

УПОРЕДНО ИСПИТИВАЊЕ И КОМБИНОВАЊЕ МЕТАХЕУРИСТИЧКИХ АЛГОРИТАМА У ПРОБЛЕМУ НАЛАЖЕЊА И ОПТИМИЗАЦИЈЕ ПУТАЊЕ COMPARATIVE EXAMINATION AND COMBINATION OF METAHEURISTIC ALGORITHMS IN PATH OPTIMIZATION PROBLEM

Игор Мандарић, Факултет техничких наука, Нови Сад

Област – РАЧУНАРСТВО И АУТОМАТИКА

Кратак садржај – У овом раду су обрађена три метахеуристичка алгорита у проблему налажења и оптимизације путање. Први је генетски алгоритам, други је оптимизација колонијом мравца, а трећи је хибридни, који је предложен у овом раду и заснован на њима и као такав показао значајне предности у односу на претходна два.

Кључне речи: Метахеуристика, Генетски алгоритам, Оптимизација колоније мравца

Abstract – This paper addresses three metaheuristic algorithms for the problem of pathfinding and path optimization. The first is the Genetic Algorithm, the second is Ant Colony Optimization, and the third is a hybrid algorithm based on these two, proposed in this work, which demonstrates significant advantages over the other two methods.

Keywords: Metaheuristic, Genetic Algorithm, Ant Colony Optimization

1. УВОД

Метахеуристички алгоритми представљају класу алгорита који се заснивају на различитим типовима сложених хеуристика, где се оптимална решења траже примарно стохастичким, а не детерминистичким приступом [1]. На овај начин се постижу врло ефикасни резултати, посебно у случајевима са пуно локалних оптимума.

У овом раду биће извршен преглед три метахеуристичка алгорита у односу на њихову способност проналазка и оптимизације путање на примеру тзв. мрежног света (енг. *grid world*). Први је генетски алгоритам (енг. *Genetic Algorithm* – у даљем тексту *GA*), други је алгоритам оптимизације колонијом мравца (енг. *Ant Colony Optimization* – у даљем тексту *ACO*), а трећи је хибридни алгоритам добијен комбинацијом претходна два алгорита и који је предложен од стране аутора са циљем да се њиховом комбинацијом минимизују мане и побољшају предности прва два алгорита.

НАПОМЕНА:

Овај рад је проистекао из мастер рада чији је ментор био др Владимир Бугарски, доцент.

2. КОРИШЋЕНЕ МЕТОДЕ

2.1. Генетски алгоритам

Генетски алгоритам је осмишљен 1975. од стране Џона Холанда (енг. *John Henry Holland*) [2] као метахеуристички алгоритам инспирисан процесом еволуције и природне селекције. Идеја овог алгорита је да се формира популација јединки репрезентована одговарајућим генима, тј. кодом који се зове још и хромозом (енг. *Chromosome*). Основна одлика тако добијених јединки је могућност њихове евалуације коришћењем критеријумске функције (енг. *fitness function*), познате још и као функција прилагођености, дефинисану у односу на природу проблема који се обрађује. Потом се као у природи бирају најбоље јединке процесом селекције (енг. *Selection*) на основу вредности добијених њиховом критеријумском функцијом, а затим се укрштањем (енг. *Crossover*) ствара потомство. После укрштања, код нових јединки долази до мутације (енг. *Mutation*) гена, са циљем уношења нових случајних информација у хромозоме које нису наслеђене од родитеља. На тај начин се постиже већа робусност алгорита, чиме он постаје отпорнији на локалне оптимуме. Ови процеси се понављају док се не задовољи критеријум конвергенције (енг. *Stopping Criteria*), углавном унапред дефинисана вредност критеријумске функције и ту свака нова популација потомака чини засебну генерацију која као таква представља родитеље наредној генерацији. Изузеци овом правилу су иницијална генерација која се дефинише углавном на случајан начин или путем одређене хеуристике и понекад одређени број најбољих јединки које се преносе у наредну генерацију у процесу званом елитизам (енг. *Elitism*).

