

SIMULAČNÁ OPTIMALIZÁCIA – JEJ MOŽNOSTI A PROBLÉMY

Doc. Ing. Pavel Važan, PhD.

Katedra aplikovanej informatiky a automatizácie

Materiálovotechnologická fakulta

Slovenská technická univerzita v Trnave

Úvod

Vývoj simulačnej optimalizácie je možné pozorovať už celé desaťročie. Kombinácia simulácie a optimalizácie sa očakávala už dávnejšie, avšak až v poslednej dekáde sa dosiahol jej reálny vývoj. Dôležitú úlohu pri rozvoji simulačnej optimalizácie zohral vývoj nových optimalizačných techník ako aj modifikácia starších metód, ktoré sa teraz lepšie kombinujú so simuláciou. Lídri v simulačnom softvéri dnes integrujú optimalizačnú podporu do svojich softvérových balíkov (2). Simulační praktici tak majú prístup k robustným optimalizačným algoritmom a môžu ich použiť pre riešenie reálnych optimalizačných problémov. Pochopiteľne existuje veľa bariér, ktoré treba prekonať, aby simulačná optimalizácia bola širšie použiteľná. Okrem toho stále vládne istý skepticizmus a nedôvera vo výsledky simulačnej optimalizácie medzi manažérmi v konkrétnych prípadoch použitia.

Čo je simulačná optimalizácia?

V literatúre existuje veľa definícií simulačnej optimalizácie. Tu sú niektoré príklady:

Simulačná optimalizácia je charakterizovaná ako optimalizácia výstupov zo simulačných modelov. V užšom slova zmysle zo stochastických diskretných udalostami riadených simulačných modelov. (6)

Simulačná optimalizácia poskytuje štruktúrovaný prístup k určeniu optimálnych hodnôt vstupných parametrov, kde optimum je merané funkciou výstupných premenných zo simulačného modelu. (7)

V súvislosti so simulačnou optimalizáciou treba uviesť, že optimálna hodnota cieľovej funkcie nemôže byť zistená priamo, ale musí byť stanovená ako výstup simulačných behov. Existencia simulačného modelu je nutnou podmienkou, aby sa simulačná optimalizácia dala použiť. Inými slovami - simulačný model je funkcia (ktorej explicitná forma nie je známa), ktorá ohodnocuje nastavené vstupy. To znamená, že môže byť výpočtovo veľmi časovo náročná, no na druhej strane je definícia účelovej funkcie veľmi jednoduchá, často bez zložitého matematického aparátu.

Optimalizačné problémy sú zložené z troch základných komponentov (6):

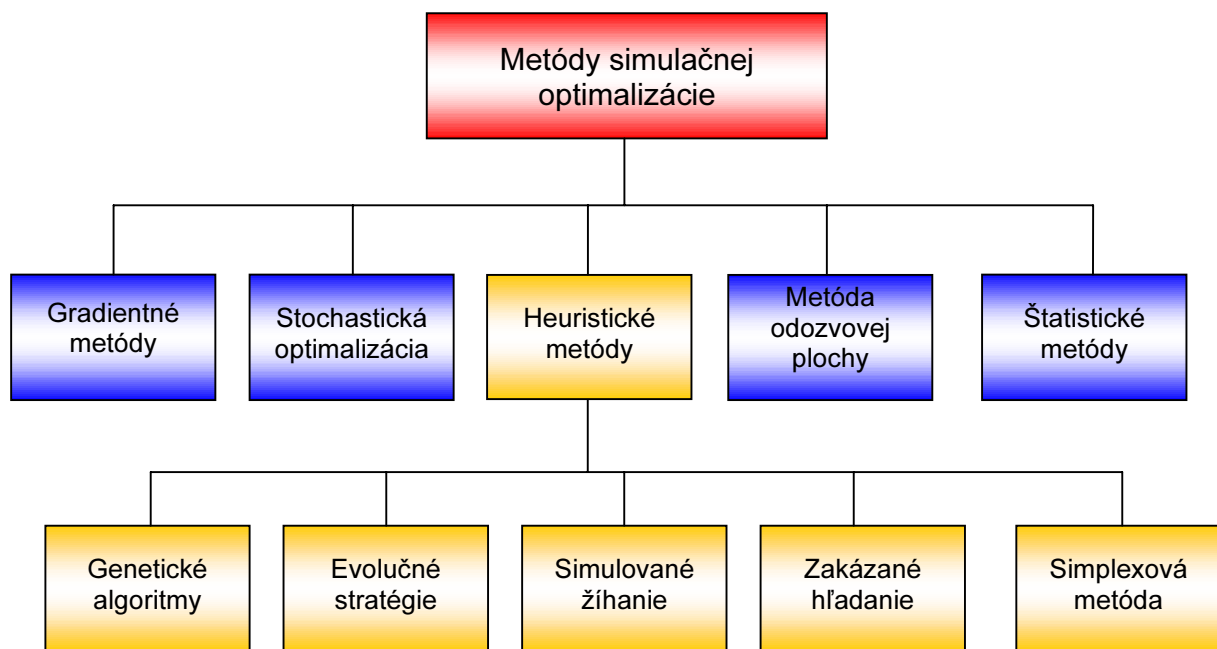
- účelová funkcia;
- súbor premenných, ktoré ovplyvňujú hodnotu účelovej funkcie;
- súbor obmedzení pre premenné.

