

IMPLEMENTATION OF MATHEMATICAL MODEL USING SOFTWARE OPTIMIZED OF LOGISTICAL PRODUCTS IN TRANSPORT SYSTEMS /STUDY/

PLAMEN DYANKOV

ASSISTANT OF ENGINEERING FACULTY, DEPARTMENT ENGINEERING LOGISTIC AT
KONSTANTIN PRESLAVSKY – UNIVERSITY OF SHUMEN

BULGARIA

PLAMEN_DQNKOV@ABV.BG

ABSTRACT: THE GLOBALIZATION OF PRODUCTION, MARKETS AND COMPETITION IS ONLY PART OF ECONOMIC TRENDS GLOBALLY DEFINING HIGH LEVELS OF APPLICATION ACTIVITY TRANSPORTATION. THE REPORTING OF THESE PERSPECTIVES HIGHLIGHTS THE VITAL IMPORTANCE OF TRANSPORT TO SUPPORT THE OVERALL PROCESS OF STABILIZATION AND ECONOMIC GROWTH DURING THE GLOBAL CRISIS. HIGHLY REDUCED PRODUCTION VOLUMES REFLECT DIRECTLY ON THE QUANTITIES OF RAW MATERIALS AND FINISHED PRODUCTS, WHICH INVOLVE THE TRANSPORT AREA IN THE SEARCH FOR RATIONAL SOLUTIONS.

KEYWORDS: MATHEMATICAL MODEL, GENETICAL ALGORITHM PROGRAMMING ENVIRONMENT CHROMOSOMES.

Генетични алгоритми за многоекстремална оптимизация
Генетичните алгоритми (ГА) (Genetic Algorithms (GA)) са стохастичен метод за глобално търсене и оптимизация, който имитира еволюцията на живите индивиди, описана от Чарлз Дарвин. ГА спадат към групата на еволюционните алгоритми.

В еволюционните алгоритми се използват *трите основни принципа на естествената еволюция*: репродукция, естествен подбор и разнообразие на индивидите, поддържано чрез разликите на всяко поколение с предишното.

При ГА се работи с набор от индивиди, представляващи възможни решения на задачата. Принципа на подбора се прилага, като се използва критерий, даващ оценка за близостта на индивида с желаното решение. В следващото поколение продължават най-добре приспособените индивиди.

Огромното разнообразие от проблеми, както инженерни, така и от други области на познанието налага използването на алгоритми от различен тип, характеристики и настройки каквито са ГА.

Основни елементи на ГА

Хромозоми

При делене на човешка клетка хроматинът (намиращ се в ядрото и изграден от ДНК (дезоксирибонуклеинова киселина), белтъци и РНК (рибонуклеинова киселина) се уплътнява и образува спирални нишки – хромозоми. В хромозомите са разположени гени, които носят наследствените белези на клетката. Всеки ген кодира конкретен протеин и представлява самостоятелен фактор на генетичната информация, който обуславя изявата на определени белези.

При генетичните алгоритми хромозомите представляват набор от гени, които кодират неизвестните променливи. Всяка хромозома представлява допустимо решение на поставената задача. Индивид и вектор на променливите ще бъдат използвани като понятия еквивалентни на хромозома.

Гените от своя страна могат да бъдат булеви, целочислени, с плаваща запетая и стрингови променливи (низове от букви и символи), както и всяка тяхна комбинация.

Множеството от различни хромозоми (индивиди) съставят текущото поколение. Чрез еволюционни операции, като селекция, рекомбинация и мутация, се достига до следващото поколение (потомство).

Селекция

В природата селекцията на индивиди се извършва чрез естественият подбор. Колкото по-приспособен е даден индивид към заобикалящата среда, толкова по-голям е шансът му да оцелее и да създаде потомство, като по този начин предаде генетичната си информация на следващото поколение.

При еволюционните алгоритми селекцията на най-добрите индивиди става въз основа на функционал или функционали (функция на приспособимост (fitnessfunction)) даващи оценка на конкретният индивид. Например такъв функционал може да е квадратичен критерий на грешката между изходите на желана от нас система и реалната, близост на полюсите на затворена система до желаните и т.н. Ако задачата е за минимизация, то индивидите с по-малка стойност на функционала ще имат по-голям шанс да бъдат избрани за рекомбинация и съответно за продължаване на поколението.

Рекомбинация

При репродукцията, първо се появява рекомбинацията (кръстосване или кросинговър). При нея гените от родителите формират по някакъв начин изцяло нова хромозома.

Типичната рекомбинация при генетичните алгоритми е операция, изискваща два родителя (възможни са и схеми с повече родители). Два от най-често използваните алгоритми са стандартно кръстосване (ConventionalCrossover) и кръстосване със смесване (Blendcrossover) [9].

Стандартно кръстосване

При този тип рекомбинация родителите си разменят съответни гени. Кръстосването може да бъде едноточково или многоточково фиг.1. За рекомбинацията се използва битова маска Mask. Уравнението описващо рекомбинацията е:

$$C_1 = Mask_1 \& P_1 + Mask_2 \& P_2$$

$$C_2 = Mask_2 \& P_1 + Mask_1 \& P_2$$

P_1, P_2 – хромозоми на родителите

C_1, C_2 – хромозоми на децата (резултантни индивиди) $Mask_1$ и $Mask_2$ - битови маски ($Mask_2 = NOT(Mask_1)$)

& означава побитова операция "И".

