

HODNOTENIE ALGORITMOV SIMULAČNEJ OPTIMALIZÁCIE VO WITNESS

Doc. Ing. Pavel Važan, PhD., Ing. Róbert Pauliček

Ústav aplikovanej informatiky a automatizácie

Materiálovotechnologická fakulta

Slovenská technická univerzita v Trnave

Úvod

Dôležitou časťou simulácie je optimalizácia. Optimalizácia v simulácii je proces hľadania najlepších parametrov rozhodovacích premenných systému, kde je výkon hodnotený na základe výstupu simulačného modelu[1].

Existuje veľa simulačných a optimalizačných softvérov, ktoré obsahujú rôzne druhy algoritmov vhodných na dosiahnutie optimálneho riešenia bez použitia zložitých matematických štruktúr. Cieľom projektu, ktorého výsledky budú prezentované v tomto príspevku, bolo porovnať optimalizačné algoritmy v module Optimizer. Na základe získaných poznatkov bude navrhnutý všeobecný postup realizácie optimalizácie, ktorý bude slúžiť ako návod pre riešenie rôznych optimalizačných problémov vo WITNESS Optimizer.

Cieľom optimalizačného algoritmu je nájsť riešenie, ktoré spĺňa určitú množinu ohraničení tak, že je nájdený globálny extrém účelovej funkcie (minimum alebo maximum). Úspešnosť optimalizačných algoritmov je často meraná ako rýchlosť, s ktorou dokáže modul nájsť optimum, alebo výsledok blízky optimálnemu riešeniu. Rýchlosť je dôležitá, pretože výsledky simulačného experimentu nie sú vypočítané okamžite, ale výpočet trvá nejaký čas. Obyčajne nie je možné uskutočniť milióny experimentov, a preto dobrý algoritmus musí byť schopný nájsť dobré výsledky v prípustnom čase.

Algoritmy modulu Optimizer

Random Solutions

Random Solutions (náhodné riešenia) umožňuje zhodnotiť tvar prehľadávaného priestoru riešení, nevyžaduje veľký čas potrebný na získanie hodnôt a priblíži možné miesta výskytu optima. Najjednoduchším spôsobom hľadania optimálneho riešenia je jeho náhodné hľadanie. Algoritmus opakovane generuje náhodne riešenie z určitej oblasti a zapamätá si ho len vtedy, ak bolo získané lepšie riešenie ako to, ktoré už bolo zaznamenané v predchádzajúcej histórii algoritmu.

All Combinations

Tento algoritmus rieši nájdenie optimálneho riešenia „hrubou silou“. Riešenie hrubou silou je spôsob riešenia problému či úlohy, pri ktorom sa systematicky prechádza celý priestor možných riešení problému a zisťuje, ako vyhovujú zadaným podmienkam. Algoritmy tohto typu sa ľahko implementujú a vždy nájdu riešenie, ak existuje. Často čas potrebný k nájdeniu optimálneho riešenia rastie exponenciálne, či dokonca faktoriálom, takže i pre veľmi malé priestory riešenia je tento algoritmus v praxi málo využívaný.

Hill Climb

Horolezecké (angl. "hillclimbing") algoritmy sú gradientnou metódou hľadania extrému v lokálnom okolí nejakého bodu. Je to stochastické prehľadávanie doplnené o usmernenie generovaných riešení. Princípom horolezeckého algoritmu je prehľadanie lokálneho okolia najlepšieho nájdeného riešenia (alebo náhodne vygenerovaného riešenia na začiatku procesu optimalizácie). Namiesto náhodného ďalšieho riešenia sa použije najlepšie doposiaľ nájdené riešenie, v ktorom sa urobí určitá malá zmena (napr. sa zmení 5 % parametrov tohto riešenia).

Toto nové riešenie sa prijme, ak je lepšie ako to, z ktorého vzniklo; ak je horšie, opäť sa urobí iná malá zmena najlepšieho riešenia. Závislosť nového riešenia od predchádzajúceho je v tomto algoritme silná. Je to rýchly algoritmus, ktorý ale často uviazne v lokálnom extréme.

