research*, 11(3). <https://doi.10.5424/sjar/2013113-3635>.
- Han, Z., Wang, D., Liu, F., Zhao, Z. (2017). Multi-AGV path planning with double-path constraints by using an improved genetic algorithm. *PLoS ONE*, 12(7). <https://doi.org/10.1371/journal.pone.0181747>
- He, P., Li, J., & Wang, X. (2018) Wheat harvest schedule model for agricultural machinery cooperatives considering fragmental farmlands. *Comput. Electron. Agric.*, 145. <https://doi.org/10.1016/j.compag.2017.12.042>
- He, Z., Bao, Y., Yu, Q., Lu, P., He, Y., Liu, Y. (2023). Dynamic path planning method for headland turning of unmanned agricultural vehicles. *Computers and Electronics in Agriculture*, 236. <https://doi.org/10.1016/j.compag.2023.107699>.
- Hilal, Y. Y. et al. (2018). Development of genetic algorithm for optimization of yield models in oil palm production. *Chilean journal of agricultural research*, 78(2). <https://doi.10.4067/S0718-58392018000200228>.
-

-
- Hu, Y., Liu, Y., Wang, Z., Wen, J., Li, J., & Lu, J. (2020). A two-stage dynamic capacity planning approach for agricultural machinery maintenance service with demand uncertainty. *Biosyst. Eng.*, 190.
<https://doi.org/10.1016/j.biosystemseng.2019.12.005>
- Hussein, M.A., Antille, D.L., Kodur, S., Chen, G., Tullberg, J.N. (2021). Controlled traffic farming effects on productivity of grain sorghum, rainfall and fertiliser nitrogen use efficiency. *Journal of Agriculture and Food Research*, 3.
<https://doi.org/10.1016/j.jafr.2021.100111>.
- Ikeda, Y. and Inoue, M. (2016). An Evacuation Route Planning for Safety Route Guidance System after Natural Disaster Using Multi-objective Genetic Algorithm. *Procedia Computer Science*. The Author(s), 96.
<https://doi.org/10.1016/j.procs.2016.08.177>.
- Joo, H. and Lim, Y. (2018). Ant colony optimized routing strategy for electric vehicles. *J. Adv. Transport*. <https://doi.org/10.1155/2018/5741982>.
- Kaur, S., Awasthi, L.K., Sangal, A.L., Dhiiman, G. (2020). Tunicate Swarm Algorithm: A new bio-inspired based metaheuristic paradigm for global optimization. *Engineering Applications of Artificial Intelligence*, 90.
<https://doi.org/10.1016/j.engappai.2020.103541>.
- Khishe, M. et Mosavi, M.R. (2020). Chimp optimization algorithm. *Expert Syst. Appl.*, 149. <https://doi.org/10.1016/j.eswa.2020.113338>
- Koca, G. O., Dogan, S. and Yilmaz, H. (2018). A multi-objective route planning model based on genetic algorithm for cuboid surfaces. *Automatika*, 59(1).
<https://doi.org/10.1080/00051144.2018.1498205>.
- Kumhála F., Gutu D., Hůla J., Chyba J., Kovaříček P., Krouhlík M., Kvíz Z., Mašek J., Vlášková M. (2013). *Technologie řízených přejezdů po pozemcích: uplatněná certifikovaná metodika*. Česká zemědělská univerzita, Technická fakulta, Praha. ISBN 978-80-213-2425-1.
- Kurnia, H. et al. (2018). Vehicle Routing Problem Using Genetic Algorithm with Multi Compartment on Vegetable Distribution. *IOP Conference Series: Materials Science and Engineering*, 325(1). <https://doi.org/10.1088/1757-899X/325/1/012012>.
- Kwaśniewski, K. K. et Gosiewski, Z. (2018). Genetic algorithm for mobile robot route planning with obstacle avoidance. *Acta Mechanica et Automatica*, 12(2).
<https://doi.org/10.2478/ama-2018-0024>.
-