За показаният на фиг. 1 -б пример:

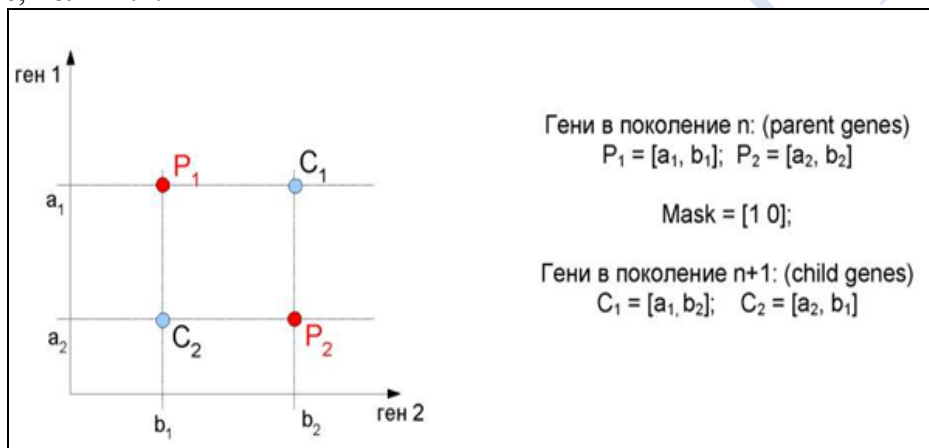
$$Mask_1 = [1\ 11\ 0\ 1\ 1\ 0\ 00];\ Mask_2 = NOT(Mask_1) = [0\ 00\ 1\ 0\ 0\ 1\ 11];$$

$$P_1 = [2\ 7\ 5\ 8\ 0\ 3\ 1\ 5\ 9];\ P_2 = [8\ 8\ 4\ 5\ 1\ 6\ 9\ 7\ 1];$$

**Фиг. 1- Кръстосване с битова маска**

Геометричното представяне на този тип кръстосване на хромозома с два гена е показано на фиг. 2. Този тип кръстосване (с битова маска) може да се използва при всички по-горе изброени типове гени.

В природата такъв тип предаване на информация между поколенията е например цвят на очите, пол и т.н.

**Фиг.2. Графично представяне на кръстосване с битова маска**

Кръстосване със смесване

Математическото описание на този тип кръстосване е:

$$C_i = \gamma.P_1 + (1-\gamma).P_2 \quad (1)$$

$$C_2 = (1-\gamma)P_1 + \gamma P_2$$

$$g = (1+2.\alpha).r - \alpha \quad (2)$$


P_1, P_2 - хромозоми на родителите;

C_1, C_2 - хромозоми на децата (резултантни индивиди);

α - коефициент на изследване - задава се от потребителя ($\alpha \geq 0$);

r - случайно число в границите (0, 1)


Графичното представяне е показано на фиг. 3 и фиг. 4.



Фиг. 3 Графично представяне на кръстосване със смесване $\alpha = 0$ **Фиг. 4** Графично представяне на кръстосване със смесване $\alpha > 0$

С помощта на α се променя областта в която може да попадне стойността на резултантния ген. При $\alpha=0$ се гарантира, че стойността на резултантния ген ще бъде между тази на родителите, а при по-големи стойности може да се изследват съседни области фиг. 5.


В природата по подобен начин се предава информацията за пигментация на кожата, телосложение и т.н.



Фиг. 5 - Промяна на зоната на търсене с промяна на α
Мутация

Новосъздаденото чрез селекция и кръстосване потомство след това може да бъде подложено на мутация. Мутация означава, че елементи от ДНК се променят. Тези промени са породени главно от грешки при копирането на гените от родителите.

В термините на генетичните алгоритми мутация означава произволна промяна на стойността на ген в поколението фиг. 6 а). Хромозомата, чиито ген ще бъде променен, и мястото на гена също се избират по случаен принцип фиг. 6 б).



а) мутация в хромозомата

б) места на мутация в поколението

Фиг. 6 Мутация при генетичните алгоритми

Обща схема на еволюционните алгоритми

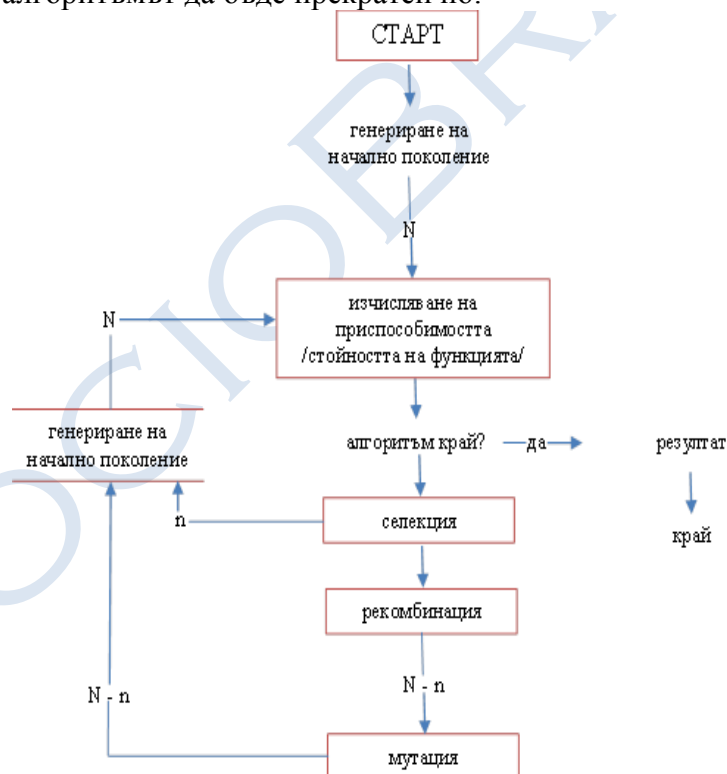
Еволюционните алгоритми поддържат популация от индивиди (хромозоми), които еволюират чрез използване на селекция и други операции, като кръстосване и мутация. Всеки индивид в популацията получава оценка за приспособимостта си (fitnessfunction) към средата. В термините на оптимизацията това означава, че за всеки набор от променливи се изчислява стойността на функцията, която се минимизира или максимизира. Селекцията служи за избор на най-добрите комбинации, които чрез кръстосване и мутация трябва да доведат до по-добри решения в следващото поколение.