Obmedzenia sú vítané v optimalizačných problémoch, pretože výrazne redukovujú prehľadávaný priestor a prispievajú k rýchlejšiemu nájdeniu riešenia.

Simulácia môže byť použitá pre optimalizáciu vybraných parametrov v simulovanom (napr. výrobnom) systéme. Účelom je zlepšenie hodnôt účelovej funkcie.

Metódy simulačnej optimalizácie

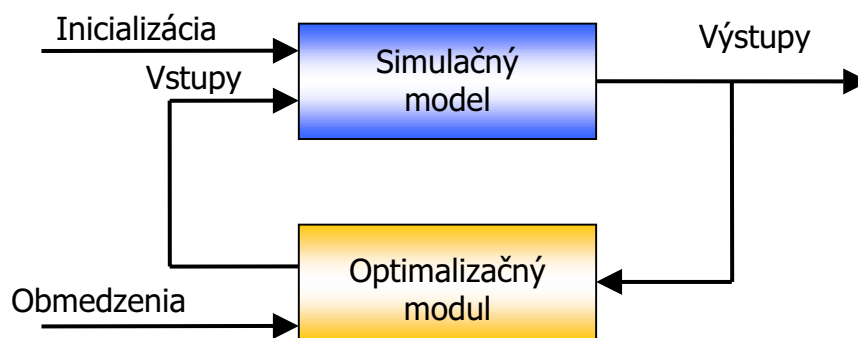
Pre simulačnú optimalizáciu existuje veľa metód. Prehľad najdôležitejších metód poskytuje obrázok 1 (5). Veľká väčšina vývojárov však požíva heuristické metódy. Tieto sú implementované vo všetkých používaných softvérových balíkoch pre simulačnú optimalizáciu (3). Heuristické metódy poskytujú dobré a rýchlo dosiahnuteľné výsledky pre širokú paletu problémov. Pochopiteľne šírka použitia, rýchlosť a presnosť získaného výsledku sú rozhodujúce faktory pre výber vhodného algoritmu.



Obr. 1: Prehľad metód simulačnej optimalizácie

Softvér pre simulačnú optimalizáciu

Výpočtová náročnosť simulačnej optimalizácie ju činí prakticky nepoužiteľnou bez počítačovej podpory. Softvérové balíky sú riešené ako plug-in moduly, ktoré sú pridané k základnej simulačnej platforme. Tento prístup k simulačnej optimalizácii nazerá na simulačný model ako na čiernu skrinku, ktorá robí ohodnocovanie účelovej funkcie (1). Obrázok 2 dokumentuje tento black-box prístup k simulačnej optimalizácii. Optimalizačný modul vyberá vstupné premenné a simulačný model používa ako odozvu systému na tieto vstupy a podľa nej vyberá vhodné vstupy pre nasledujúci krok postupu. Tento postup je automatický, dobre dokumentovaný a riadený optimalizačným modulom. Proces zastane, ak bolo nájdené optimálne riešenie.



