



Univerzita Komenského v Bratislave
Fakulta matematiky, fyziky a informatiky



Mgr. Anton Sedliak

Autoreferát dizertačnej práce

Optimalizácia prepravy médií v potrubných systémoch

na získanie akademického titulu philosophiae doctor

**v odbore doktorandského štúdia:
9-1-9 Aplikovaná matematika**

Bratislava 2016

Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia

na Oddelení aplikovanej matematiky Matematického ústavu Slovenskej akadémie vied

Predkladateľ: **Mgr. Anton Sedliak**
Oddelenie aplikovanej matematiky
Matematický ústav SAV
Štefánikova 49
814 38, Bratislava 1

Školiteľ: **doc. RNDr. Rudolf Hajóssy, CSc.**
Oddelenie aplikovanej matematiky
Matematický ústav SAV
Štefánikova 49
814 38, Bratislava 1

Oponenti:

.....

.....

.....

.....

.....

(meno a priezvisko oponenta s uvedením jeho titulov a hodností
a názov ustanovizne, s ktorou je oponent v pracovnom pomere)

Obhajoba dizertačnej práce sa koná v o h

**pred komisiou pre obhajobu dizertačnej práce v odbore doktorandského štúdia vymenovanou predsedom
odborovej komisie**

(uviesť dátum vymenovania)

Odbor, študijný program: 9-1-9 Aplikovaná matematika, Aplikovaná matematika
na Matematickom ústave SAV, Štefánikovej 49, Bratislava

Predseda odborovej komisie:

.....
(meno a priezvisko s uvedením titulov a hodností
a presná adresa jeho zamestnávateľa)

Úvod

Podľa predpovedí renomovaných inštitúcií sa ukazuje, že zemný plyn bude jedným z najdôležitejších zdrojov energie blízkej budúcnosti. Či už sa pozrieme na predpovede International Gas Union [1], The European Union of the Natural Gas Industry [2], alebo správu U.S. Energy Information Administration [3], všetky predpovedajú približne lineárny rast spotreby zemného plynu. Percentuálne by malo ísť o nárast v rozmedzí približne 1 až 6 % za rok v závislosti od toho, či hovoríme o raste spotreby v domácnostiach, v priemysle alebo vo výrobe elektrickej energie zo zemného plynu. Nárast spotreby plynu logicky vedie k nárastu jeho ťažby a prepravy k zákazníkom, čo v dôsledku znamená aj nárast celkových nákladov prepravy. O to dôležitejšou sa stáva otázka zlepšenia efektivity prepravy plynu.

V dizertačnej práci sme sa sústredili na úlohy spojené s tranzitnými vysokotlakými plynovodnými systémami (tlak prepravovaného média je väčší ako cca 0,4 MPa). Konkrétne sme rozoberali úlohy pre určenie maximálneho prietoku sústavou, minimalizačné úlohy (minimalizácia spotrebovanej energie alebo spotreby plynu na pohon, resp. minimalizácia celkových prevádzkových nákladov) pri vopred zadaných prepravných požiadavkách, ako aj úlohy vedúce na multikriteriálnu optimalizáciu.

Cieľ

Cieľom predkladanej práce bolo nájsť vhodnú metodológiu na riešenie vybraných optimalizačných úloh pri preprave médií v plynovodných potrubných systémoch. V tejto práci sú navrhnuté modifikácie algoritmov evolučných stratégií, pomocou ktorých je možné riešiť viaceré triedy optimalizačných úloh pri preprave plynu. Testovanie algoritmov bolo realizované pomocou softvérovej implementácie na modeli reálnej lineárnej tranzitnej sústavy.

Prehľad súčasného stavu riešenej problematiky

Úlohy stacionárnych optimalizácií pri preprave plynu potrubnými systémami sú pomerne dobre spracovanou oblasťou. Samotný problém sa zvyčajne definuje ako úloha matematického programovania, ktorá sa potom rieši širokou škálou deterministických alebo stochastických optimalizačných metód. Napríklad Pratt a Wilson v [4] použili zmiešané celočíselné programovanie (mixed integer linear programming), Percel a Ryan [5] zovšeobecnenú redukovanú gradientnú metódu (generalized reduced gradient method (GRG)), alebo Flores-Villarreal a Ríos-Mercado, ktorí v [6] tiež použili GRG metódu na cyklické aj necyklické siete.

Zatiaľ najúspešnejšími sú prístupy založené na dynamickom programovaní (DP). Wong a Larson v roku 1968 publikovali práce [7], [8], kde ako prví použili DP na riešenie optimalizačného problému pre siete s lineárnou a stromovou topológiou (vzhľadom na umiestnenie kompresorových staníc). Prvý komerčne úspešný optimalizačný program pre siete so stromovou topológiou, ktorý bol založený na DP, vyvinul Zimmer [9] už v roku 1975. Pokusy riešiť pomocou DP aj úlohy s cyklickými sieťami boli inšpirované prístupmi z prác [10] a [11] z chemického inžinierstva. Ucelený prehľad vývoja a základné princípy DP možno nájsť v Carterovej práci [12]. Z pohľadu praxe sú metódy založené na DP veľmi vhodné a široko používané pre jednoduchšie problémy, najmä na lineárnych a stromových sieťach. Pri cyklických problémoch však čas potrebný na vyriešenie úlohy neúnosne narastá, a tak metódy založené na DP pri takýchto úlohách strácajú svoju najväčšiu výhodu.