На фиг. 7 е показана една от най-често използваните схеми на генетичните алгоритми.

1. Създаване на начално поколение - при повечето алгоритми първото поколение се генерира по случаен принцип - гените на отделните хромозоми се избират случайно измежду азбуката на допустимите гени. Заради по-лесната изчислителна процедура се приема, че всички поколения се състоят от еднакъв брой индивиди (N на брой).

2. Следващата стъпка е изчисляване на стойността на функцията, която минимизираме или максимизираме.

3. Проверка за край на алгоритъма - както при всички алгоритми за оптимизация и тук е възможно алгоритъмът да бъде прекратен по:



Фиг. 7 - Обща схема на еволюционните алгоритми

- Стойност на функцията - стойността на функцията на най-добрия индивид става достатъчно близка до зададена стойност. Обикновено не се препоръчва използването само на този критерий, защото поради стохастичният характер на търсенето не може да се гарантира достигане до желания екстремум в разумно време;

- Максимален брой итерации - това е най-често използвания критерий за спиране. Той гарантира, че независимо дали алгоритъмът е достигнал до екстремум или не ще

спре след определено време;

- Достигане на установена стойност - ако в продължение на предварително зададен брой итерации не е настъпило подобрене на стойността на функцията алгоритъмът спира.

4. Селекция - измежду всички индивиди в текущото поколение се избират тези, които да продължат развитието си в кръстосването и мутацията. На този етап може да се използва *елитарен подход*. Това означава част от най-добрите индивиди (n на брой) да се прехвърлят без промяна в следващото поколение. По този начин се гарантира, че достигнатата стойност на функцията не може да се влоши (веднъж достигнат екстремумът няма да бъде изпуснат).

5. Кръстосване - избраните чрез селекция индивиди се кръстосват. По този начин се получават нови индивиди, като стремежът е тези индивиди да наследят възможно най-добрата комбинация от характеристики на родителите си.

6. Мутация - чрез случайна промяна на някои от гените се гарантира, че дори нито един от индивидите в текущото поколение не съдържа необходимият ген, пак е възможно да се достигне до екстремум.

7. Ново поколение - избраните от селекцията индивиди се обединяват с получените чрез селекция и мутация и образуват следващото поколение.

Области на приложение на генетичните алгоритми за оптимизация

Генетичните алгоритми са пряк, стохастичен метод за оптимизация. Тъй като използват поколения от допустими решения (индивиди) те спадат към групата на паралелните алгоритми. Поради стохастичният характер на търсене се налага поставяне на ограничения поне по условие на параметрите на оптимизация (неизвестните променливи).

Едно- и многопараметрични задачи

В зависимост от броя на оптимизационните параметри задачите биват:

- Еднопараметрични $\min f(x), x \in R^1$ (3.)
- Многопараметрични $\min f(x), x \in R^n$ (4)

Въпреки че стандартните генетичните алгоритми са създадени за многопараметрична оптимизация има модификации позволяващи еднопараметрична оптимизация. Такава възможност съществува и в разработените програми за оптимизация. Всеки ген, представящ променлива с реална стойност се разделя на под-гени, кодиращи различните степени на числото 10. Всеки от тези под-гени се променя независимо от другите.

Едно- и многокритериални задачи

Инженерните задачи, често изискват удовлетворяване на няколко противоречиви изисквания. Ето защо е подходящо инженерните задачи да се разглеждат като многокритериални задачи. Пример за такава задача в теория на управлението е синтезът на регулатор, при което искаме да имаме както минимална разлика между заданието и изхода на системата, така и минимална стойност на управлението.

$$\min_{x \in R^n} F(x) = (f_1(x), f_2(x), \dots, f_k(x))^T \quad (5)$$

Паралелни алгоритми

Тъй като генетичните алгоритми наподобяват еволюцията в природата, където търсенето на решение е паралелен процес, те могат лесно да бъдат пуснати на

паралелни машини. Съществуват три основни начина за паралелното им изпълнение:

- Обща популация, но паралелно изчисляване на целевите функции - целевата функция на всеки индивид се изчислява на отделен процесор (slave), а генетичните оператори се изпълняват на отделен (master).
- Разделяне на под-популации - цялото поколение се разделя на под-поколения (популации), всяко едно от които се изчислява на отделен процесор.
- Разпределяне на генетичните операции (разширение на горният) - генетичните операции се прилагат само между съседни популации, като по този начин се запазва разнообразието на индивидите.