Obr. 2: Black-box prístup k simulačnej optimalizácii

Tabuľka 1 poskytuje prehľad rozhodujúcich softvérových balíkov a ich základných vyhľadávajúcich stratégií (6). Je z nej celkom zrejmé, že dôležití výrobcovia používajú heuristické metódy. Žiadny algoritmus, ale negarantuje nájdenie optima v najkratšom možnom čase pre všetky problémy. To by bol iste monumentálny výsledok. Avšak cieľom je, aby tieto algoritmy a metódy poskytli dobré výsledky za prijateľný čas a dokázali byť úspešné pre širšie problémy ako klasické analytické metódy. Doterajšie softvérové riešenia simulačnej optimalizácie dokazujú jej úspešnosť a užitočnosť.

Tab.1: Prehľad komerčných softvérových produktov pre simulačnú optimalizáciu :

Optimalizačný balík	Simulačná platforma	Dodávateľ	Základná stratégia vyhľadávania
Optimizer	Witness	Lanner Group, Inc.	Simulované žihanie,
OptQuest	Arena	Optimization Technologies, Inc.	Vyhľadavanie rozptylom, tabu vyhľadavanie, neurónové siete
Optimiz	Simul8	Visual Thinking International, Ltd.	Neurónové siete
AutoStat	AutoMod	AutoSimulations, Inc.	genetické algoritmy
SimRunner	ProModel	ProModel Corp.	genetické algoritmy

Oblasti simulačnej optimalizácie

V literatúre (4) je identifikovaných šesť domén, ktoré sú spoločné pre softvérové nástroje v oblasti simulačnej optimalizácie. Tieto domény sú základné stavebné kamene pre unifikovanú stratégiu simulačnej optimalizácie a vytvárajú smerovanie ďalšieho výskumu a vývoja budúcej generácie simulátorov. Týmito doménami sú:

- formulácia problému,
- metódy,
- klasifikácia,
- stratégia a taktika,
- inteligencia,
- rozhrania.

Oblasť formulácie problému sa orientuje na podporu simulátora alebo optimalizátora pri definovaní účelovej funkcie a obmedzení. Zle formulovaný problém nevyrieši ani najlepší optimalizátor. Podpora užívateľovi už pri formulácii problému bude pre úspech optimalizačného balíka veľmi dôležitá.

Oblasť metód je zameraná na vývoj a poskytnutie špecifických metód pre simulačnú optimalizáciu. Doporučenia sa týkajú zlepšenia optimalizačných algoritmov aj ich výkonnosti pre špecifické situácie, ktoré prax bude vyžadovať.

Oblasť klasifikácie by sa mala zamerať na analýzu a klasifikáciu daného optimalizačného problému. Správna klasifikácia je dôležitá pre výber vhodnej metódy a stratégie postupu simulačnej optimalizácie. Zahrňuje typy a rozsahy premenných, veľkosť a topológiu prehľadávaného priestoru, rozmanitosť výstupov simulačného modelu, počet potrebných behov simulačného modelu a podobne.

Stratégia a taktika určujú kroky a ich poradie tak, aby boli výpočtové zdroje najefektívnejšie využité pre nájdenie optimálneho riešenia s vysokou presnosťou. Stratégia je zameraná na výber optimalizačnej metódy pre danú triedu problému. Taktika zahrňuje použitie metamodelovacích techník, techník pre redukciu možných kombinácií a iných nástrojov s cieľom zlepšiť účinnosť a presnosť hľadania optima.

Oblasť inteligencie zahrňuje nástroje podporujúce inteligenciu riešiteľa pri výbere strategického prístupu, ktorý použije pre riešenie optimalizačného problému a tiež zahrňuje inteligentnú podporu pre taktiku výberu nástroja, ktorá bude založená na správnej klasifikácii problému.

Oblasť rozhraní rieši rozhrania medzi užívateľom a optimalizačným modulom a medzi optimalizačným modulom a simulačným modelom. Nároky na efektívne rozhrania budú len narastať.

Výhody simulačnej optimalizácie

- Jednoduché použitie pre najrozličnejšie problémy.
- Definícia účelovej funkcie je veľmi jednoduchá. Nie je potrebný zložitý matematický aparát.

- Rovnako je jednoduché stanovovanie vstupných premenných a ich obmedzení.
- Simulačná optimalizácia prebieha automaticky.
- Výsledky sú jasne zobrazované.