-
- Lamini, C., Benhlina, S. and Elbekri, A. (2018). Genetic algorithm based approach for autonomous mobile robot path planning. *Procedia Computer Science*. Elsevier B.V., 127. <https://doi.org/10.1016/j.procs.2018.01.113>.
- Lee, H. Y., Shin, H. and Chae, J. (2018). Path planning for mobile agents using a genetic algorithm with a direction guided factor. *Electronics (Switzerland)*, 7(10). [https://doi.org/10.1016/S1067-2516\(09\)80071-9](https://doi.org/10.1016/S1067-2516(09)80071-9).
- Leitold, D., Vathy-Fogarassy, A., & Abonyi, J. (2018). Network Distance-Based Simulated Annealing and Fuzzy Clustering for Sensor Placement Ensuring Observability and Minimal Relative Degree. *Sensors*, 18(9). <https://doi.org/10.3390/s18093096>
- Li, X. et al. (2020). An Improved Method of Particle Swarm Optimization for Path Planning of Mobile Robot. *J. Control Sci. Eng.* <https://doi.org/10.1155/2020/3857894>.
- Liu, L. et al. (2020). Harmony search method with global sharing factor based on natural number coding for vehicle routing problem. *Information (Switzerland)*, 11(2). <https://doi.org/10.3390/info11020086>.
- Mahaleh, M.B.B. et Mirroshandel, S.A. (2018). Harmony search path detection for vision based automated guided vehicle. *Robot. Auton. Syst.*, 107. <https://doi.org/10.1016/j.robot.2018.06.008>
- Marinello, F., Pezzuolo, A., Cillis, D., Chiumenti, A., & Sartori, L. (2017). Traffic effects on soil compaction and sugar beet (*Beta vulgaris* L.) taproot quality parameters. *Spanish Journal of Agricultural Research*, 15(1). <https://doi.org/10.5424/sjar/2017151-8935>
- Mařík, V., Štěpánková, O., Lažanský, J. (2001). *Umělá inteligence 3*. Praha: Academia. ISBN 80-200-0472-6.
- Mavrovouniotis, M., Ellinas, G., Polycarpou, M. (2018). Ant Colony Optimization for the Electric Vehicle Routing Problem. 8th IEEE Symposium Series on Computational Intelligence (IEEE SSCI). Bangalore, India, 2018. <https://doi.org/10.1109/SSCI.2018.8628831>.
- Mileusnić, Z.I, Saljnikov, E., Radojević, R.L, Petrović, D.V. (2022). Soil compaction due to agricultural machinery impact. *Journal of Terramechanics*, 100. <https://doi.org/10.1016/j.jterra.2021.12.002>.
-

-
- Mohammed, M. A. et al. (2017). Solving vehicle routing problem by using improved genetic algorithm for optimal solution. *Journal of Computational Science*. Elsevier B.V., 21. <https://doi.10.1016/j.jocs.2017.04.003>.
- Mukherjee, A., Misra, S., Sukrutha, A., & Raghuwanshi, N. S. (2020). Distributed aerial processing for IoT-based edge UAV swarms in smart farming. *Computer Networks*, 167. <https://doi.org/10.1016/j.comnet.2019.107038>
- Mutar, M. L., Burhanuddin, M. A., Hameed, A. S., Yusof, N., & Mutashar, H. J. (2020). An efficient improvement of ant colony system algorithm for handling capacity vehicle routing problem. *Int. J. Ind. Eng. Comput.* <https://doi.org/10.5267/j.ijiec.2020.4.006>
- Nazarahari, M., Khanmirza, E. and Doostie, S. (2019). Multi-objective multi-robot path planning in continuous environment using an enhanced genetic algorithm. *Expert Systems with Applications*. Elsevier Ltd, 115. <https://doi.10.1016/j.eswa.2018.08.008>.
- Neungmatcha, W. et al. (2013). Adaptive genetic algorithm for solving sugarcane loading stations with multi-facility services problem. *Computers and Electronics in Agriculture*. Elsevier B.V., 98. <https://doi.10.1016/j.compag.2013.07.016>.
- Ngoc, T. A., Hiramatsu, K. and Harada, M. (2014). Optimizing the rule curves of multi-use reservoir operation using a genetic algorithm with a penalty strategy. *Paddy and Water Environment*, 12(1). <https://doi.10.1007/s10333-013-0366-2>.
- Právǎlie, R. (2021). Exploring the multiple land degradation pathways across the planet. *Earth-Science Reviews*, 103689. <https://doi.org/10.1016/j.earscirev.2021.103689>.
- Qiongbing, Z. and Lixin, D. (2016). A new crossover mechanism for genetic algorithms with variable-length chromosomes for path optimization problems. *Expert Systems with Applications*. Elsevier Ltd, 60. <https://doi.10.1016/j.eswa.2016.04.005>.
- Sales, L. de P. A., Pitombeira-Neto, A. R. and Prata, B. de A. (2018). A Genetic Algorithm Integrated with Monte Carlo Simulation for the Field Layout Design Problem. *Oil & Gas Sciences and Technology – Revue d’IFP Energies nouvelles*, 73. <https://doi.10.2516/ogst/2018017>.
- Santos, L. C., Santos, F. N., Solteiro Pires, E. J., Valente, A., Costa, P., Magalhães, S. (2020). Path Planning for ground robots in agriculture: a short review. 2020 IEEE International Conference on Autonomous Robot Systems and
-