Селекция

Селекцията е процес, при който се избират индивидите, които да бъдат подложени на генетичните оператори и да създадат следващото поколение. Селекцията има две основни функции:

1. Да избере най-перспективните индивиди, които да участват в създаване на следващото поколение или да бъдат директно копирани (елитарна стратегия);
2. Да осигури възможност на индивиди с сравнително лоша стойност на целевата функция (функции) да участват в създаването на следващото поколение. По този начин се осигурява запазване на глобалното търсене и не се позволява на един индивид да доминира популацията, като по този начин доведе до локален екстремум.


Приложение на генетичен алгоритъм за оптимизация на мултимодална транспортна мрежа

Направения анализ на литературните източници се базира на избора на транспортни методи и мрежи извършващи комбинаторна оптимизация на математическия модел. Той се основава на принципа на намаляване на разходите и представена оценка на многочленна (многостепенна) транспортна мрежа. Проблемът за най-късият път при този вид транспорт е изследван от всички насочени краища отнасящи се до единния модел на транспортните случаи. Многочленния транспортен проблем е преобразуван в проблем за най-късият път с времево и капацитетно ограничение при построяването на виртуални транспортни мрежи. Евристичен изпълнителен алгоритъм решаващ определен най-кратък път е представен в трудовете на De-Zhi and Chun Yu [3]. Модела на Wendong and Wenfrang [7] е структуриран на две нива, като горното ниво разглежда времевия прозорец на стоките, а долното ниво е оптимизацията на пътя.

Константата на времевия прозорец не се разглежда или долната граница на константата на времевия прозорец не се взема под внимание. Базирайки се на горния анализ е представен модел на многочленна транспортна мрежа и генетичен алгоритъм за решаване на моделите от ниско ниво [4].

Описание на проблема

Предполага се, че експресна товарна компания желае да изпрати пратка от стоки от град (O) доград (D). В транспортната мрежа има няколко пътя- фиг. 8. Съществуват няколко транспортни способа с различни цени и време между двата града. Стоките трябва да се доставят в специфичен времеви прозорец гарантиран от компанията. Целта е да се намери най-добрия транспортен метод и път за да се получи минимум на крайната цена на доставка.



Фиг.8. Графика на транспортна мрежа

Моделиране

Модела може да се преобразува до мрежа с един източник и един краен пункт $G=(V, E, C)$, фиг.8, V е множество елементи и $V=\{O, P_1, P_n, D\}$, E е множество от маршрути, което може да бъде представено като $E = E_1 \cup E_2 \cup E_3$ където $E_1 = \{e_{opi}/\text{град } P_i \text{ е съседен с град } O\}$ и $E_2 = \{e_{ij}/\text{върхове между междинните градове } P_i \text{ и } P_j\}$, $E_3 = \{e_{PID}/\text{град } P_i \text{ е съседен до град } D\}$, C е теглово множество на върховете и представя единната транспортна цена, разстоянието между два града и средната скорост на движение на транспортното средство. От тук целта е да намерим най ниската цена, най - краткият път в зададен времеви интервал от O до D .

Моделни допускания:

- само един транспортен способ може да бъде избран между два града;
- трансфер се извършва в града и само веднъж;
- времето на забавяне се включва в транзитното време.

Символни означения: за да се опише проблема и модела се използват следните означения:

- **константи** m – пълен тонаж на стоките, n – брой на градовете през които преминава транспортното средство, K – множеството на транспортните способности $K=\{1, 2, \dots, k\}$, d_{ij}^k - транспортно разстояние между градовете i и j при избран k th транспортен способ, $(i, j) \in E, k = 1, 2, \dots, K$; w_i^{kl} - трансферната цена ако трансфера на стоки от транспортен метод k към транспортен метод l е град $i, i = 1, 2, \dots, n, k = 1, 2, \dots, K$ и $k \neq l$; t_{ij}^k - транспортно време между градовете i и j при избран k th транспортен способ, $(i, j) \in E, k = 1, 2, \dots, K$; tt_i^{kl} - трансферно време ако трансфера на стоки от транспортен метод k към транспортен метод l е град $i, i = 1, 2, \dots, K$, и $k \neq l$, v_{ij}^k - средна транспортна скорост между градовете i и j при избран k th транспортен способ, $(i, j) \in E, k = 1, 2, \dots, K$

- **променливи** x_{ij}^k е 0-1 променлива от град i до град j при избран k th транспортен способ, тогава $x_{ij}^k = 1$, в противен случай $x_{ij}^k = 0$, $(i, j) \in E, k = 1, 2, \dots, K$; x_i^k е 0-1 променлива в град i ако е извършен трансфера на стоки от транспортен метод k към транспортен метод l в противен случай $x_i^k = 0$, $i \in (1, \dots, n), k, l = 1, 2, \dots, K$ и $k \neq l$.

Модел с две нива на програмиране. За експресна транспортна компания разстоянието и пълното време за извършване на доставката са важни индикатори за измерване качеството на услугата. Но оценката и на двете в едно и също време е

труднодасереша с модела. Затова тук се разглеждат двенивана програмирана модела, горното ниво на модела намира връзката между обслужването и времевия прозорец, долното ниво установява оптимален модел с минимална цена, като цел за определяне на оптимален път в съответствие с константата на времевия прозорец [8].