2.2. Оптимизација колонијом мравца

Када је реч о оптимизацији колонијом мравца, овај алгоритам је настао као докторска дисертација Марка Дорига (енг. *Marco Dorigo*) 1992. године [3]. У њему је изложио своју идеју о алгоритму инспирисаном понашањем мравца у природи. Наиме, мрави при тражењу путање до хране остављају иза себе специфичан мирис добијен хемијском супстанцом званом феромони (енг. *pheromones*), који привлачи друге мраве. Што се више мрави крећу том путањом и чешће то је јачи траг феромона, док код оних путања код којих то није случај дође с временом до евапорације (енг. *Evaporation*) феромона и њиховог

нестанка. Доригова идеја је била да се ова појава преточи у алгоритам претраге у графовима, тако што би се на везама између чворова распоредили вештачки феромони, а по графу би били потом пуштени вештачки мрави да се крећу у простору претраге (енг. *search space*). Кретање мрава је било стохастичко, а вероватноћа да мрав стане на неки од чворова у његовој околини се рачунала по следећој формули:

$$p(c_{ij}|s^p) = \frac{\tau_{ij}^\alpha \cdot \eta_{ij}^\beta}{\sum_{c_{il}, l \in N(s^p)} \tau_{il}^\alpha \cdot \eta_{il}^\beta} \quad \forall c_{ij} \in N(s^p); \quad (1)$$

где је $p(c_{ij}|s^p)$ вероватноћа да се изврши транзиција са тренутног чвора i на потенцијални чвор j при непотпуним скупом решења, тј. веза са суседним чворовима s^p , где је $N(s^p)$ могући скуп непотпуних решења у који спада c_{ij} . Она се одређује количником производа τ_{ij}^α и η_{ij}^β и суме производа τ_{il}^α и η_{il}^β , од чега τ представља ниво феромона између чворова у његовом индексу, а η хеуристичку информацију (енг. *heuristic information*) везе чворова у његовом индексу која зависи од природе проблема, док је l итератор који представља све друге чворове суседне чвору i осим чвора j . Преостали параметри су α и β који подешавају значај феромона, односно хеуристике у рачунању вероватноће. После завршетка кретања свих мрава приступа се обнављању нивоа феромона, од стране свих или само појединих мрава, што се може приказати следећом формулом:

$$\tau_{ij} \leftarrow (1 - \rho) \cdot \tau_{ij} + \Delta\tau_{ij}; \quad (2)$$

где је $(1 - \rho) \cdot \tau_{ij}$ део који се односи на евапорацију феромона између чворова i и j , са параметром ρ који представља вредност стопе евапорације, а $\Delta\tau_{ij}$ допринос појединачних мрава заснован на квалитету њихових решења између поменутих чворова. Овај поступак се итеративно понавља док се не задовољи критеријум конвергенције.

2.3. Хибридна метода

Кад је реч о хибридној методи коришћеној у раду, она се заснива на идеји аутора да се алгоритам састоји из две фазе, прве са *GA* и друге са *ACO*. Идеја прве фазе је да се у малом броју генерација покуша пронаћи глобални оптимум, а ако то није случај да се најбоља међусобно различита решења искористе за иницијализацију нивоа феромона у другој фази. Том приликом би вредности феромона биле у распону од 0.1 до 1, где би прва вредност била резервисана за вредности феромона на везама које нису биле укључене у решења добијена са *GA* фазом, а потоња за вредности укључене у сва решења добијена у *GA* фази, са преосталим вредностима скалираним између. Потом би приликом прве обнове нивоа феромона све вредности од 0,1 и мање биле постављене на 0, осигуравајући тако бржу конвергенцију методе.