Nevýhody

- Nutnosť vytvorenia simulačného modelu. Bez jeho existencie ako už bolo spomenuté nie je možné realizovať simulačnú optimalizáciu. Simulačný model navyše musí mať vysoký stupeň validity, aby jeho výsledky mohli byť akceptované. Vytvorenie simulačného modelu môže byť komplikované a zdĺhavé.
- Aj pri súčasných výkonných počítačoch a dobrých algoritmoch stále môže simulačná optimalizácia trvať veľmi dlho.
- Existuje riziko nenájdenia globálneho extrému. Hľadanie riešenia môže uviaznuť v lokálnom extréme, čo súvisí s výberom algoritmu a nastavením zlých podmienok.
- Presnosť výsledku – často je nájdený len výsledok, ktorý je blízko globálneho extrému.
- V simulačnej optimalizácii ide často o kompromis medzi presnosťou a časom získania výsledku.

Skúsenosti s Witness

Skúsenosti s Witness budú demonštrované na príklade modelu pružného výrobného systému, ktorý sa skladá zo štyroch skupín zameniteľných pracovísk. V systéme sa realizuje kusová výroba dvoch technologicky príbuzných výrobkov, ktoré sú zadávané v rozdielnych výrobných dávkach. Optimalizácia bola použitá na stanovenie minimálnych dávok. Cieľovým kritériom bola minimalizácia nákladov na 1 vyrobený kus. Táto hodnota bola ešte podmienená dosiahnutím presne kvantifikovaných hodnôt ďalších cieľov výroby ako priebežný čas, využitie strojov, požadovaný počet vyrobených kusov. Kvantitatívne ohodnotenie týchto cieľov bolo získané špeciálne navrhnutými prípravnými experimentmi. Tvar účelovej funkcie bol nasledovný:

```
IF Odvedené_ks () < priradená hodnota počtu odvedených kusov AND Využitie_strojov () < priradená hodnota minimálneho využitia strojov AND Priebežný_čas () > priradená hodnota priemerného priebežného času výroby
```

```
    Náklady_na_1ks = Náklady_celkom / Celkom_ks
```

```
RETURN Náklady_na_1ks
```

```
ELSE
```

```
    Náklady_na_1ks = Náklady_celkom / Celkom_ks + konštanta
```

```
RETURN Náklady_na_1ks
```

```
ENDIF
```

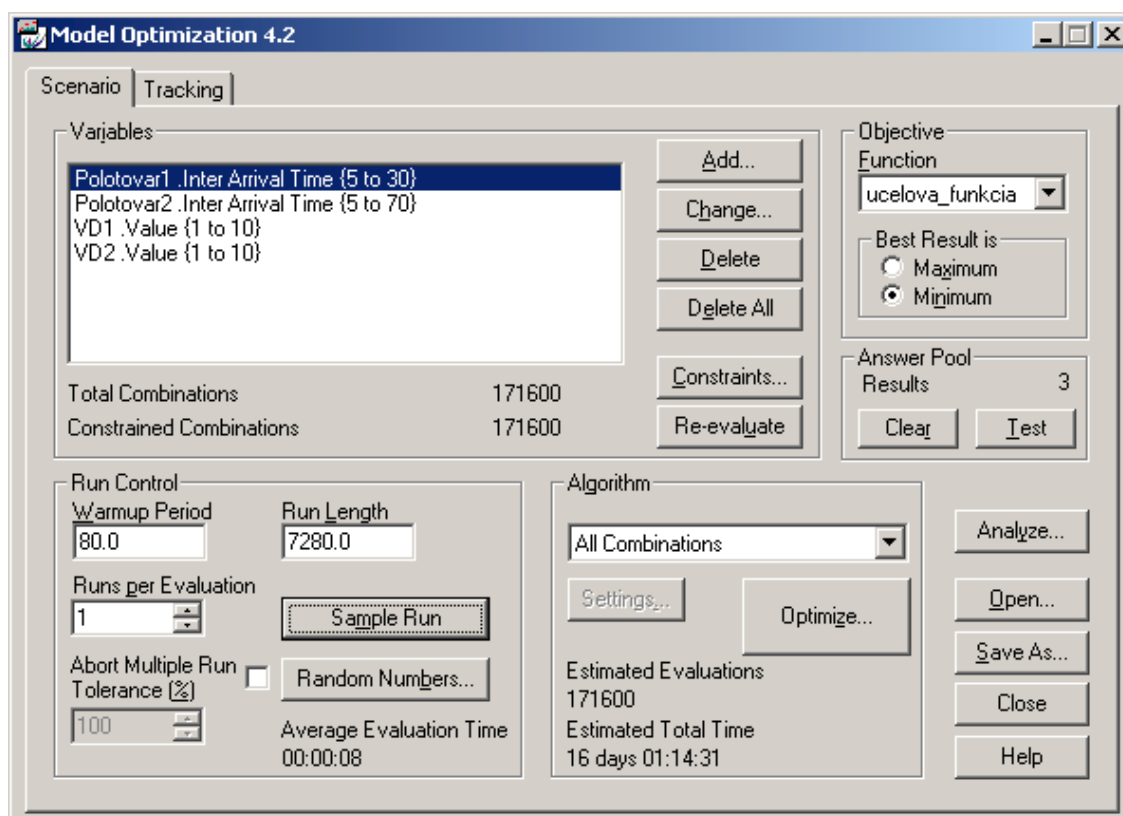
V prípade, že podmienka na začiatku nebola splnená bola k nákladom pripočítaná konštanta rádovo väčšia ako hodnota nákladov na 1 ks.