Модел на времевия прозорец. Обект на модела на горното ниво е да се намери път от O до D с минимално разстояние:

$$\min d = \sum_{(i,j) \in E} \sum_{k \in K} d_{ij}^k x_{ij}^k \quad (6)$$

$$s. t. \sum_{k \in K} x_{oj}^k = 1 \quad \forall (o,j) \in E_1 \quad (7)$$

$$\sum_{k \in K} x_{ij}^k - \sum_{k \in K} x_{ji}^k = 0 \quad \forall (i,j) \in E_2 \quad (8)$$

$$x_{ij}^k \in \{0,1\} \quad \forall (i,j) \in E \quad E \in K \quad (9)$$

Ограничения 6 – 8 са ограничение на потока на ограниченията, които формират пътя от точка O до точка D , докато ограничение 9. осигурява, че x_{ij}^k са 0-1 променливи.

Ако транспортната организация може да бъде разделена на нива, всяко съответстващо на ограниченията на времевия прозорец $(t_{l-1}, t_l) l \subseteq L$, се взема интервал от време във времевия прозорец на модела и връзка между времевия прозорец и транспортното разстояние е както следва:

$$t_{OD} = \begin{cases} (0, t_1) & 0 \leq d \leq d_1 \\ (t_1, t_2) & d_1 \leq d \leq d_2 \\ \dots \dots \dots \\ (t_{l-1}, t_l) & d_{l-1} \leq d \leq d_l \\ (t_{L-1}, t_L) & d_L \leq d \end{cases} \quad (10)$$

В модела интервала от $d_{l-1} \leq d \leq d_l, l=1,2,\dots,L$ е ограничение на работното разстояние [2].

Модел на оптимизация на пътя: В долното ниво на модела обект на изследване е да се намери път от точка O до точка D с минимални транспортни разходи.

$$\min Z = \sum_{(i,j) \in E} \sum_{k \in K} mc_{ij}^k d_{ij}^k x_{ij}^k + \sum_{i \in V} \sum_{k \in K} \sum_{l \in K} mw_i^k x_i^{kl} \quad (11)$$

$$t_{ij}^k = \frac{d_{ij}^k}{v_{ij}^k} \quad \forall (i,j) \in E \quad k \in K \quad (12)$$

$$\sum_{(i,j) \in E} \sum_{k \in K} t_{ij}^k x_{ij}^k + \sum_{i \in V} \sum_{k \in K} \sum_{l \in K} tt_i^{kl} x_i^{kl} \in t_{OD} \quad \forall t_{OD} \quad (13)$$

$$\sum_{k \in K} x_{oj}^k = 1 \quad \forall (o, j) \in E_1 \quad (14)$$

$$\sum_{k \in K} x_{iD^*}^k = 1 \quad \forall (i, D^*) \in E_3 \quad (15)$$

$$\sum_{k \in K} x_{ij}^k - \sum_{k \in K} x_{ji}^k = 0 \quad \forall (i, j) \in E_2 \quad (16)$$

$$\begin{cases} x_{ij}^k \in \{0,1\} & \forall (i, j) \in E \quad k \in K \\ x_i^{kl} \in \{0,1\} & \forall i = 1 \dots n \quad k, l \in K \end{cases} \quad (17)$$

Ограничението 11 изчислява транспортното време от град i до град j при избран k th транспортен способ; Ограничение 12 е ограничение на времевия прозорец, което уточнява обхвата на времето за пристигане на стоките от дестинацията. Ограничения 13 – 16 са ограничения за запазване на потока от пътя от точка O до D , докато ограничение 17 осигурява, че x_{ij}^k и x_i^{kl} са 0/1 променливи [5].

Решения базирани на генетичен алгоритъм

Модела от горното ниво е типичен проблем за най-късият път (SPP) в теорията на графовете и има множество алгоритми за решаването му. Такъв е алгоритъма на Декстра, динамично програмирания алгоритъм и други такива алгоритми [6]. Най-долното ниво може да бъде разглеждано като SPP с ограничения във времевия прозорец. Традиционният алгоритъм не е достатъчно еластичен да реши такъв проблем и когато има няколко крайни точки в мрежата броят на изчисленията ще нарастват експоненциално. Предлага се нов алгоритъм наречен генетичен алгоритъм за решаването на проблема.

Метод на хромозомно записване: Този метод има голямо влияние върху решаването на скоростния проблем, обхвата на решенията и размера на грешните изчисления. Тук е приет бинарен метод на записване и дължината на хромозомите са номерата на градовете (табл. 1)

Табл. 1

Метод на хромозомно записване

| | | | | | | | | | | | |
|---|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|-----------------|---|
| 1 | 0 | 1 | 1 | 0 | 0 | 0 | 1 | 0 | 1 | 0 | 1 |
| O | P ₁ | P ₂ | P ₃ | P ₄ | P ₅ | P ₆ | P ₇ | P ₈ | P ₉ | P ₁₀ | D |

Символите P_i ($i = O, 1, 2, \dots, n, D$) са номера на градовете върхове (точки). Ако стойността на върха е 1 означава, че транспортното средство преминава през града, ако стойността е 0 това означава, че транспортното средство не преминава през града.

Функция на съответствие Проблем на оцеляване е индивидуален и се определя от неговото съответствие. Обект на този проблем е използването на път от O до D с минимално оценена стойност C_{max} .

Генетични оператори: В генетичния алгоритъм има три главни генетични оператора- подбор, пресичане и изменение. Чрез използване на различни вероятности за използване на тези оператори, скоростта на срещане може да бъде контролирана. Операторите на пресичане и изменение трябва да бъдат внимателно определени, тъй като техният избор влияе силно върху качествата на целия генетичен алгоритъм.