Min/Mid/Max

Min/Mid/Max - testuje extrémy (minimálne a maximálne hodnoty premenných) a stredné hodnoty všetkých nastavených parametrov. Pokrýva všetky možnosti

pre nerozsahové parametre. Algoritmus nepovoľuje v module Optimizer žiadne špecifické nastavenia.

Adaptive Thermostatical Simulated Annealing

Adaptive Thermostatical SA je hlavný algoritmus, variant simulovaného žihania s extra prispôsobivým charakterom. Zahrňuje prvky tabu hľadania. WITNESS Optimizer využíva algoritmus simulovaného žihania, ktorý vychádza z Metropolisovho algoritmu. Metropolisov algoritmus sa snaží na rozdiel od horolezeckého algoritmu zabrániť uviaznutiu v lokálnom extrémne tým, že za určitých podmienok prijíma za lepšie riešenie aj to, ktoré má mierne nižšiu „fitness“ ako predchádzajúce najlepšie riešenie. "Ochladzovanie" v tejto metóde znamená postupné znižovanie pravdepodobnosti, s ktorou sa do ďalšieho kroku prijme aj horšie riešenie.

Six Sigma Algorithms

Je veľmi podobný algoritmu Adaptive Thermostatical Simulated Annealing. Pretože parametre potrebné pre použitie tohto algoritmu neboli vo vybraných modeloch nastavené, tak sme do porovnávania tento algoritmus nezahrnuli [2].

Charakteristika použitých modelov

Do projektu sme vybrali 4 simulačné modely. Dva z nich a to model pre vybavenie reklamácie počítačových zostáv BprBase.mod (bude označený ako model č.1) a model výrobného systému ManBase.mod (bude označený ako model č.2) sú štandardne dodávané ako vzorové príklady pre simulačnú optimalizáciu vo Witness a dva modely výrobných systémov, ktoré boli vytvorené v rámci tohto projektu. V oboch modeloch sa pomocou simulačnej optimalizácie určovala optimálna veľkosť výrobných dávok (vždy dvoch výrobkov), pričom sa minimalizovali náklady na jeden kus. Tieto modely sú označené ako model č.3 a model č.4.

Z pohľadu použitia simulačnej optimalizácie je dôležité poznamenať, že modely č.1 a č.2 predstavujú modely so stochastickými prvkami. To znamená, že na jedno ohodnotenie účelovej funkcie bude potrebných viac behov. Naopak modely č.3 a 4 sú deterministické.

Tiež dôležité sú počty vstupných premenných a celkový počet kombinácií, ktoré tieto premenné vytvárajú. Model č.1 má 10 vstupných premenných. Ich rozsah (definičný obor) je však malý a spolu vytvárajú 21600 možných kombinácií vstupov. Model č. 2 má 6 vstupných premenných, ktoré spolu vytvárajú 87846 možných kombinácií vstupov. Model č. 3 má 4 vstupné premenné, ale s väčším rozsahom, ktoré spolu vytvárajú 171600 možných kombinácií vstupov. Model č. 4 má 4 vstupné premenné, ktoré spolu vytvárajú 78400 možných kombinácií vstupov.

Scenár experimentov

Jednotlivé algoritmy budú mať nastavené rovnaké hodnoty špecifických parametrov Maximum Evaluations =800, Maximum Moves Without Improvement = 300.

Základný scenár všetkých experimentov bol nasledujúci:

- počet behov na jedno ohodnotenie účelovej funkcie nastaviť na 1, veľkosť kroku 1;
- ak čas optimalizácie je prijateľný, vždy začať s algoritmom All Combinations aby sme hneď zistili globálny extrém účelovej funkcie a až potom pokračovať s ostatnými algoritmi;
- počet behov na jedno ohodnotenie účelovej funkcie zvýšiť z 1 na 3;
- na základe výsledkov získaných z prvých dvoch experimentov zúžiť rozsah premenných;
- kvalitu optimalizácie sa bude hodnotiť na základe času a presnosti nájdeného optima;
- získané výsledky budú zobrazované v tabuľkách a grafoch;

Výsledky experimentov pre 1. model

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive Thermostatistical SA	12020	0:04:23	0:01:54	467
All Combinations	12080	2:15:21	1:43:51	21600
Random Solutions	11980	0:03:24	0:02:58	800
Min/Mid/Max	11940	0:48:37	0:35:27	7776
Hill Climb	11940	0:02:02	0:00:09	334