-
- Competitions (ICARSC), Ponta Delgada, Portugal, 2020.
<https://doi.org/10.1109/ICARSC49921.2020.9096177>.
- Shah, A.N., Tanveer, M., Shahzad, B. et al. (2017). Soil compaction effects on soil health and cropproductivity: an overview. *Environ Sci Pollut Res*, 24.
<https://doi.org/10.1007/s11356-017-8421-y>
- Shaheb, M.R., Venkatesh, R. & Shearer, S.A. (2021). A Review on the Effect of Soil Compaction and its Management for Sustainable Crop Production. *J. Biosyst. Eng.*, 46. <https://doi.org/10.1007/s42853-021-00117-7>
- Sivarajan, S., Maharlooei, M., Bajwa, S.G., Nowatzki, J. (2018). Impact of soil compaction due to wheel traffic on corn and soybean growth, development and yield. *Soil and Tillage Research*, 175. <https://doi.org/10.1016/j.still.2017.09.001>.
- Tamirat, T.W, Pedersen, S.M., Farquharson, R.J., de Bruin, S., Forristal, P.D., Sørensen, C.G., Nuyttens, D., Pedersen, H.H., Thomsen, M.N. (2022). Controlled traffic farming and field traffic management: Perceptions of farmers groups from Northern and Western European countries. *Soil and Tillage Research*, 217. <https://doi.org/10.1016/j.still.2021.105288>.
- Tong, J. et al. (2017). Optimizing the path of seedling low-density transplanting by using greedy genetic algorithm. *Computers and Electronics in Agriculture*. Elsevier B.V., 142. <https://doi.org/10.1016/j.compag.2017.09.017>.
- Utamima, A., Reiners, T., & Ansariipoor, A. H. (2019). Evolutionary Estimation of Distribution Algorithm for Agricultural Routing Planning in Field Logistics. *Procedia Comput. Sci.*, 161.
<https://doi.org/10.1016/j.procs.2019.11.156>
- Utamina, A. et Djunaidi, A. (2021). Agricultural routing planning: A narrative review of literature. *Procedia Computer Science*, 197.
<https://doi.org/10.1016/j.procs.2021.12.190>.
- Valente, J., Del Cerro, J., Barrientos, A., Sanz, D. (2013). Aerial coverage optimization in precision agriculture management: A musical harmony inspired approach. *Comput. Electron. Agr.*, 99.
<https://doi.org/10.1016/j.compag.2013.09.008>
- Wieczorek, Ł. and Ignaciuk, P. (2018). Continuous Genetic Algorithms as Intelligent Assistance for Resource Distribution in Logistic Systems. *Data*, 3(4).
<https://doi.org/10.3390/data3040068>.
-

Yi, Y., Choi, K. and Lee, Y. (2016). Optimal Limited-stop Bus Routes Selection Using a Genetic Algorithm and Smart Card Data. *Journal of Public Transportation*, 19(4). <https://doi.10.5038/2375-0901.19.4.11>.