Autori v [13] riešili multikriteriálnu optimalizáciu pre minimálnu energiu a súčasne maximálny prietok. Úlohu definovali pomocou matematického programovania a tento model riešili pomocou PSO (partical swarm optimization) a genetických algoritmov. Model testovali na reálnej sieti, ktorá však pozostávala len zo štyroch paralelných kompresorov, štyroch chladičov plynu a jedného potrubia.

Z pohľadu praktického uplatnenia majú tieto prístupy niekoľko závažných nedostatkov: samotný model prúdenia plynu potrubím je zjednodušený – neberie do úvahy zmeny teploty plynu pri jeho kompresii a interakcii s okolitým prostredím, ani zmeny nadmorskej výšky pozdĺž potrubí. Pritom napr. v [13] bolo ukázané, že až 25 percent ušetrených prostriedkov bolo dosiahnutých vďaka optimálnemu schladeniu plynu za kompresorovými stanicami. Model kompresorovej stanice býva príliš zjednodušený a tým nepresný. Ďalej, každá zo spomínaných metód je určená len na istú špecifickú úlohu stacionárnej optimalizácie a zvyčajne len pre siete s lineárnou topológiou.

Metódy používané v práci

Náš prístup k hľadaniu optimálneho riešenia spomínaných úloh je založený na rozložení hľadania optima do dvoch úrovní: lokálnej – optimalizácia jednej kompresorovej stanice a globálnej – optimalizácia potrubnej siete ako celku. Tieto dve úrovne zároveň vedú k rozdeleniu riešenia optimalizácie na

- deterministickú časť, prezentovanú stacionárnou simuláciou, v rámci nej sú implementované lokálne optimalizácie kompresorových staníc,
- stochastickú časť, konkrétne v našom prípade je to optimalizačná metóda evolučné stratégie, využívajúcu výsledky deterministickej časti na priradenie hodnoty účelovej funkcie kandidátovi na riešenie.

Stochastické evolučné metódy používajú stacionárne simulácie ako veľmi zložitú a komplexnú účelovú funkciu. Aby ich mohli tieto metódy používať ako čiernu skrinku, musia tieto stacionárne simulácie spĺňať pre naše účely viaceré kritériá.

Stacionárna simulácia musí vedieť spočítať stacionárny stav po zadaní

- okrajových tlakových resp. prietokových podmienok, teplota sa zadáva na vstupných (tlakových aj prietokových) uzloch
- tlakových obmedzení na prietokových vstupných resp. výstupných uzloch, v prípade potreby aj tlakových obmedzení na vnútorných uzloch siete
- kompresných pomerov na každej kompresorovej stanici
- výkonových obmedzení pohonov jednotlivých kompresorov
- vonkajšej teploty ovzdušia, ktorá determinuje obmedzenia pohonov jednotlivých kompresorov
- tlakových nastavení pre regulačné armatúry

Ak je zadanie také, že existuje stacionárny stav, ktorý ho realizuje, po výpočte budeme požadovať, aby bola každá kompresorová stanica optimalizovaná vzhľadom na zadané minimalizačné kritérium stacionárnej simulácie (spotreba energie, plynu na pohon alebo celkové prevádzkové náklady). To znamená, že budú určené počty, zapojenia a otáčky prevádzkovaných kompresorov na každej kompresorovej stanici. Predpoklad vyplýva z toho, že požiadavka dodržania zadaného kompresného pomeru nie je jednoznačná – pre dostatočne zložitú kompresorovú stanicu existuje zvyčajne viacero rôznych zapojení kompresorov v tejto kompresorovej stanici, pri ktorých má táto stanica zadaný kompresný pomer – optimalizácia na zadané kritérium potom prirodzene poskytuje jednoznačnosť riešenia.

Ďalej, čas výpočtu stacionárnej simulácie musí byť, vzhľadom na veľké množstvo potrebných vyčíslení hodnotovej funkcie, dostatočne krátky.

Stacionárna simulácia teda optimalizuje zapojenie kompresorov na lokálnej úrovni – na úrovni kompresorovej stanice. Pre potreby tejto práce budeme stacionárnu simuláciu považovať za čiernu skrinku, ktorá pre dané vstupné parametre (kompresné pomery, nastavenia regulátorov, stav ventilov a okrajové podmienky) zistí, či zadanie reprezentuje stacionárny stav a ak áno tento stav vráti ako výsledok. Zhrnieme len, že používame simuláciu založenú na úplnom jednorozmernom modeli turbulentného prúdenia plynu v potrubí. Jej implementácia je založená na modifikovanej Hardy-Cross metóde a dostatočná rýchlosť výpočtu bola dosiahnutá pomocou hierarchického zjednodušenia siete (tzv. multi-level network method) [14], [15].