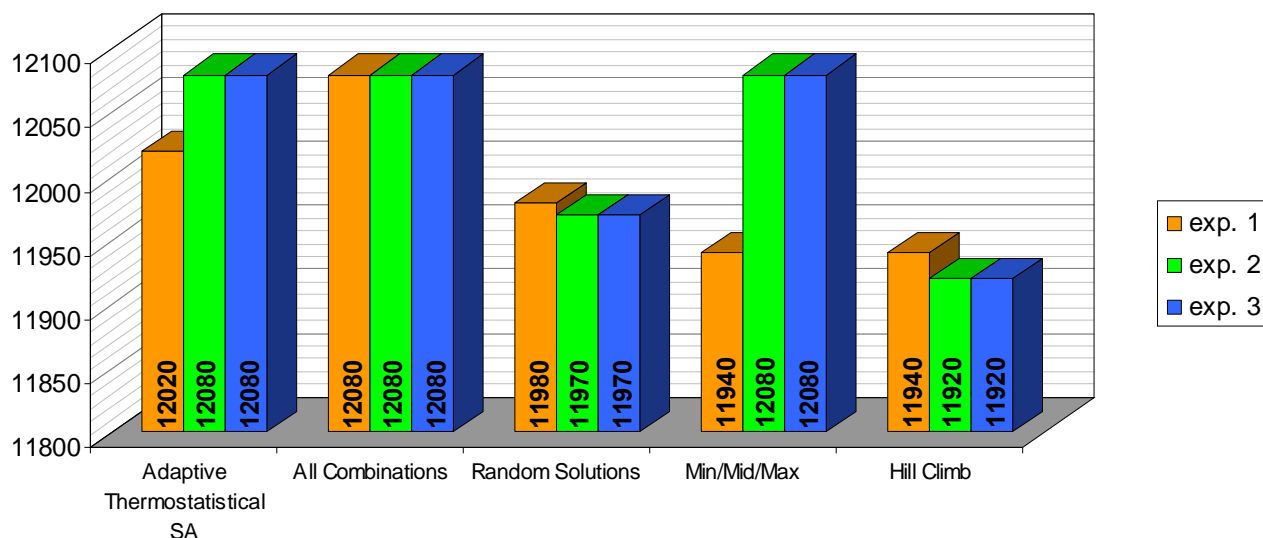
Exp. 1, veľkosť kroku 1 pre všetky premenné, 1 beh za evolúciu

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive Thermostatistical SA	12080	0:05:00	0:00:51	522
All Combinations	12080	0:32:24	0:21:40	5184
Random Solutions	11970	0:03:45	0:03:28	800
Min/Mid/Max	12080	0:24:16	0:21:17	5184
Hill Climb	11920	0:03:58	0:00:09	305

Exp. 2, veľkosť kroku 1 pre všetky premenné, 3 behy za evolúciu

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive Thermostatistical SA	12080	0:05:00	0:00:51	522
All Combinations	12080	0:32:24	0:21:40	5184
Random Solutions	11970	0:03:45	0:03:28	800
Min/Mid/Max	12080	0:24:16	0:21:17	5184
Hill Climb	11920	0:03:58	0:00:09	305

Exp. 3, veľkosť kroku 1 pre všetky premenné (zúžený rozsah), 1 beh za evolúciu



Ako ukazuje graf, zúženie premenných prinieslo podstatné zlepšenie výsledku. Až tri algoritmy dosiahli optimálnu hodnotu (12080), pričom sa hodnoty časov výrazne skrátili. Pri algoritme All Combinations bola optimálna hodnota získaná už za necelých 22 minút, čo je skoro polovičná hodnota času algoritmu Min/Mid/Max v prvom experimente. Čas získania jedného ohodnotenia bol v tomto modeli menej ako 1s.

Na základe získaných výsledkov je možné tvrdiť, že obmedzenie rozsahu vstupných premenných výrazne ovplyvňuje kvalitu optimalizácie. Nielen že sa výrazne zmenší čas potrebný na optimalizáciu pre všetky algoritmy, ale aj hodnoty získané pomocou jednotlivých algoritmov sú mnohokrát presnejšie. Navyše algoritmy ktoré predtým neboli schopné nájsť optimum, po zúžení premenných optimum našli v relatívne krátkom čase.

