



MOŽNOSTI VYUŽITIA GENETICKÉHO ALGORITMU PRI OPTIMALIZÁCII ENERGETICKÝCH SYSTÉMOV

POSSIBILITIES OF GENETIC ALGORITHM USE IN ENERGY SYSTEM OPTIMIZATION

Juraj ŠEBO

Abstract: This article deals with the optimization of energy systems using genetic algorithm. It describes the functioning of genetic algorithm and provides methodologies of its application in the context of optimization of energy systems with a focus on hybrid systems using different (in our case particularly alternative) energy sources. Application of the above methodologies generally confirm the suitability of the application of genetic algorithms in the optimization of the number, type, or other characteristics of installations in the energy systems operating with different energy sources, and also confirm reliance of these methodologies on mathematical models for included electric power generation sources.

Abstrakt: Tento článok sa zaoberá problematikou optimalizácie energetických systémov pomocou genetického algoritmu. Popisuje podstatu fungovania genetického algoritmu a uvádza metodické postupy jeho aplikácie v kontexte optimalizácie energetických systémov so zameraním na hybridné systémy využívajúce rôzne (v našom prípade najmä alternatívne) zdroje energie. Aplikácie popísaných metodík vo všeobecnosti potvrdzujú vhodnosť aplikovania genetických algoritmov v oblasti optimalizácie počtu, typu, prípadne iných charakteristík zariadení v energetických systémoch pracujúcich s rôznymi zdrojmi energie, a tiež potvrdzujú závislosť týchto metodík na matematických modeloch generovania elektrickej energie pre zahrnuté zdroje.

Kľúčové slová: genetický algoritmus, optimalizácia, energetický systém, alternatívne zdroje energie.

Úvod

V oblasti umelej inteligencie patrí genetický algoritmus (GA) medzi vyhľadávacie heuristiky, ktoré napodobňujú prirodzený výber. Táto heuristika sa štandardne používa na generovanie použiteľných riešení pri optimalizácii a vyhľadávacích problémoch. [1] Genetický algoritmus patrí do skupiny evolučných algoritmov, ktoré využívajú na riešenie optimalizačných problémov techniky inšpirované evolúciou prírody, ako sú dedičnosť, mutácia, výber a kríženie. [2] V rámci genetického algoritmu sa využíva funkcia kódovania, ktorou sa zabezpečí transfer charakteristík (premenných) objektov do kódu reťazca (chromozómu) a dekódovania na transfer reťazca kódu (chromozómu) späť na charakteristiky (premenné) objektov. Chromozóm teda predstavuje reťazec určitej dĺžky, kde sú uložené všetky genetické informácie jedinca. Každý chromozóm sa skladá z mnohých alel. Alely sú najmenšie informačné jednotky v chromozóme. [3] Najjednoduchší algoritmus má chromozóm vo forme bitového reťazca, t.j. obsahujúci iba hodnoty 0 a 1 (napr. chromozóm o dĺžke 8 alel, má tvar 1,0,0,0,0,0,1,1). Na zápis číselných charakteristík (parametrov) je možné v chromozóme (reťazci) štandardne využiť celé čísla (napr. chromozóm o dĺžke 8 alel, má tvar 1,5,7,3,4,4,1,1).



Popis troch metodológií využívania genetických algoritmov v oblasti optimalizácie energetických systémov

Metodológia podľa Ismail et al. (2014)

Táto metodológia je zameraná na dimenzujúcu optimalizáciu komponentov hybridného systému a snaží sa identifikovať taký hybridný systém, ktorý minimalizuje náklady na výrobu energie a zároveň maximalizuje využitie solárnych panelov a minimalizuje emisie znečisťujúcich látok. Pred alebo v rámci optimalizácie je potrebné vybalansovať energiu za každú hodinu v priebehu celého roka. Pre tento účel je potrebné vypočítať energiu generovanú každým zdrojom (zariadením). To si vyžaduje matematické modelovanie každého komponentu v systéme, ktoré si ďalej vyžaduje dostupnosť údajov o klíme, čo si vyžaduje analýzu aj týchto údajov. Analýza slnečného žiarenia a vytvorenie matematického modelu komponentov tvoriacich hybridný systém sú nevyhnutné kroky, ktoré treba tiež vykonať pred vykonaním dimenzujúcej optimalizácie komponentov hybridného systému (spracované podľa [4]).