3. ПРЕГЛЕД ЛИТЕРАТУРЕ

Постоји релативно велик број радова везан за примену *GA* и *ACO* у проблемима проналаaska и оптимизације путање, пошто је реч о веома познатим и прихваћеним

алгоритмима. Из тог разлога ћемо се фокусирати на њихову хибридизацију, како са другим алгоритмима, тако и на међусобну.

3.1. Генерална хибридизација *GA* и *ACO*

Кад разматрамо проблем хибридизације ових алгоритама са другим алгоритмима, ту је тешко заобићи рад групе аутора са блиског истока из 2017. године [4] који се бави хибридизацијом метахеуристичких алгоритама са *A-star* алгоритмом (енг. *A-star* – у даљем тексту *A**), веома популарним, егзактним алгоритмом за претрагу путања у графовима. Хибридизација је вршена тако што је коришћењем *A** алгоритма, односно његове варијанте познате као „релаксирани“ *A** (енг. *Relaxed A** - у даљем тексту *RA**), креиран иницијални скуп решења, који је код *GA* представљао иницијалну популацију, а код *ACO* иницијалну концентрацију феромона. Резултати су показали да хибридизација комбиновањем *RA** са *GA* даје добре резултате, са солидним компромисом између квалитета путање и брзине претраге у односу на *RA** и *A**. Нажалост исто се не може рећи за *ACO* који се није добро показао, примарно због насумичне природе кретања мрава.

Још један веома интересантан допринос проучавању метахеуристичких алгоритама у претраживању и оптимизацији путање је и рад турских аутора из 2023. године [5]. У њему се дискутује детаљно читав низ метахеуристичких алгоритама укључујући ту и *GA* и *ACO*, као и могућих њихових хибридизација са другим алгоритмима, постигнутих у истраживањима претходних деценија, а чији би детаљан опис изашао ван оквира овог рада. Ту, за разлику од претходно обрађеног рада, аутори тврде да се *ACO* показао значајно ефикаснијим од *GA* у проблему налаaska оптималне путање, а истичу и да његово комбиновање са метахеуристичким алгоритмом оптимизације ројем честица (енг. *Particle Swarm Optimization*) показује још боље резултате него основни *ACO* алгоритам.

3.2. Међусобна хибридизација *GA* и *ACO*

Што се тиче хибридног приступа комбиновањем *GA* и *ACO*, он није толико распрострањен као њихова самостална употреба, али и поред тога постоји одређени број истраживања који се бави тиме, било кад је реч о проблему тражења и оптимизације путање, било кад је реч о другим оптимизационим проблемима, попут оних везаних за логистику [6].

Један од значајних радова који се бавио проблемом комбиновања *GA* и *ACO* у циљу тражења и оптимизације путање је и рад индонезанских научника 2013. године [7]. У њему се предлаже комбиновање поменутих алгоритама тако што би они делили велики број параметара и, још битније, путање мрава су могле да се претворе у хромозоме, а хромозоми у путање мрава које су могли да се искористе за обнављање нивоа феромона. Идеја аутора је била да оба алгоритма теку паралелно и да после сваке генерације, тј. итерације се бирају најбоље путање од оба алгоритма, истом методом евалуације, и које су потом коришћене за нову популацију код *GA* и обнављање вредности феромона код *ACO*. Ова метода

је потом тестирана над проблемом трговачког путника (енг. *Travelling Salesman Problem*), где је показао супериорност у односу на базне алгоритме у готово свим случајевима.

Мало другачији приступ овом проблему је имала већ поменута група аутора са блиског истока у раду објављеном 2014. године [8]. Њихова идеја је била да се алгоритам подели на две фазе. У првој фази би био коришћен *ACO* са циљем генерисања иницијалне популације за другу *GA* фазу. Овај приступ је потом тестиран на графовима различитих величина, заједно са базним алгоритмима, али и са Ђикстра (енг. *Dijkstra*) алгоритмом који је веома популаран егзактан алгоритам за претрагу графова (толико популаран да се и *A** базира на њему). Резултати су показали да се нови хибридни алгоритам показао пуно боље у односу на базне, са резултатима у нивоу Ђикстре, али уз значајно краће време у односу на поменути.