Výsledky experimentov pre 2. model

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	440	0:07:36	0:01:53	325
All Combinations	455	1:32:00	1:18:28	16530
Random Solutions	445	0:07:25	0:06:16	800
Min/Mid/Max	440	0:04:05	0:00:14	30
Hill Climb	455	0:06:29	0:00:06	310

Exp. 1, veľkosť kroku 1 pre všetky premenné, 1 beh za evolúciu

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	443	0:03:56	0:00:58	666
All Combinations	444	0:34:41	0:07:45	1578
Random Solutions	444	0:04:41	0:02:40	800
Min/Mid/Max	440	0:02:26	0:00:10	42
Hill Climb	366	0:03:10	0:00:05	306

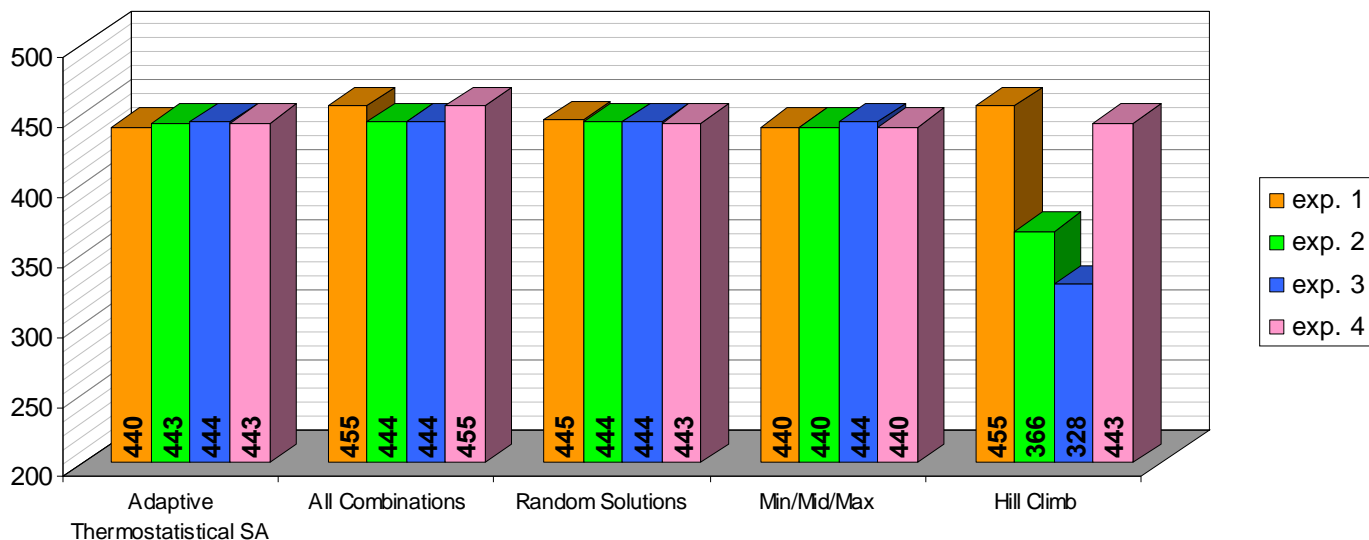
Exp. 2, veľkosť kroku 2 pre 4 premenné, 1 beh za evolúciu

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	444	0:02:34	0:01:19	342
All Combinations	444	0:12:26	0:01:10	342
Random Solutions	444	0:01:10	0:01:10	342
Min/Mid/Max	444	0:01:39	0:01:14	342
Hill Climb	328	0:02:53	0:00:03	302

Exp. 3, veľkosť kroku 3 pre 4 premenné, 1 beh za evolúciu

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	443	0:03:25	0:00:34	307
All Combinations	455	0:12:21	0:05:30	1476
Random Solutions	443	0:02:59	0:01:58	800
Min/Mid/Max	440	0:01:10	0:00:25	128
Hill Climb	443	0:02:39	0:00:03	302

Exp. 4, veľkosť kroku 1 pre všetky premenné (zúžený rozsah), 1 beh za evolúciu



Z časového hľadiska boli jednotlivé postupy približne rovnaké, trochu lepší sa ukázal postup so zúžením premenných, ktorý však dosiahol časy lepšie len o niekoľko sekúnd. Pri rovnakom počte kombinácií teda nemá spôsob postupu výrazný vplyv na čas.