Pri optimalizácii siete ako celku hľadáme také kompresné pomery všetkých kompresorových staníc a prípadných ďalších riadiacich parametrov prepravného systému (napr. nastavenie

regulátorov alebo okrajových podmienok stacionárnej simulácie), aby sledovaný globálny parameter dosiahol optimálnu, prípadne optimu dostatočne blízku hodnotu.

Jednokriteriálna optimalizácia


V samotnej implementácii evolučných stratégií sme sa na základe numerických testov rozhodli použiť modifikovaný typ $(\mu + \lambda)$ -ES so samoadaptívnymi smerodajnými odchýlkami, bez kovariančnej matice. Symbolom μ označujeme počet rodičov v populácii a λ označuje počet potomkov. Symbol $+$ znamená, že o prežitie budú súťažiť rodičia spolu s potomkami (na označenie modifikácie evolučných stratégií sa okrem symbolu $+$ používa aj čiarka, čo znamená, že o prežitie spolu súťažia len potomkovia a na rodičov sa „zabudne“). Nakoniec pod pojmom samoadaptívne smerodajné odchýlky máme na mysli princíp, kedy aj vektor parametrov σ (pomocou ktorého sa použitím normálneho rozdelenia s parametrami $N(0, \sigma)$ generujú nové potomkovia) podlieha evolúcii.

Poznámka: Pod konštatovaním „bez kovariančnej matice“ máme na mysli reprezentáciu jedinca len pomocou vektorov x a σ , teda bez vektora rotácií θ . Pri numerickom testovaní sa ukázalo, že pri použití vektora rotácií sa v niektorých prípadoch doba výpočtu až zdvojnásobila.

Vieme, že jedinec v evolučných stratégiách je reprezentovaný vektorom reálnych čísiel. Ak sieť, na ktorej budeme realizovať optimalizačné výpočty obsahuje n kompresorových staníc, jedinec bude reprezentovaný vektorom $2n$ reálnych čísiel (x, σ) . Prvých n čísiel x_i bude reprezentovať kompresné pomery, pričom $x_i \in \{1; [K_i^{\min}; K_i^{\max}]\}$ reprezentuje kompresný pomer v i -tej kompresorovej stanici. $K_i^{\min} > 1$ reprezentuje minimálny kompresný pomer a K_i^{\max} maximálny kompresný pomer, ktorý môže dosiahnuť i -ta kompresorová stanica. Hodnota 1 reprezentuje stav, kedy kompresorová stanica nekoná žiadnu kompresnú prácu a je teda premostená (je v stave bypass). Hodnoty $\sigma_i > 0$ reprezentujú smerodajné odchýlky pre jednotlivé i -te kompresné pomery x_i .

Pre vybraný optimalizovaný parameter získame hodnotu účelovej funkcie až po spočítaní stacionárneho stavu pre danú voľbu kompresných pomerov.

Pri vytváraní počiatočnej populácie (pre viacčlenné populačné stochastické optimalizačné metódy) je výhodné mať členy tejto populácie rovnomerne rozložené v priestore prípustných riešení. Na obrázku č.1 je zobrazený priestor prípustných riešení, aj s danými hodnotami účelovej funkcie, spotreby plynu (v kg/s) kompresorovými stanicami. V tomto konkrétnom prípade sú to reálne dáta zo stacionárnych výpočtov pre reálnu slovenskú tranzitnú sústavu. Aby bolo možné výsledky vizualizovať, simulovali sme stav, kedy sú do prevádzky zapojené len dve zo štyroch kompresorových staníc (KS1 a KS3). Ako je zrejmé z obrázka, účelová funkcia, aj samotná oblasť prípustných riešení, je pomerne zložitá a nespojitá. Oblasť prípustných riešení býva často veľmi úzka, čo potom vedie k problému nájsť vôbec nejaké počiatočné prípustné riešenie len náhodným generovaním atribútov (v tomto prípade kompresných pomerov) jedinca.



Obrázok č.1. Spotreba plynu dvoma kompresorovými stanicami (KS1 a KS3) v kg/s, pričom kompresorové stanice KS2 a KS4 nie sú zapojené do prevádzky.

V takom prípade si musíme vystačiť napríklad aj s jediným jedincom počiatočnej populácie. Ukázalo sa, že aj takáto malá počiatočná populácia stačí na to, aby už po niekoľkých generáciách bola populácia diverzifikovaná po priestore prípustných riešení a aby prehľadavacie schopnosti algoritmu neboli poškodené.