Optimalizácia veľkostí výrobných dávok (premenné VD1 a VD2 na obr.3) vyžaduje súčasne optimalizovať aj intervaly zadávania oboch dávok. Preto sú vstupné premenné štyri.

Hlavným problémom simulačnej optimalizácie je časová náročnosť. Ako vidno z obrázka, ak by sa použil algoritmus All combination odhadovaný čas by bol viac ako 16 dní. Ako teda vybrať algoritmus, aby sa v prijateľnom čase dalo nájsť akceptovateľné riešenie? Ponúka sa niekoľko možností:

- Zúžiť počet kombinácií nastavením väčšieho kroku. Táto možnosť môže byť len na úkor presnosti nájdeného riešenia.
- Definovať obmedzenia. V tomto prípade však nebolo možné určiť obmedzenia.
- Použiť vhodný algoritmus.

Podmienky optimalizácie boli nastavené ako na obr. 3.



Obr. 3: Okno Optimizera vo Witness

Na tomto príklade bude demonštrovaná zložitost' problému výberu algoritmu. Help k Witness neposkytuje dostatočné informácie pre rozhodovanie. Pokiaľ realizátor optimalizačných experimentov nie je súčasne expert v riešenej oblasti (v tomto prípade v riadení výrobných systémov s kusovou výrobou) má veľké problémy pri správnom rozhodovaní. Pri výbere algoritmu ide vždy o kompromis medzi presnosťou a akceptovateľným časom, za ktorý je získaný výsledok. Súčasne treba poznať aj ďalšie vlastnosti algoritmov ako napr. hrozba uviaznutia v lokálnom extrémne ako napr. pri algoritme Hill climb.

V nasledujúcej tabuľke 2 sú prezentované výsledky optimalizačných pokusov so všetkými algoritmi Optimizera pri ich inicializačnom nastavení.

Tab.2 Porovnanie algoritmov

Algoritmus	Nájdené optimum (minimum)	Počet vykonaných kombinácií	Čas optimalizácie
All Combinations	-	171600	-
All Combinations s krokom 2	178	17136	44h:01m:22s
SA	257	311	00h:27m:35s
SA s krokom 2	198	246	00h:23m:33s
SA s kr.2 pre 2 prem.	180	605	02h:29m:40s
HillClim	239	32	00h:02m:29s
HillClimb s krokom 2	221	53	00h:03m:58s
Random solutions	233	100	00h:14m:09s
Random solutions s krokom 2	233	100	00h:04m:01s
Min/Mid/Max	271	81	00h:11m:39s
SixSigma	230	297	00h:46m:09s

Skutočné globálne minimum je 155. Tento výsledok nedosiahol ani jeden algoritmus. Priblížil sa k nemu All combinations s krokom 2. Tento algoritmus nemohol byť použitý pre celý prehľadávaný priestor pre neakceptovateľný čas poskytnutia výsledku. Ďalším algoritmom, ktorý sa priblížil hľadanému extrému bol Adaptive Thermostatical Simulated Annealing (v tabuľke sa používa len skratka SA).