Výsledky s počtom ohodnotení boli tiež mierne lepšie pri postupe so zúžením premenných, čo vidno hlavne pri algoritme Min/Mid/Max, kde sa počet ohodnotení zmenšil približne 3-krát. Z toho možno vyvodiť záver, že zúžením premenných sa prehľadávaná oblasť zmenšila približne 3-krát oproti experimentu č.2.

Výsledky experimentov pre 3. model

Algoritmus	Nájdene optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	189	0:27:51	0:06:59	627
All Combinations	189	2:58:17	2:56:48	8280
Random Solutions	249	0:24:16	0:23:56	800
Min/Mid/Max	271	0:01:50	0:01:40	81
Hill Climb	252	0:25:00	0:00:36	317

Exp. 1, veľkosť kroku 2 pre 2 premenné a 3 pre 2 premenné

Algoritmus	Nájdene optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	179	0:17:40	0:04:04	467
All Combinations	163	1:01:52	0:59:02	2800
Random Solutions	164	0:30:33	0:21:07	800
Min/Mid/Max	189	0:02:28	0:02:27	81
Hill Climb	183	0:24:18	0:00:33	318


Exp. 2, veľkosť kroku 1 pre všetky premenné (zúžený rozsah)

Algoritmus	Nájdene optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	162	0:15:15	0:14:31	441
All Combinations	162	0:14:23	0:15:06	441
Random Solutions	162	0:14:30	0:14:05	441
Min/Mid/Max	162	0:02:35	0:02:34	81
Hill Climb	163	0:25:26	0:00:37	441

Exp. 3, veľkosť kroku 1 pre všetky premenné (2 krát zúžený rozsah)

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
SA	162	0:18:09	0:01:34	321
All Comb.	155	0:25:00	0:22:28	990
Random S.	155	0:17:48	0:12:39	800
M/M/M	170	0:01:49	0:01:48	81
Hill Climb	1114	0:27:07	0:00:23	311

Exp. 4, veľkosť kroku 1 pre všetky premenné (rozšírený rozsah exp. 3)



Celkovo sa optimum (155) našlo až v štvrtom experimente, keď sa zužoval rozsah premenných až 3-krát. Výsledok bol získaný približne za 1 hodinu a 28 minút. Ak by sa však rozsah premenných po prvom experimente nezužil priveľmi (hodnoty extrému boli nájdené na hraniciach intervalov vstupných premenných), získanie výsledku by bolo pravdepodobne skôr. Preto sa v ďalšom experimente zisťovalo, ako dosiahnuť optimálnu hodnotu pri modeli s veľkým počtom kombinácií. Dôraz sa kládol hlavne na to, ako zúžiť rozsah premenných, pričom sa nevychádza z hodnôt získaných algoritmom All Combinations. Čas získania jedného ohodnotenia bol v tomto modeli menej ako jedna sekunda.

Výsledky experimentov pre 4. model

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	203.307	0:08:32	0:02:58	530
All Combinations	193.897	6:39:27	4:10:48	21205
Random Solutions	195.17	0:07:01	0:07:08	800
Min/Mid/Max	1158.584	0:00:44	0:00:42	81
Hill Climb	1358.506	0:07:31	0:00:08	304