Pre tvorbu nových jedincov sa na praktických úlohách najlepšie osvedčili evolučné stratégie s jednoduchým evolučným operátorom – len jeden rodič a samoadaptívna smerodajná

odchýlka. Rodiča vyberieme z populácie náhodným výberom, pričom každý jedinec má rovnakú pravdepodobnosť výberu, určenú uniformným rozdelením. Potom podľa vzťahu:

$$\sigma' = \sigma e^{N(0, \Delta\sigma)}, \quad (1)$$

kde $\Delta\sigma$ je parameter metódy, ktorý Schwefel ([25]) odporúča nastaviť na hodnotu $\Delta\sigma = \frac{1}{\sqrt{2\sqrt{n}}}$ modifikujeme smerodajné odchýlky a nakoniec podľa vzťahu:

$$x' = x + N(0, \sigma'), \quad (2)$$

vytvoríme atribúty nového potomka. Potom, ako sme vygenerovali premenné parametre nového jedinca, je potrebné overiť, či tento jedinec patrí do množiny prípustných riešení, teda či jeho atribútmi v spojení s okrajovými podmienkami je definovaný nejaký realizovateľný stacionárny stav. Ak je tomu tak, treba ešte podľa typu optimalizačnej úlohy zistiť hodnotu účelovej funkcie. Ak nový jedinec nedefinuje realizovateľný stacionárny stav, je potrebné sa pokúsiť vygenerovať pomocou (1) a (2) nové atribúty jedinca a proces overovania opakovať.

Proces overovania prípustnosti testovaného riešenia (jedinca) znamená spočítať stacionárny stav prúdiaceho reálneho plynu potrubným systémom pre dané okrajové podmienky a atribúty jedinca (kompresné pomery). Z pohľadu výpočtovej náročnosti zaberá výpočet stacionárneho stavu najviac času. Je zrejmé, že pre potreby praxe je dôležitá nielen dostatočná presnosť navrhovaného optimalizačného výpočtu, ale aj čo najkratšia doba výpočtu. Preto ak samotný jeden stacionárny výpočet už nie je možné viac urýchliť, potom v zásade existujú dve možnosti, ako skrátiť celkový čas optimalizačného výpočtu:

- *Paralelizácia*: moderná architektúra dnešných procesorov umožňuje súčasný beh viacerých výpočtových vlákien. To je možné využiť na to, aby sa vykonávalo súčasne viacero stacionárnych výpočtov. Tým získame niekoľkonásobné skrátenie celkového času optimalizačného výpočtu.
- *Optimálne generovanie kandidátov na riešenie*: na rozdiel od paralelizácie, kde sa snažíme v jednom čase súčasne vykonať čo najviac stacionárnych výpočtov, tu sa naopak snažíme upraviť algoritmus tak, aby bolo potrebné urobiť čo najmenší počet stacionárnych výpočtov, a tým sa znížil celkový čas optimalizačného výpočtu. Snažíme sa to dosiahnuť pomocou optimálneho generovania kandidátov na riešenie. Tento cieľ sa snažíme dosiahnuť pomocou výberu vhodnej modifikácie algoritmu a optimálneho nastavenia riadiacich parametrov algoritmu. Na to, aby sme mohli jednotlivé modifikácie kvalitatívne porovnávať, sme zaviedli parameter „úspešnosť“. Je to pomer medzi počtom prípustných riešení ku počtu všetkých kandidátov na riešenie za celý čas optimalizačného výpočtu. Pomocou parametra úspešnosti sme testovali viacero spôsobov generovania potomkov a analyzovali jeho správanie pri rôznych hodnotách riadiacich parametrov. Ako najefektívnejší sa ukázal spôsob

výpočtu len s jedným rodičom. V tejto oblasti ale stále zostáva priestor na ďalší výskum a testy.

Pre výbere členov novej populácie sme zostali pri spôsobe definovanom modifikáciou $(\mu + \lambda)$ -ES, teda že o účasť v novej generácii spolu súťažia rodičia spolu so všetkými novými potomkami. Samotný výber členov novej populácie je realizovaný tak, že zo všetkých jedincov, ktorí sa zúčastňujú výberu, sa vyberie práve μ jedincov s najlepšou hodnotou účelovej funkcie.

Pre zlepšenie konvergenčných vlastností algoritmu sme zaviedli niekoľko modifikácií. Prvou z nich je modifikácia pravidla 1/5-vej úspešnosti, ktorou sme sledovali zlepšenie konvergenčných vlastností v záverečnej časti optimalizačného výpočtu. Táto modifikácia je realizovaná tak, že na začiatku je potrebné zadať poradové číslo m a koeficient $0 < \alpha < 1$. Potom po každej m -tej generácii každému jedincovi tejto generácie vynásobíme všetky jeho smerodajné odchýlky parametrom α . (Táto modifikácia sa uplatňuje iba pri m -tej, $2m$ -tej, $3m$ -tej ... generácii.) Touto modifikáciou sme sa snažili zlepšiť konvergenčné schopnosti algoritmu pri konci behu algoritmu, kedy už očakávame, že sa nachádzame blízko hľadaného globálneho extrému. Zmenšením smerodajných odchylok tak nútime algoritmus už len lokálne prehľadávať okolie, do ktorého sa mu podarilo dokonvergovať.