ŽIVOTOPIS



Jméno a příjmení: Ing. Mgr. Roman Bumbálek

Narození: 11. dubna 1991, Praha

Bydliště: Sadová 84,257 41 Týnec nad Sázavou

Kontakt: bumbalekr@fzt.jcu.cz

Rodinný stav: ženatý

ODBORNÉ ZAMĚŘENÍ

Zpracování obrazu

Metaheuristické algoritmy

Aplikace umělé inteligence v zemědělství

VZDĚLÁNÍ

- Od 2021 **Jihočeská univerzita v Českých Budějovicích – Fakulta zemědělská a technologická**
obor Obecná zootechnika, Ph.D. studium.
- Od 2017 **Jihočeská univerzita v Českých Budějovicích – Fakulta zemědělská a technologická**
obor Obecná produkce rostlinná, Ph.D. studium.
- 2017-2021 **Jihočeská univerzita v Českých Budějovicích – Fakulta zemědělská a technologická**
Obor Zemědělská a dopravní technika, titul Ing.
- 2014-2016 **Jihočeská univerzita v Českých Budějovicích – Pedagogická fakulta**
obor Učitelství pro 2. stupeň základní školy Matematika/zeměpis, titul Mgr.
- 2010-2014 **Jihočeská univerzita v Českých Budějovicích – Pedagogická fakulta**
obor Učitelství pro 2. stupeň základní školy Matematika/zeměpis, titul Bc.
- 2006-2010 **Gymnázium Benešov u Prahy**

PRACOVNÍ ZKUŠENOSTI

- Od 2018 **Jihočeská univerzita v Českých Budějovicích, Fakulta zemědělská a technologická**
odborný asistent
-

IT manažer ZF JU

2016-2018 **ZŠ Týn nad Vltavou, Malá Strana**

učitel matematiky

Pracovní úvazky formou DPP či DPČ u společností **Jihočeská univerzita v Českých Budějovicích, STARNET s.r.o.** a další.

VĚDECKO-VÝZKUMNÁ ČINNOST

Člen týmu několika grantů, například:

TRIO FV30234 Výzkum a vývoj procesu laserového potisku skleněných ploch malého až velkého formátu pro potřeby současného stavebnictví (2018-2020 – člen řešitelského týmu)

TRIO FV40316 Vývoj komplexu modulárního systému robotizovaného dojení za současného hodnocení parametrů chovu aplikací metod umělé inteligence čase (2019-2022 – člen řešitelského týmu)

TAČR TREND FW01010391 Vývoj systému pro nepřetržitou identifikaci a etologické sledování zvířat v chovech skotu s využitím metod umělé inteligence (2020-2023 – člen řešitelského týmu)

TAČR TM02000027 Výzkum a vývoj chytrých technologií pro chovy skotu a prasat založených na pokročilých výpočetních postupech (2021-2023 – člen řešitelského týmu)

TAČR TM04000023 Výzkum a vývoj klíčových technologií pro chovy drůbeže – systém pro monitorování zvířat a prostředí a inteligentní management chovu

Realizace Funkčních úkolů Ministerstva zemědělství ČR v rádech několika milionů korun.

PUBLIKAČNÍ ČINNOST

Články v impaktovaném časopise

Petrovič B., Bumbálek, R., Zoubek, T., Kuneš, R., Smutný, L., Bartoš, P. (2024). Application of precision agriculture technologies in Central Europe-review. Journal of Agriculture and Food Research, 101048.

Kuneš R., Havelka Z., Olšan P., Smutný L., Filip M., Zoubek T., Bumbálek R., Petrovič B., Stehlík R., Bartoš, P. (2022). A Review: Comparison of Approaches to the Approval Process and Methodology for Estimation of Ammonia Emissions from Livestock Farms under IPPC. *Atmosphere*, 13, 2006.

Kříž, P., Horčíčková, M., Bumbálek, R., Bartoš, P., Smutný, L., Stehlík, R., Zoubek, T., Černý, P., Vochozka, V., Kuneš, R. (2021). Application of the Machine Vision Technology and Infrared Thermography to the Detection of Hoof Diseases in Dairy Cows: A Review. *Appl. Sci.*, 11, 11045.

Filip, M., Zoubek, T., Bumbalek, R., Cerny, P., Batista, C. E., Olsan, P., Bartos, P., Kriz, P., Xiao, M., Dolan, A., Findura, P. (2020). Advanced Computational Methods for Agriculture Machinery Movement Optimization with Applications in Sugarcane Production. *Agriculture*, 10, 434.

Další publikační činnost

Bumbálek R., Zoubek T., Štindlová L., Havelka Z., Olšan P., Bartoš P., Kuneš R., Stehlík R., Dolan A. (2023). Comparison of the Performance of Convolutional Neural Networks YOLOV5 and YOLOV8 for Application in Agricultural Technologies. In: *TECHNOFORUM 2023 „New Trends in Machines and Technologies for Biosystems*. SUA, Nitra. ISBN 978-80-552-2603-3.

Bumbálek, R., Zoubek, T., Otáhal, M., Stehlík, R., Smutný, L. (2022). Aplikace strojového vidění ve velkochovu hospodářských zvířat. *Náš chov*, (8)2022, 39-62.