Faktory ovplyvňujúce priebeh simulačnej optimalizácie

- Vstupné premenné – ich počet a rozsah. Vytvárajú celkový počet kombinácií, ktoré treba preskúmať. Ich počet je možné znížiť obmedzeniami a vhodným krokom zmeny jednotlivých premenných.
- Dĺžka simulačného behu a nábehová doba. Predovšetkým dĺžka simulačného behu ovplyvňuje celkovú dobu realizácie simulačnej optimalizácie.
- Počet opakovaní je pochopiteľne veľmi dôležitý faktor. Treba brať do úvahy či ide o deterministický model alebo stochastický model. Pri stochastických modeloch je viac opakovaní nevyhnutných.

Navrhovaný postup výberu algoritmu a postupu optimalizácie

- Prípravnými experimentmi zúžiť rozsah premenných. Správny rozsah reprezentuje také stavy systému, ktoré sa majú preskúmať. V prezentovanom príklade hranice intervalov zadávania reprezentovali hranice málo vyťaženého resp. preťaženého systému.
- Použiť algoritmus Random solutions alebo SA s väčším krokom.
- Opakovane zúžiť rozsah premenných a experiment opakovať s použitím algoritmu SA
- Ak je možné ešte zúžiť rozsah alebo čas získania výsledku je prijateľný opakovať experiment s algoritmom All combinations alebo Hill Climb.
- Tento postup bol overený vo viacerých riešeniach.

Záver

Simulačná optimalizácia môže byť použitá pre rôzne problémy. Voľba správneho postupu však závisí od riešiteľa a zložitosti problému. Relatívna jednoduchosť softvérovej podpory simulačnej optimalizácie, kam môžeme bez problémov zaradiť aj Witness a jeho Optimizer, robí zo simulačnej optimalizácie silný nástroj pre riešenie reálnych problémov. Algoritmy a dobrá softvérová podpora zaručujú, že užívateľ nemusí byť vynikajúci matematik, aby mohol problém pomocou simulačnej optimalizácie riešiť. Verím, že simulačná optimalizácia bude bežnou metódou v rukách analytikov riešiacich mnohé problémy, často komplikovaným spôsobom.

Literatúra

1. April J., Glover F., Kelly J.P., Laguna M.: *PRACTICAL INTRODUCTION TO SIMULATION OPTIMIZATION* In S. Chick, P. J. Sánchez, D. Ferrin, and D. J. Morrice, eds. Proceedings of the 2003 Winter Simulation Conference, New Orleans dec. 2003, pp. 71-77.
2. Banks J.: The future of simulation. In: Peters B.A., Smith J.S., Medeiros D.J., Rohrer m.W.: Proceedings of the 2001 Winter Simulation Conference. Arlington, USA
3. Boesel J., Glover F., Bowden O.R., Kelly J. P., Westvig E.: Future of simulation optimization. In: Peters B.A., Smith J.S., Medeiros D.J., Rohrer m.W.: Proceedings of the 2001 Winter Simulation Conference. Arlington, USA.
4. Bowden R. O., Hall J.D.: Simulation optimization research and development. In: Medeiros D.J., Watson E. F.: Carson J.S.: Manivannan J.S.: Proceedings of the 1998 Winter Simulation Conference., USA. pp. 1693-1698
5. Carson Y., Maria A.: Simulation optimization: Methods and applications. In: Andraróttir S., Healy K.J., Withers D.H., Nelson B.L.: Proceedings of the 1997 Winter Simulation Conference., USA. pp. 118-126

6. Fu C. M.: *Simulation Optimization* In: Peters B.A., Smith J.S., Medeiros D.J., Rohrer m.W.: Proceedings of the 2001 Winter Simulation Conference. Arlington, USA
7. Swisher J.R., Jacobson S.H., Hyden P.D., Schruben L.W.: *A survey of simulation optimization techniques and procedures*. In Joines J.A., Barton R.R., Kang K., Fishwick, P.A.,: Proceedings of the 2000 Winter Simulation Conference. Orlando, USA