Druhou modifikáciou sme sa snažili zmenšiť riziko predčasnej konvergenencie, alebo inak povedané, pokúsiť sa zabrániť algoritmu, aby dokonvergoval len do lokálneho extrému. Dosiahli sme to spojením princípov $(\mu + \lambda)$ -ES a (μ, λ) -ES modifikácií evolučných stratégií. Každý jedinec v populácii získal ďalší parameter, ktorý sme nazvali vek. Navyše sme zaviedli riadiaci parameter algoritmu s názvom *maximálny vek rodiča*. Samotná modifikácia je realizovaná nasledovne: každému jedincovi počiatkovej populácie sa nastaví parameter veku na celočíselnú hodnotu, ktorú vyberieme pomocou rovnomerného rozdelenia pravdepodobnosti z intervalu $\left(\frac{\text{maximálny vek rodiča}}{2}, \text{maximálny vek rodiča}\right)$. Rovnakým spôsobom priradíme hodnotu parametra veku aj každému novovyprodukovanému potomkovi. Každému jedincovi, ktorý sa stane súčasťou ďalšej generácie, sa zníži vek o jeden. Rodičom sa môže stať len ten člen populácie, ktorého vek je väčší ako 0. Motiváciou bola snaha o vyváženie výhod a nevýhod oboch modifikácií $(\mu + \lambda)$ -ES a (μ, λ) -ES. Modifikácia $(\mu + \lambda)$ -ES zaručuje prehľadávanie priestoru prípustných riešení v okolí miesta, ktoré je práve v čase výpočtu považované za najlepšieho kandidáta na riešenie, čo ale môže viesť ku konvergencii do lokálneho extrému. Naopak, (μ, λ) -ES modifikácia zaručuje, že nová generácia bude obsahovať vždy nových jedincov, čo zvyšuje prehľadávacie schopnosti algoritmu a zároveň znižuje možnosť predčasnej konvergenencie, ale za cenu pomalšej konvergenencie.


Keďže vo všeobecnosti optimálnu hodnotu účelovej funkcie nepoznáme, ako ukončovaciu podmienku optimalizačného výpočtu sme zvolili počet generácií, alebo celkový čas výpočtu, alebo kombináciu oboch podmienok. Tieto ukončovacie parametre sa zadávajú na začiatku

výpočtu. Po splnení zvolenej podmienky sa vyberie jedinec s najlepšou hodnotou účelovej funkcie, ktorý sa tým stane hľadaným optimálnym riešením.

Multikriteriálna optimalizácia

Zaujímavou a súčasne pre prax veľmi dôležitou úlohou je optimalizácia prepravy, ak je vopred zadaná akumulácia. Pojmom akumulácia sa v praxi zvykne označovať objem plynu, ktorý sa nachádza v plynovodnom systéme. Pri optimalizačnom výpočte, ktorý napr. minimalizuje množstvo spotrebovanej energie, je množstvo plynu v systéme výsledkom výpočtu. Ak pre nové zadanie plynárenského dňa je výsledkom optimalizačného výpočtu stav, ktorý má výrazne inú akumuláciu ako má momentálny reálny stav, tak nie je vypočítané nastavenie siete (kvôli nedostatku alebo prebytku plynu v sieti) uskutočniteľné. To vedie na multikriteriálnu úlohu – nájsť nielen také riadiace parametre prepravy plynu, aby bola spotreba energie (resp. technologického plynu, elektrickej energie, celkovej ceny prevádzky) minimálna, ale aby súčasne bola odchýlka akumulácie od požadovanej hodnoty čo najmenšia.

I keď nami prezentovaná metóda pre riešenie stacionárnych optimalizačných úloh pri preprave plynu tranzitnými plynovodmi je dosť robustná a všeobecná, jej použitie pre multikriteriálne optimalizačné problémy (ďalej len MOP) si vyžadovala určité modifikácie. Na úrovni jedinca a jeho reprezentácie neboli potrebné žiadne modifikácie. Čo bolo potrebné upraviť, bol proces priradovania hodnoty účelovej funkcie a proces selekcie nových rodičov, pretože z podstaty MOP nemusí byť kandidát na riešenie ohodnotený jedným číslom ale ak uvažujeme napr. *k* rôznych kritérií hodnotu účelovej funkcie môžeme reprezentovať *k*-rozmerným vektorom reálnych čísiel. Treba vziať do úvahy aj to, že len veľmi málo MOP ma jediné optimálne riešenie. Zvyčajne sa snažíme nájsť celú množinu Pareto optimálnych riešení. Tento pojem ako prvý zdefinoval taliansky ekonóm Vilfredo Pareto.



Obrázok č. 2. Modré body reprezentujú konečnú aproximáciu Paretovho frontu, sivé krúžky reprezentujú všetky predchádzajúce aproximácie Paretovho frontu počas optimalizačného výpočtu s dvoma kritériami: minimálna odchýlka od zadanej akumulácie v kg a súčasne minimálna spotreba energie v GJ.