Smutný, L., Bumbálek, R., Kožíšková, M., Stehlík, R., Smutný, D. (2022). Využití robotické ruky jako náhrada ruční práce dojičů. In: *Aktuální otázky bioklimatologie zvířat 2022. Výzkumný ústav živočišné výroby*, Praha. ISBN 978-80-7403-277-6.

Bumbálek, R., Havelka, Z., Stehlík, R., Smutný, L., Olšan, P. (2021). Stručný přehled umělé inteligence a její aplikace. In: *Aktuální otázky bioklimatologie zvířat 2021. Výzkumný ústav živočišné výroby*, Praha. ISBN 978-80-7403-263-9.

Filip, M., Šístková, M., Zoubek, T., Bumbálek, R., Olšan, P. (2020). Technologické linky pro výrobu objemných krmiv. *Náš chov*, (3)2020, 59-63.

Šístková, M., Kuneš, R., Lang, A., Hankovec, T., Bumbálek, R., Filip, M. (2019). Vliv typu míchacího krmného vozu na přesnost nakládky. *Náš chov*, (11)2019, 82-86.

Knihy

Havelka Z., Olšan P., Kuneš R., Stehlík R., Bumbálek R., Zoubek T., Filip M., Šístková M., Bartoš P. 2021. Referenční dokument o nejlepších dostupných technologiích pro intenzivní chovy drůbeže a prasat, Jihočeská univerzita v Českých Budějovicích, Zemědělská fakulta, České Budějovice. ISBN 978-80-7394-889-4.

Patenty

AGROSOFT Tábor, s.r.o., Jihočeská univerzita v Českých Budějovicích. 2023. Zařízení pro automatizaci dojíren s manuální obsluhou dojících strojů. Původci: Bartoš P., Bumbálek R., Filip M., Havelka Z., Kuneš R., Lang A., Olšan P., Smutný L., Smutný D., Stehlík R., Špalek F., Zoubek T. Patent č. 309824.

Užitné vzory

Jihočeská univerzita v Českých Budějovicích, AGROSOFT Tábor, s.r.o. 2023. Multifunkční identifikační mikročip. Původci: Bartoš P., Bumbálek R., Filip M., Havelka Z., Kuneš R., Olšan P., Stehlík R., Smutný L., Špalek F., Zoubek T. Česká republika. Užitný vzor č. 37059.

Jihočeská univerzita v Českých Budějovicích. 2023, AGROSOFT Tábor, s.r.o. Systém pro monitorování zdravotního stavu paznehtů dojnic. Původci: Bartoš P., Bumbálek R., Filip M., Havelka Z., Kuneš R., Olšan P., Stehlík R., Smutný L., Špalek F., Zoubek T. Česká republika. Užitný vzor č. 37058.

Jihočeská univerzita v Českých Budějovicích, AGROSOFT Tábor, s.r.o. 2023. Systém pro monitorování zdravotního stavu vemene dojnic. Původci: Bartoš P., Bumbálek R., Filip M., Havelka Z., Kuneš R., Olšan P., Stehlík R., Smutný L., Špalek F., Zoubek T. Česká republika. Užitný vzor č. 37057.

AGROSOFT Tábor, s.r.o., Jihočeská univerzita v Českých Budějovicích. 2022. Zařízení pro automatizaci dojíren s manuální obsluhou dojících strojů. Bartoš P., Bumbálek R., Filip M., Havelka Z., Kuneš R., Lang A., Olšan P., Smutný L., Smutný D., Stehlík R., Špalek F., Zoubek T. Užitný vzor č. 36572.

AGROSOFT Tábor, s.r.o., Jihočeská univerzita v Českých Budějovicích. 2022. Systém pro využití rozboru obrazového záznamu k řízení chovu skotu. Bartoš P., Bumbálek R., Filip M., Havelka Z., Kuneš R., Lang A., Olšan P., Smutný L., Smutný D., Stehlík R., Špalek F. Zoubek T. Česká republika. Užitný vzor č. 36612.

Prototypy

Jihočeská univerzita v Českých Budějovicích, AGROSOFT Tábor, s.r.o. 2022: Prototyp robotizovaného systému. Bartoš P., Bumbálek R., Filip M., Kuneš R., Lang A., Olšan P., Smutný L., Smutný D., Stehlík R., Špalek F., Zoubek T., prototype.