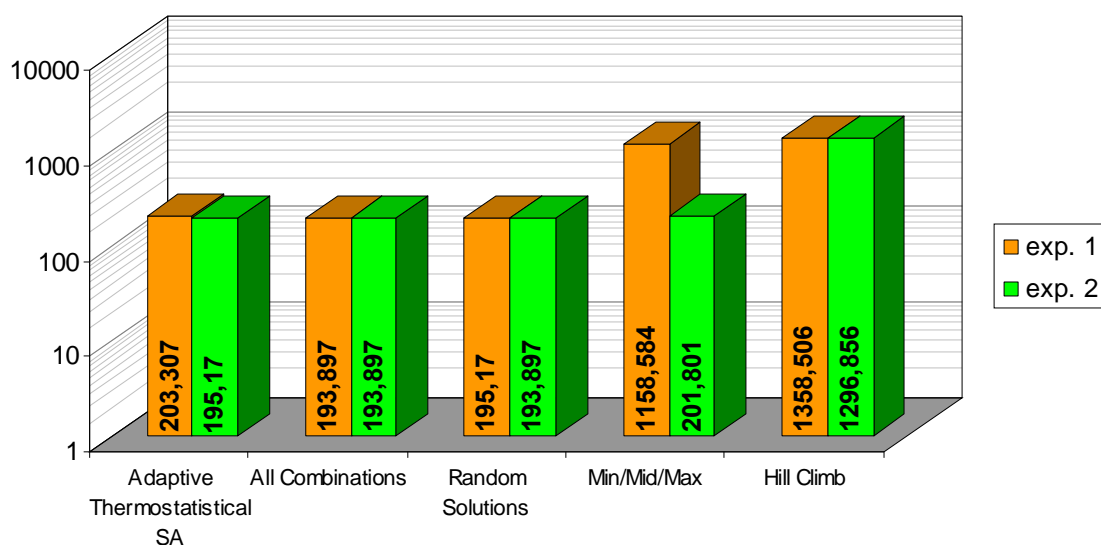
Exp. 1, veľkosť kroku 2 pre 2 premenné

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
Adaptive ThermostatisticalSA	195.17	0:05:30	0:00:44	402
All Combinations	193.897	0:38:21	0:34:15	4725
Random Solutions	193.897	0:05:44	0:05:23	800
Min/Mid/Max	201.801	0:00:35	0:00:32	81
Hill Climb	1296.856	0:05:21	0:00:06	317

Exp. 2, veľkosť kroku 2 pre 2 premenné (zúženie rozsahu)

Algoritmus	Nájdené optimum	Odhadovaný čas	Skutočný čas	Počet ohodnotení
SA krok 2 pre veľké rozsahy	222.326	0:05:27	0:01:59	690
Random Solutions krok 1	209.907	0:05:29	0:05:20	800
SA zúžené rozsahy	210.087	0:05:58	0:00:42	531
SA upravené rozsahy	204.177	0:06:15	0:05:36	800
SA upravené rozsahy 2	202.62	0:05:29	0:02:09	422
All Combinations	193.897	0:43:40	0:38:09	5040

Exp. 3, postupná kombinácia algoritmov za účelom zužovania intervalu



Výsledok ukázal, že kombináciou viacerých algoritmov a postupným zužovaním rozsahov je čas optimalizácie kratší, ako pri použití algoritmu All Combinations hneď na začiatku optimalizácie. Daný postup našiel optimálnu aj hodnotu účelovej funkcie.

Problémom pri tomto postupe je správne určenie nových rozsahov premenných. Pri modeloch s veľkým počtom kombinácií odporúčame zužovať rozsahy vzhľadom na počet

kombinácií. Pri prvom zúžení rozsahov by sa mal počet kombinácií pohybovať okolo 10000. To by malo zabrániť vynechaniu niektorej z hodnôt, ktorá by v konečnom dôsledku mohla byť súčasťou kombinácie pre optimum účelovej funkcie. Pri ďalších úpravách premenných je potrebné zúžiť rozsahy tak, aby sa počet kombinácií pohyboval približne okolo 3-5 tisíc. Potom je výhodné použiť algoritmus All Combinations.

Pri algoritmoch Adaptive Thermostatistical SA a Random Solutions odporúčame nastavovať počet ohodnotení na 800. Počet ohodnotení algoritmu Adaptive Thermostatistical SA bez zlepšenia na 300. Ostatné nastavenia algoritmu Adaptive Thermostatistical SA (Initial Temperature, Cooling Rate, Cooling steps a Adaptive Search) odporúčame nemeniť.