Povieme, že prípustné riešenie multikritériálnej optimalizácie \mathbf{x} *dominuje* prípustnému riešeniu \mathbf{y} , ak pre $\forall i = 1, 2, \dots, k$ $f_i(\mathbf{x}) \geq f_i(\mathbf{y})$ a súčasne existuje aspoň jedno i také, že $f_i(\mathbf{x}) > f_i(\mathbf{y})$. Nech \mathbf{P} je podmnožina množiny prípustných riešení. Prípustné riešenie multikritériálnej optimalizačnej úlohy, pre ktoré neexistuje prípustné riešenie z \mathbf{P} , ktoré by mu dominovalo, budeme nazývať *nedominované* vzhľadom na \mathbf{P} . Podmnožina všetkých nedominovaných riešení z množiny všetkých prípustných riešení sa nazýva *Paretova množina* (alebo množina Pareto optimálnych riešení) a obraz tejto množiny v priestore účelovej funkcie nazývame *Pareto front* (obr. č. 2).

Poznáme ([17]) viacero prístupov na riešenie MOP pomocou populačných algoritmov. Zaujímavé je, že aj napriek potenciálu evolučných optimalizačných techník pre riešenie MOP, naznačenému Rosenbergom v jeho dizertačnej práci z roku 1967 [18], zostala táto oblasť neprebádaná takmer 25 rokov.

V princípe môžeme prístupy k riešeniu MOP rozdeliť do dvoch tried

- agregačný prístup,
- Pareto front.

Agregačný prístup je založený na váženom súčte jednotlivých zložiek vektorovej účelovej funkcie $f(x)$, teda definujeme novú účelovú funkciu ako

$$F(x) = \sum_{i=1}^k w_i f_i(x).$$

Výhodou je, že pri takomto prístupe nie je potrebné upravovať použitý evolučný algoritmus. Tento prístup je vhodný pre jednoduchšie MOP s len niekoľkými zložkami účelovej funkcie $f(x)$ a s konvexnou množinou prípustných riešení. Problémom môže byť nájdenie správnych hodnôt váh w_i , ak nemáme dostatočné vedomosti o podstate riešenej úlohy. Ďaleko väčší problém však nastane, ak nie je Pareto front konvexný. V takom prípade bez ohľadu na voľbu váh w_i nedokáže takýto prístup generovať skutočné Pareto optimálne riešenia [19].

V druhej triede prístupov na riešenie MOP pomocou Pareto frontu je množstvo modifikácií rôznych druhov evolučných algoritmov tak, aby hľadali aproximáciu Pareto frontu. V tejto oblasti bolo publikovaných mnoho prác a existuje niekoľko aplikácií v praxi [20]. Výsledky výskumu v tejto oblasti však ukazujú, že kľúčovými prvkami pre dosiahnutie uspokojivého výsledku je elitizmus a rôznorodosť populácie.

Poznámka: Pod pojmom elitizmus máme na mysli princíp, podľa ktorého sa na tvorbe novej populácie podieľajú len najlepší jedinci v populácii.

Preto sme aj my pri úprave nášho algoritmu pre riešenie MOP mali tieto výsledky na zreteli. V algoritme evolučných stratégií pre jednokriteriálnu optimalizáciu zoradíme jedincov podľa hodnoty účelovej funkcie a vyberieme μ najlepších jedincov, ktorí sa stanú novými rodičmi. V prípade MOP za najlepších jedincov budeme brať nedominovaných jedincov vzhľadom na všetky doteraz vygenerované prípustné riešenia. Množina všetkých nedominovaných jedincov v aktuálnej populácii jedincov bude tvoriť aproximáciu Pareto frontu. Ak je počet nedominovaných jedincov rovný μ , práve títo nedominovaní jedinci budú noví rodičia. Komplikácia nastane v prípade, keď nedominovaných jedincov z aproximácie Pareto frontu je viac, alebo menej ako μ . Pre tieto dva prípady sme navrhli riešenia s ohľadom na vyššie spomínaný princíp elitizmu a rôznorodosti populácie

1. Prípade, keď jedincov Pareto frontu je viac ako potrebných rodičov: Rodičov sme vyberali tak, aby čo najrovnomernejšie pokrývali aproximáciu Pareto frontu. To znamená, že pri výbere rodičov vynecháme práve tých nedominovaných jedincov, ktorí sú najbližšie iným nedominovaným jedincom.
2. Prípade, keď jedincov Pareto frontu je menej ako potrebných rodičov: Chýbajúcich jedincov sme vyberali tak, aby boli čo najbližšie k aproximácii Pareto frontu.