Оператор за подбор: Тук за генетичния алгоритъм се използва елитарен подбор базиран на ролетно измерване и елитарна стратегия.

Оператор на пресичане: Оператора на пресичане смесва пътища на две различни решения за създаване на две различни разклонения. Тук пресечните точки се елиминират чрез едноточковият метод. Така вероятността за пресичане е 0,9.

Оператор на изменение: Нов модел се създава, чрез изменение на съществуващ такъв. Крайното изменение на позицията по хромозомата се избира винаги случайно и след това изменението на хромозомата се изменя случайно с променлива вероятност.

Симуляционен оператор: Някои спомагателни решения се приемат чрез използване на симуляционен оператор и неблагоприятните явления могат да бъдат ефективно избегнати.

Обикновено компанията желае да има множество от пътища, така че ако оптималния път поради инцидентни фактори не може да се използва, те могат да изберат друг маршрут за да го заменят.


Програмна реализация на ГА в Matlab

Изходни данни:



Фиг. 9. Карта на възможните маршрути с жп транспорт

Въвеждане на мащаб и графична решетка за опорните точки на транспорт



Фиг.10. Мащабиране на транспортните направления

```

clear,clc
closeall
% Карта на маршрутите
I=imread('jpmreja.png');
imshow(I);
% въвеждане на координатите на точки от маршрута
defaultConfig.xy= [1.5 3.9;7.8 3.2;2.7 2.6;5 3;1.5 3.9;3.8 2.2;1.5 3.9;5 3;6.4 3.1;5 3;6.9
3.8;7.8 3.2];
% инициализиране на конфигурацията на ГА
defaultConfig.dmat = [];
defaultConfig.popSize = 100;
defaultConfig.numIter = 1e4;
defaultConfig.showProg = true;
defaultConfig.showResult = true;
defaultConfig.showWaitbar = false;
% потребителски входове
if ~nargin
userConfig = struct();
elseif isstruct(varargin{1})
userConfig = varargin{1};
else
try
userConfig = struct(varargin{:});
catch
error('Expected inputs are either a structure or parameter/value pairs');
end
end

% конфигурация по подразбиране
configStruct = get_config(defaultConfig,userConfig);

% Extract configuration

```

```

xy      = configStruct.xy
dmat    = configStruct.dmat;
popSize = configStruct.popSize;
numIter = configStruct.numIter;
showProg = configStruct.showProg;
showResult = configStruct.showResult;
showWaitbar = configStruct.showWaitbar;
if isempty(dmat)
nPoints = size(xy,1);
    a = meshgrid(1:nPoints);
dmat = reshape(sqrt(sum((xy(a,:)-xy(a',:)).^2,2)),nPoints,nPoints);
end

% Проверка на входните параметри
[N,dims] = size(xy);
[nr,nc] = size(dmat);
if N ~= nr || N ~= nc
error('Invalid XY or DMAT inputs!')
end
n = N;

% избор на клон
popSize = 4*ceil(popSize/4);
numIter = max(1,round(real(numIter(1)))));
showProg = logical(showProg(1));
showResult = logical(showResult(1));
showWaitbar = logical(showWaitbar(1));

% Инициализация на Популацията
pop = zeros(popSize,n);
pop(1,:) = (1:n);
for k = 2:popSize
pop(k,:) = randperm(n);
end
% Старт на ГА
globalMin = Inf;
totalDist = zeros(1,popSize);
distHistory = zeros(1,numIter);
tmpPop = zeros(4,n);
newPop = zeros(popSize,n);
if showProg
figure('Name','TSPO_GA | CurrentBestSolution','Numbertitle','off');
hAx = gca;
end
if showWaitbar
hWait = waitbar(0,'Searching for near-optimal solution ...');
end

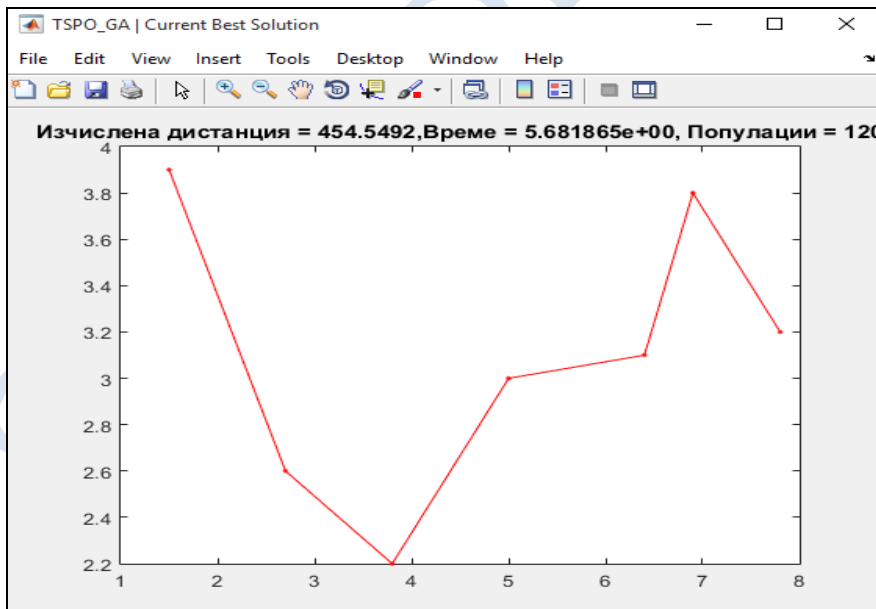
```

```

for iter = 1:numIter
% EvaluateEachPopulationMember (Изчисляване на общото разстояние)
for p = 1:popSize
    d = 0; % OpenPath
for k = 2:n
    d = d + dmat(pop(p,k-1),pop(p,k));
end
totalDist(p) = 100*d/1.7;
end

% Търсене на оптимален маршрут
[minDist,index] = min(totalDist);
distHistory(iter) = minDist;
if minDist < globalMin
    globalMin = minDist;
    optRoute = pop(index,:);
if showProg
% Построява оптимален маршрут
if dims > 2, plot3(hAx,xy(optRoute,1),xy(optRoute,2),xy(optRoute,3),'r-');
else plot(hAx,xy(optRoute,1),xy(optRoute,2),'r-'); end
title(hAx,sprintf('Изчислена дистанция = %1.4f, Време = %d, Популации = %d',minDist,minDist/80,12*iter));
drawnow;
end
end