4. ПОСТУПАК


Основна поставка проблема заједничка за сва три алгоритма се састојала од следећег:

1. Направљено је јединствено симулационо мрежно окружење димензија 10 x 15 поља које је у себи имало одређени број непрелазних

препрека, празних поља на које је било могуће стати, као и стартно и циљно поље. Сама конфигурација ове мапе је била таква да у њој има више различитих могућих путања оптималне дужине, дужине 21 поље.

2. Максимална дужина било које путање је била 33 поља.
3. Све путање почињу у стартном пољу, са циљем завршетка у циљном пољу.
4. Сваки од разматраних алгоритама је имао скуп улазних параметара, од којих су неки имали фиксне вредности, а неки су се мењали, зависно од симулације. На тај начин је добијено више јединствених скупова улазних параметара за сваки алгоритам.
5. За сваки од њих је извршено 10 симулација, при различитим вредностима параметра случајности (енг. *random state*), обезбеђујући на тај начин поновљивост, односно псеудостохастичку природу експеримента. Тако добијена решења су затим анализирана.

Коришћена мапа се може видети на слици 1, са бројевима који представљају вредност корака у склопу потенцијалне оптималне путање.



Слика 1: Приказ коришћене мапе

Када је реч о *GA* методи, за њу су важила следећа правила:

1. Популација је била дефинисана као хромозом са низом бита, који су у групама од два садржали информацију о правцу кретања на кардиналним осама.
2. Тим смерницама се водио агент који се кретао по мапи, са изузетком кад су смернице биле такве да траже да удари у препреку, тад би узео насумично други правац и исправио тај део хромозома.
3. Тако добијена путања, односно хромозом је евалуирана са две критеријумске функције, примарном и секундарном. Примарна се заснивала на еуклидској удаљености (енг.

Euclidean distance) последњег и „оптималног“ 21. поља путање, ако потоње постоји у путањи, у односу на поље циља. Секундарна се састојала од дужине путање.

4. Рангирање јединки популације, тј. путања се вршило тако што су већи значај имале путање са мањом примарном и секундарном критеријумском вредности, где би друга била коришћена само кад две путање имају исту прву критеријумску вредност.
5. Критеријум конвергенције је био да се достигне оптимална путања.

Што се тиче *ACO* за њу су важила следећа правила:

1. Мрави су се кретали по мапи вођени формулом (1) тако да је хеуристичка

информација η била еуклидска дистанца потенцијалног наредног поља j у односу на циљно поље.

2. Пошто су растојања између поља у мапи еквилидистантна, носиоци вредности феромона су била поља, а не везе између њих.
3. Обнављање вредности феромона је било рађено у два случаја, зависно од тога да ли је пронађена оптимална путања или не. У првом случају обнављање су вршили само сви мрави који су успели да стигну до циља, док би у другом обнављање вршили увек само мрав са најбољом глобалном путањом и мрав са најбољом путањом у итерацији.
4. Пре сваког унапређивања вредности феромона све вредности мање или једнаке 0,1 би се прво поставиле на 0. Потом би се применила формула (2), а после ње би се вредности скалирале у опсегу од 0 до 1.

Правила симулације која су важила за хибридни алгоритам су обухваћена у правилима за његове базне алгоритме, са принципом рада описаним у претходном поглављу.

4. РЕЗУЛТАТИ

После извршења симулација добијени су следећи резултати:

1. Код 33,33 % *GA* симулација није постигнута конвергенција, у односу на 7,5 % код *ACO* симулација и 4,38 % код хибридне методе.
2. У случајевима кад је достигнута конвергенција просечно време трајања симулације је било 6,75 секунди за *GA*, 3,51 секунду за *ACO* и 0,76 секунди за хибридну методу.
3. Код хибридног алгоритма је у 66,67 % симулација дошло до конвергирања у првој фази.