Záver

V práci sme sa zaoberali implementáciou stochastickej populačnej metódy evolučných stratégií na riešenie viacerých tried optimalizačných úloh vznikajúcich pri reálnej preprave zemného plynu. Konkrétne sa rozoberali nasledujúce úlohy:

- určenie maximálneho prietoku sústavou podľa viacerých kritérií,
- minimalizačné úlohy (napr. minimalizácia spotrebovanej energie alebo spotreby plynu na pohon, resp. minimalizácia celkových prevádzkových nákladov pri vopred zadaných prepravných požiadavkách),
- multikriteriálna optimalizácia (napr. určenie maximálneho prietoku sústavou, pričom je zadané celkové množstvo plynu v potrubnej sústave a súčasne sa požaduje minimalizácia spotreby energie).

Pri klasickom prístupe k riešeniu takýchto úloh na potrubných systémoch so zložitými kompresorovými stanicami (mnoho druhov kompresorov s rôznymi možnými zapojeniami) je potrebné hľadať veľké množstvo parametrov. Napr. v kontexte slovenskej tranzitnej siete, ktorá obsahuje štyri kompresorové stanice a za predpokladu, že by nás zaujímalo len optimálne nastavenie práve týchto štyroch kompresorových staníc, by sa jednalo približne o 120 celočíselných premenných (reprezentujúcich stav jednotlivých kompresorov (zapnutý/vypnutý) a spôsob zapojenia (sériovo/ paralelne)) a rovnaký počet reálnych čísel reprezentujúcich otáčky každého kompresora. To vedie k neúnosnému predĺženiu času výpočtu, ktorý by bol potom v praxi prakticky nepoužiteľný.

Jedným z najzákladnejších prínosov tejto práce, okrem samotnej implementácie evolučných stratégií, je preto návrh na efektívnu elimináciu veľkého množstva hľadaných parametrov a ich nahradenie menším počtom iných parametrov. Konkrétne sa namiesto hľadania počtov a otáčok kompresorov a spôsobu ich zapojenia do prevádzky hľadá pre každú kompresorovú stanicu jediný parameter – kompresný pomer tejto kompresorovej stanice. Takéto podstatné zmenšenie dimenzionality problému má za následok výrazné zníženie času výpočtu. Tento sa dá ešte ďalej skrátiť využitím paralelizácie výpočtov na viacjadrových procesoroch.

Navrhnutý prístup sme overili na reálnom modeli tranzitného potrubného systému prechádzajúceho územím Slovenskej republiky. Z topologického hľadiska ide o lineárnu sieť, ale kvôli možným veľkým objemom prepravy táto sieť obsahuje kompresorové stanice s veľkým počtom rôznych druhov kompresorov, ktoré možno zapájať sériovo, paralelne, alebo sériovo paralelne. Ako verifikačný nástroj sme použili implementovaný algoritmus dynamického programovania, pretože podľa [21] dynamické programovanie zaručuje dosiahnutie globálneho extrému.

Dosiahnuté výsledky môžeme zhrnúť do nasledujúcich bodov:

Implementácia vo forme funkčného produktu

Navrhnutý optimalizačný prístup bol implementovaný v programovacom jazyku C++ ako samostatný modul stacionárnych optimalizačných výpočtov v rámci softvérovej aplikácie MARTI Studio. Je navrhnutý tak, že za riadiace parametre výpočtu je možné definovať nielen kompresné pomery na kompresorových staniciach, ale v podstate ľubovoľný parameter siete (napríklad okrajové podmienky vo výstupných uzloch siete, alebo regulačný tlak na regulátoroch) čím sme dosiahli možnosť jednoducho zadať a riešiť širokú triedu úloh stacionárnych optimalizácií.

Paralelizácia algoritmu s využitím viacprocesorovej architektúry

Dosiahnutie tohto cieľa nám pomohlo udržať dobu výpočtu na prípustnej úrovni tak, aby náš prístup bol využiteľný aj v praxi, keď dispečeri prevádzky majú na svoje rozhodnutia len relatívne krátke (desiatky minút) čas.

Heuristiky pre zlepšenie konvergenčných vlastností algoritmu

Pre zlepšenie konvergenčných vlastností algoritmu a zníženie celkového počtu potrebných stacionárnych simulácií a tým zníženie celkového času výpočtu sme zaviedli dve heuristiky. „Vek rodiča“, ktorým sa snažíme zabrániť predčasnej konvergencii tým, že dovolíme každému rodičovi len obmedzený počet generácií podieľať sa na tvorbe novej populácie. „Riadené znižovanie smerodajných odchyliet σ “ zabezpečilo rýchlejšiu konvergenciu ku koncu výpočtu.

Overenie algoritmu na reálnom probléme a analýza riadiacich parametrov algoritmu

Vďaka dlhodobej spolupráci s priemyslom zabezpečujúcim tranzitnú prepravu zemného plynu plynovodom prechádzajúcim územím Slovenskej republiky sme boli schopní otestovať náš prístup a samotnú implementáciu na modeli reálneho potrubného systému v reálnych prevádzkových podmienkach a overiť možnosti riešení spomínaných reálnych praktických úloh. Taktiež sme vykonali komplexnú numerickú analýzu riadiacich parametrov na konkrétnych reálnych úlohách z praxe a odhadli optimálne nastavenie riadiacich parametrov algoritmu.