```



Фиг.11. Определяне на оптимален маршрут - изчисляване на разстояние, време и брой итерации (популации)

% Оператори на ГА

```

randomOrder = randperm(popSize);
for p = 4:4:popSize
rtes = pop(randomOrder(p-3:p),:);
dists = totalDist(randomOrder(p-3:p));
    [ignore,idx] = min(dists); %#ok
    bestOf4Route = rtes(idx,:);
routeInsertionPoints = sort(ceil(n*rand(1,2)));
    I = routeInsertionPoints(1);
    J = routeInsertionPoints(2);
for k = 1:4
% Мутация за три алтернативни маршрута
tmpPop(k,:) = bestOf4Route;
switch k
case 2 % Подбор
tmpPop(k,I:J) = tmpPop(k,J:-1:I);
case 3 % Замяна
tmpPop(k,[I J]) = tmpPop(k,[J I]);
case 4 % Преход
tmpPop(k,I:J) = tmpPop(k,[I+1:J I]);
otherwise% Минимум
end
end
newPop(p-3:p,:) = tmpPop;
end
pop = newPop;

% Обновяване
ifshowWaitbar&& ~mod(iter,ceil(numIter/325))
waitbar(iter/numIter,hWait);
end

end
ifshowWaitbar
close(hWait);
end

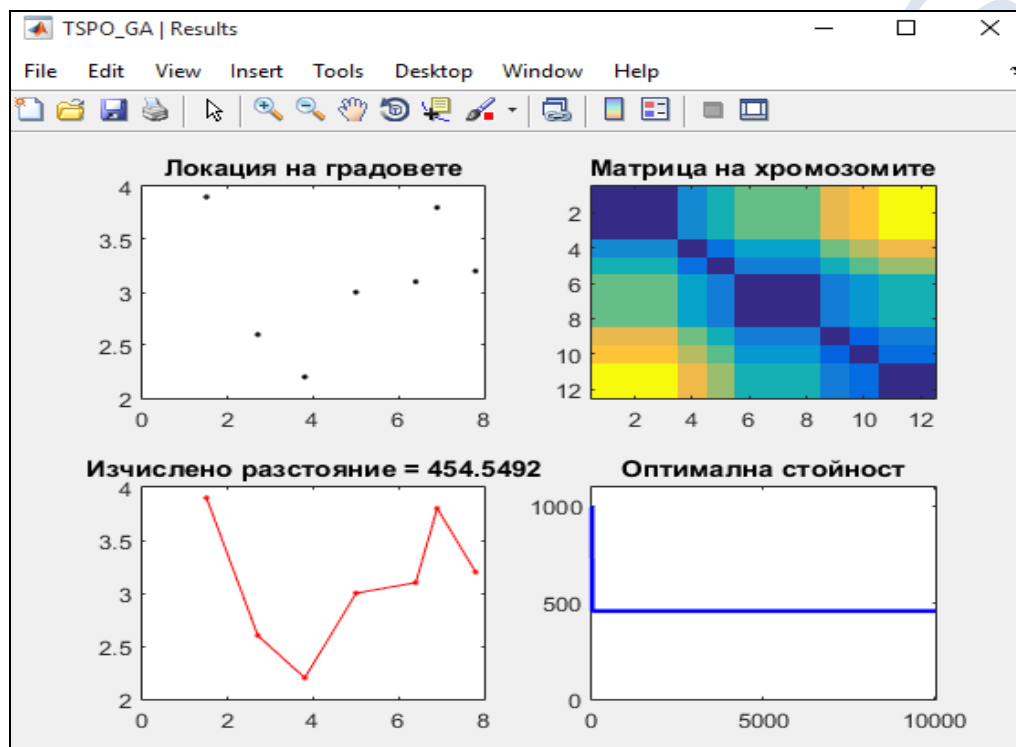
ifshowResult
% Изчертаване на резултатите на ГА
figure('Name','TSPO_GA | Results','Numbertitle','off');
subplot(2,2,1);
pclr = ~get(0,'DefaultAxesColor');
ifdims> 2, plot3(xy(:,1),xy(:,2),xy(:,3),'.','Color',pclr);
elseplot(xy(:,1),xy(:,2),'.','Color',pclr); end
title('Локация на градовете');
subplot(2,2,2);
imagesc(dmat(optRoute,optRoute));
title('Матрица на хромозомите');