Vyhodnotenie simulačných experimentov a návrh voľby optimalizačných algoritmov

Základným kritériom pre optimalizáciu je získať čo najpresnejšie výsledky v čo najkratšom čase. Jednotlivé algoritmy WITNESS Optimizer potrebujú na určenie výsledku rôzny čas pri rovnakých podmienkach a získané výsledky sú tiež často krát rôzne.

Pre modely s malým počtom optimalizačných premenných s malými rozsahmi odporúčam použiť algoritmus All Combinations s krokom 1, ktorý zaručene nájde hľadané optimum.

Pre modely s veľkým počtom optimalizačných premenných a malými rozsahmi odporúčam použiť algoritmus Adaptive Thermostatistical SA s krokom 1. Algoritmus síce nemusí nájsť optimálnu hodnotu účelovej funkcie, ale získaná hodnota vo viacerých experimentoch bola najbližšia optimu a čas potrebný na nájdenie riešenia bude mnohonásobne menší, ako pri použití algoritmu All Combinations.

Pre modely s malým počtom optimalizačných premenných a veľkými rozsahmi odporúčame postupovať kombináciou viacerých algoritmov nasledovne:

- Optimalizovať model algoritmom Random Solutions s krokom 1
- Optimalizovať model algoritmom Adaptive Thermostatistical SA so zväčšeným krokom pre premenné s veľkými rozsahmi
 - Odporúčame krok 1 pre rozsah premenných od 1 do 20
 - Odporúčame krok 2 pre rozsah premenných od 20 do 40
 - Odporúčame krok 3 pre rozsah premenných nad 40
- Analyzovať získané výsledky pre oba algoritmy
- Na základe najlepších výsledkov upraviť rozsahy premenných
 - Najlepšie hodnoty musia ležať v nových rozsahoch premenných, nie však na hranici
 - Celkový počet kombinácií by sa mal pohybovať okolo 10000
- Optimalizovať model algoritmom Adaptive Thermostatistical SA s krokom 1
- Analyzovať získané výsledky
 - Najlepšie hodnoty nesmú ležať na okrajoch (hraniciach) rozsahov premenných
 - Ak hodnoty ležia na okraji premenných, pravdepodobne existujú lepšie hodnoty a je potrebné znovu upraviť rozsahy
 - Pri úprave rozsahov je potrebné sledovať minimálne 5 najlepších hodnôt a ich postupnosť k nejakej hodnote rozsahu premennej
- Znovu optimalizovať model algoritmom Adaptive Thermostatistical SA s krokom 1
 - Ak hodnoty neležia na okraji premenných, pravdepodobne je najlepšia hodnota hľadané optimum, alebo sa optimum nachádza v týchto rozsahoch premenných
- Ak sa dosiahne malý počet kombinácií (okolo 5000) a je odhadovaný prijateľný čas pre algoritmus All Combinations, verifikovať výsledok týmto algoritmom
- Získaný výsledok by mal byť optimum

Záver

Cieľom projektu bolo porovnať algoritmy simulačnej optimalizácie vo Witness Optimizer. Ako kritériá pre hodnotenie kvality algoritmov bol zvolený čas potrebný na nájdenie najlepšej hodnoty účelovej funkcie a presnosť algoritmov pri hľadaní optimálnej hodnoty účelovej funkcie. Porovnávanie sa realizovalo na štyroch rôznych modeloch. Poznatky získané z porovnávacej štúdie boli zosumarizované do postupu ako najvhodnejšie realizovať simulačnú optimalizáciu vo Witness, tak aby za čo najkratší čas boli dosiahnuté buď optimálne hodnoty účelovej funkcie alebo hodnoty, ktoré sú veľmi blízko optimálnej hodnoty.

Použitá literatúra:

- [1] Waller A.P. **Optimization of simulation experiments**, Available from : http://www.dynamic.co.kr/Witness_Training_Center/Articles/White%20paper%20-%20Optimization.pdf Accessed: 2010-04-28

- [2] Bc. Mrva, M: **Porovnanie vybraných algoritmov simulačnej optimalizácie**. [Diplomová práca] – Slovenská technická univerzita v Bratislave. Materiálovotechnologická fakulta so sídlom v Trnave; – Vedúci diplomovej práce: doc. Ing. Pavel Važan, PhD. – Trnava: MtF STU, 2008, 111 pages.