Modifikácia algoritmu pre riešenie multikriteriálnej optimalizácie

Reálne úlohy nás priviedli k potrebe implementovať aj možnosť multikriteriálnej optimalizácie, na ktorú vedie množstvo reálnych inžinierskych problémov. Možnosť počítať multikriteriálnu optimalizáciu sa stalo kompaktnou súčasťou nami realizovanej softvérovej implementácie.

Vlastná publikačná a prezentačná činnosť súvisiaca s prácou

Niektoré aspekty problémov optimalizácie na plynovodných sieťach budú prezentované v roku 2016 na Študentskej medzinárodnej konferencii ISCAMI (International Student Conference on applied Mathematics and Informatics) v Českej republike.

Výsledky práce budú prezentované v roku 2016 v časopise Tatra Mountains Mathematical Publications.

Summary

The purpose of this work was to design a suitable methodology to solve selected tasks from the field of gas transport optimization in pipeline systems. Modifications of evolution strategy algorithms to solve optimization problems of gas transport have been developed. Testing of the algorithms has been realized by a software implementation on a model of real transmission pipeline system.

Literatúra

1. International Gas Union, Global Vision for Gas, The Pathway towards a Sustainable Energy Future, Jún 2012.
2. The European Union of the Natural Gas Industry, Long-term Outlook for Gas to 2035, október 2013.
3. U.S. Energy information Administration, Annual Energy Outlook 2012 with Projection to 2035, Jún 2012.
4. *K. F. Pratt, J. G. Wilson*. Optimization of the Operation of Gas Transmission systems. Transactions of the Institute of Measurement and Control, 6(5), str. 261–269, 1984.
5. *F. B. Percell, M. J. Ryan*. Steady-state Optimization of Gas Pipeline Network Operation. PSIG 1987, príspevok 8703.
6. *H. J. Flores-Villarreal, R. Z. Ríos-Mercado*. Computational experience with a GRG method for minimizing fuel consumption on cyclic natural gas networks. Computational methods in circuits and systems applications, 90–94, 2003.
7. *P. J. Wong, R. E. Larson*. Optimization of Natural-gas Pipeline Systems via Dynamic Programming. IEEE Transactions on Automatic Control, AC-13(5), str. 475–481, 1968.
8. *P. J. Wong, R. E. Larson*. Optimization of Tree-structured Natural-gas Transmission Networks. Journal of Mathematical Analysis and Applications, 24(3), str. 613–626, 1968.
9. *H. I. Zimmer*. Calculating Optimum Pipeline Operations. Presented at the AGA Transmission Conference, 1975.
10. *D. J. Wilde*. Strategies for Optimizing macrosystems. Chemical Engineerings Progress, 61(3), str. 86–93, 1965.
11. *R. Aris, G. L. Nemhauser*. Optimization of Multistage Cyclic and Branching Systems by Serial Procedures. A.I.Ch.E. Journal, 10(6), str. 913–919, 1965.
12. *R. G. Carter*. Pipeline Optimization: Dynamic Programming after 30 Years. Huston, 1998.
13. *J. Haddad, R. M Behbahani*. Optimization of natural gas transmission system. International Journal of Computer application, vol. 66 No.11, marec 2013.
15. *R. Hajossy, A. Huček, P. Somora, T. Žáčik*. Acceleration of the computations in gas transport optimization. In: Conference Proceedins of Inter–Academia 2002, Bratislava. Eds. Kováčik D., Chudý V., Comenius University and Union of Slovak Mathematicians and Physicist, pp. 90–94.
16. *T. Žáčik, P. Somora, R. Hajossy*. Modeling and Optimizing in Slovak Gas Transmission Network. In Proceedings of the Pipeline Simulation Interest Group, PSIG Annual Meeting, 16–19 April, 2013, Prague, Czech Republic, Paper number PSIG–1319, 2013.

17. E. Zitzler. Evolutionary Algorithms for multiobjective optimization: Methods and applications, dizertačná práca, Swiss Federal Institute of Technology Zurich, 1999
18. R. S. Rosenberg. Simulation of genetic population with biochemical properties. Dizertačná práca, University of Michigan, Ann harbor, Michigan, 1967.
19. I. Das, J. Dennis. A closer look at drawbacks of minimizing weighted sums of objectives for Pareto set generation in multicriterial optimization problems. Structural optimization, 14(1) 63–69, 1997.
20. C. A. Coello Coello. A short tutorial on evolutionary multiobjective optimization. *First International Conference on Evolutionary Multi-Criterion Optimization*, pages 21–40. Springer-Verlag. Lecture Notes in Computer Science No. 1993, 2001
21. R. Z. Ríos-Mercado, C. Borraz-Sánchez. Optimization Problems in Natural Gas Transmission Systems: A State of the Art Survey, Január 2012.
25. T. Bäck, F. Hoffmeister, H.-P. Schwefel. Survey of Evolution Strategies. Fourth International Conference on Genetic Algorithms, San Mateo, CA, 1991.