```

```

subplot(2,2,3);
ifdims> 2, plot3(xy(optRoute,1),xy(optRoute,2),xy(optRoute,3),'r.-');
elseplot(xy(optRoute,1),xy(optRoute,2),'r.-'); end
title(sprintf('Изчислено разстояние = %1.4f',minDist));
subplot(2,2,4);
plot(distHistory,'b','LineWidth',2);
title('Оптимална стойност');
set(gca,'XLim',[0 numIter+1],'YLim',[0 1.1*max([1 distHistory])]);
end

```



Фиг.12. Визуализация на локацията на градовете, матрицата на хромозомите, изчисленото разстояние – дименсия километри, оптимална стойност

% Възстановяване на алгоритъма

```

ifnargout
resultStruct = struct( ...
'xy',      xy, ...
'dmat',    dmat, ...
'popSize', popSize, ...
'numIter', numIter, ...
'showProg', showProg, ...
'showResult', showResult, ...
'showWaitbar', showWaitbar, ...
'optRoute', optRoute, ...
'minDist', minDist);

```



```

varargout = {resultStruct};
end

end

% Subfunction to override the default configuration with user inputs
function config = get_config(defaultConfig, userConfig)

% Initialize the configuration structure as the default
config = defaultConfig;

% Extract the field names of the default configuration structure
defaultFields = fieldnames(defaultConfig);

% Extract the field names of the user configuration structure
userFields = fieldnames(userConfig);
nUserFields = length(userFields);

% Override any default configuration fields with user values
for i = 1:nUserFields
    userField = userFields{i};
    isField = strcmpi(defaultFields, userField);
    if nnz(isField) == 1
        thisField = defaultFields(isField);
        config.(thisField) = userConfig.(userField);
    end
end

end
end

```

В резултат на изследването са обобщени следните изводи:

1. Реализиран е генетичен алгоритъм за оптимизиране на транспортна мрежа, чрез използване на евристичен модел за най-кратък път. Полученият резултат доказва, че мащабирането на транспортните направления по разстояние, време и брой итерации в голяма степен се доближават до приетия теоретичен подход. Визуализирана е локацията на градовете, матрицата на хромозомите и е изчислена оптималната стойност на разстоянията за различни видове транспорт.

2. Приетата и приложена методика за определяне на транспортното време доказва, че колкото намалява неговата стойност, толкова оптимизационната процедура дава най-добри резултати. Увеличаване на стойността или удължаване на транспортното време увеличава разходите и утежнява в допълнителна степен ефективността на дейностите.

Заключение

Изборът на оптимален маршрут на комбиниран транспорт се представя като поредица от разстояния, времена за натоварване и разтоварване и на множеството коефициенти формиращи икономическата рентабилност изразена в цена. Дефиниран е

графичен модел на възможните маршрути и е оптимизиран посредством симулационен модул на генетичен алгоритъм. Моделът дава възможност да се комбинира транспортен оператор в процеса на оптимизационното решение на транспортна мрежа, като поредица от няколко натоварвания и транспортиране и е съвместим с практиката за осигуряване на приемлив път. Приемливите последователности на комбинирания превози не са статични. Оценка на транспортната мрежа потребителите могат да извършат само при ограничение на избора на най-добра комбинация на методи за транспортиране и на изминат път. Рационализацията на пътя на комбинирания транспорт изисква задълбочаване на проучванията в тази област и създаване на база статистически и имперични данни, така че моделите с определени корекции да осигуряват максимална икономическа рентабилност.

Изследването на оптималния съществуващ многовариантен комбиниран път развива идеята за приемлив маршрут с комбиниран транспорт. Базирайки се на комбинирания превози анализа на приемливия път има основно значение. Чрез създаването на диаграма на комбинирания транспортна мрежа този труд анализира пълната транспортна цена и състава на пълното време.

REFERENCES:

1. **Zhelyazkova, D., 2011:** Transportat kato klyuchova funkztiya v logistikata, izd. „Nauka i ikonomika“, Varna, 2011
2. Development Opportunites for the Logistics Sectorin Bulgaria, PHARE programme BG 9805-01-01-03 of European Union „Marketing Support for the Promotion of Foreign Direct Investmens“, project team was lead by Philip Todorov, NEI, Rotterdam, 2001
3. **De-Zhi, Z. and L. Chun-Yu, 2001:** Shortes to ptimization model for multiple rans portation mode. Selection Solution Algorithm, 20: 46-50.
4. **Lozano, A. and G. Storchi, 2001:** Shortest viable path algorithm in multimodal net works. Transport. Res., 35: 225-241.
5. **Niksirat, M., M. Ghatee and S.M. Hashemi, 2012:** MultimodalK-shortestviablepathinTehranpublictransportationnetworkanditssolutionapplyin gantcolonyandsimulatedannealingalgorithms. AppliedMath. Model., 36: 5709-5726.
6. **Tao, W. and W. Guang, 2005:** A combine do ptimization model for transportation modes of multimodal transport. Eng. Sci., 7: 46-50.
7. **Wendong, Y. and W. Wenfang, 2009:** Analyzing and modeling of multimodal transportation with time window. J. Nanjing Univ. Aeronautics Astronautics, 41: 111-115.
8. **Wu, D., Y. Yin and S. Lawphongpanich, 2011:** Pareto-improving congeation pricin go multimodal transportation networks. Eur. J. Operation Res., 20: 660-669.

9. **Yang, L., Z.J. Zuo and Z.D. Li, 2010:** Topological consistency of multimodal composite transportation network. *J. China Univ. Geosci.*, 35: 397-402.

SOCIOBRAINS