На основу добијених резултата се може закључити следеће:

1. *GA* као самостална метода се није показала задовољавајуће у решавању овог типа проблема.
2. *ACO* постиже много боље резултате због хеуристике у њему, међутим доста зависи од тога како се феромони иницијализују.
3. Хибридна метода коју аутор предлаже се показала веома робусно, где је искоришћена са једне стране тенденција *GA* да ако успе да конвергира то уради углавном релативно брзо и у малом броју генерација, а са друге стране *ACO* у ситуацији кад феромони носе информације од њихове иницијализације, без чекања да се њихове вредности обнове.

5. ЗАКЉУЧАК

У овом раду је обрађен проблем проналаска и оптимизације путање у мрежној мапи помоћу три метахеуристичка алгоритма, а то су генетски алгоритми, оптимизација колонијом мравца и трећи,

хибридни алгоритам, којег је аутор предложио са циљем да се помену два комбинују.

На основу добијених резултата може се закључити да је нови алгоритам значајно супериорнији у односу на базне алгоритме из којих је настао у решавању овог типа проблема.

6. ЛИТЕРАТУРА

- [1] A. H. Gandomi, X.-S. Yang, S. Talatahari, and A. H. Alavi, "Metaheuristic algorithms in modeling and optimization," *Metaheuristic Appl. Struct. Infrastruct.*, vol. 1, pp. 1–24, 2013.
- [2] J. H. Holland, *Adaptation in Natural and Artificial Systems*. 1975.
- [3] M. Dorigo, "Optimization, Learning and Natural Algorithms," *PhD Thesis Politec. Milano*, 1992, Accessed: Dec. 02, 2024. [Online]. Available: <https://cir.nii.ac.jp/crid/1573950400977139328>
- [4] I. Chaari, A. Koubaa, H. Bennaceur, A. Ammar, M. Alajlan, and H. Youssef, "Design and performance analysis of global path planning techniques for autonomous mobile robots in grid environments," *Int. J. Adv. Robot. Syst.*, vol. 14, no. 2, p. 1729881416663663, Mar. 2017, doi: 10.1177/1729881416663663.
- [5] O. Mbah and Q. Zeeshan, "Optimizing Path Planning for Smart Vehicles: A Comprehensive Review of Metaheuristic Algorithms," *J. Eng. Manag. Syst. Eng.*, vol. 2, no. 4, pp. 231–271, Dec. 2023, doi: 10.56578/jemse020405.
- [6] J. Luan, Z. Yao, F. Zhao, and X. Song, "A novel method to solve supplier selection problem: Hybrid algorithm of genetic algorithm and ant colony optimization," *Math. Comput. Simul.*, vol. 156, pp. 294–309, Feb. 2019, doi: 10.1016/j.matcom.2018.08.011.
- [7] Z. Zukhri and I. V. Paputungan, "A Hybrid Optimization Algorithm based on Genetic Algorithm and Ant Colony Optimization," *Int. J. Artif. Intell. Appl.*, vol. 4, no. 5, pp. 63–75, Sep. 2013, doi: 10.5121/ijaia.2013.4505.
- [8] I. Châari, A. Koubâa, S. Trigui, H. Bennaceur, A. Ammar, and K. Al-Shalfan, "SmartPATH: An Efficient Hybrid ACO-GA Algorithm for Solving the Global Path Planning Problem of Mobile Robots," *Int. J. Adv. Robot. Syst.*, vol. 11, no. 7, p. 94, Jul. 2014, doi: 10.5772/58543.

Кратка биографија:



Игор Мандарић је рођен 1998, године у Новом Саду, где је Мастер рад на Факултету техничких наука из области Вештачка интелигенција и машинско учење – Интелигентни системи за доношење одлука, одбранио 2024. године.

Контакт:
igor.mandarich@protonmail.com