Táto metodológia využíva nasledovný optimalizačný postup založený na genetickom algoritme [4]:

1. Definovanie obmedzení a inicializácie
2. Vstup: slnečné žiarenie po hodinách, teplota po hodinách, dopyt po energii, typ zariadení, všetky druhy nákladov a iné globálne vstupy
3. Optimalizácia uhlu a smeru orientácie fotovoltaiických panelov(FP) založená na maximálnej vygenerovanej energii za rok
4. Vytvorenie štruktúry „chromozómu“ a počiatkovej populácie.
5. Výpočet energetickej rovnováhy pomocou prístupu (viď iný článok autora Ismail(2014)) a výpočet pravdepodobnosti nepokrytia dopytu po energii
6. Výpočet ohodnocovacej (fitness) funkcie (náklady na výrobu energie)
7. Rozhodovanie či sa vytvorili a preskúmali všetky generácie (Pozn. Podľa vopred zadaného počtu)
 - a. Ak áno vytvorí sa výstup, ktorý zahŕňa: náklady na výrobu energie, pravdepodobnosť nepokrytia dopytu po energii, optimálne typy zariadení, optimálny počet a optimálny smer a uhol FP na základe minimalizácie nákladov na výrobu energie
 - b. Ak nie pokračuje sa v algoritme na krok 9
8. Selekcia – vytvorenie párov
9. Kríženie – vytvorenie potomkov
10. Kontrola obmedzení a oprava „chromozómov“
11. Mutácia – vytvorenie novej generácie
12. Kontrola obmedzení a oprava „chromozómov“
13. Pokračovanie – skok na krok 6

Metodológia podľa Koutroulis et al. (2006)

Táto metodológia využíva nasledovný optimalizačný postup využívajúci genetický algoritmus [5]:

1. Špecifikácie vstupov (konkrétne špecifikácie nabíjačiek batérií, fotovoltaiických modulov, veterných generátorov, batérií a DC/AC meničov)
2. Výber kombinácie fotovoltaiických modulov, veterných generátorov, nabíjačiek batérií a DC/AC meničov



3. Optimalizácia počtu jednotlivých zariadení. V tomto kroku do výpočtu vstupujú:
 - a. Požiadavky spotrebiteľov elektrickej energie
 - b. Denná dávka slnečného žiarenia a priemerné hodinové teploty a rýchlosti vetra
4. Uloženie optimálnych parametrov (počtu)
5. Rozhodovanie o tom či už boli všetky kombinácie optimalizované
 - a. Ak nie vracia sa algoritmus späť na krok 2
 - b. Ak áno pokračuje algoritmus ďalej
6. Výber kombinácie zariadení s najnižšími nákladmi

Tento optimalizačný algoritmus je na vstupe naplňaný údajmi z databázy obsahujúcej technické charakteristiky bežne dostupných zariadení (rôznych typov fotovoltických modulov, veterných generátorov, batérií, atď.) spolu s ich jednotkovými kapitálovými nákladmi a nákladmi na údržbu. Prvý krok v rámci optimalizácie počtu jednotlivých zariadení je založený na simulácii systému, s cieľom posúdiť, či konfigurácia systému, ktorá zahŕňa určitý počet jednotlivých zariadení a detaily inštalácie, spĺňa požiadavky na dodávky elektrickej energie v priebehu roka. Prevádzka systému je simulovaná za obdobie jedného roka s časovým krokom 1 hodiny. Údaje, ktoré využíva sú: denná dávka slnečného žiarenia v horizontálnej rovine, hodinové priemerné hodnoty vonkajšej teploty a rýchlosti vetra a požiadavky spotrebiteľov na dodávku elektrickej energie v priebehu jedného roka. Druhý krok optimalizácie počtu jednotlivých zariadení sa skladá z metódy využívajúcej genetický algoritmus, ktorý dynamicky vyhľadáva konfiguráciu systému, ktorá spĺňa podmienky stanovené v prvom kroku a minimalizuje celkové náklady systému. Pre každú kombináciu typov zariadení z ktorých sa systém skladá, sa v rámci optimalizácie počtu jednotlivých zariadení vykoná výpočet zodpovedajúcich optimálnych celkových nákladov a konfigurácie (počtu) jednotlivých zariadení systému. V navrhutej metodológii, je výstupom optimalizácie počtu jednotlivých zariadení založenej na genetickom algoritme optimálny počet fotovoltických modulov, veterných generátorov, batérií, nabíjačiek batérií, spolu s optimálnym vertikálnym sklonom fotovoltických modulov a výškou veterných generátorov, predstavujúcich súbor rozhodovacích premenných, pri minimalizácii funkcie celkových nákladov systému v priebehu 20-tich rokov. Funkcia celkových nákladov systému sa pritom skladá z funkcie celkových kapitálových nákladov a funkcie nákladov na údržbu. Minimalizuje sa teda funkcia celkových nákladov zložená zo súčtu kapitálových nákladov na jednotlivé prvky systému a dvadsaťročných nákladov na ich údržbu. Potom, čo všetky kombinácie typov zariadení prejdú optimalizáciou počtu jednotlivých zariadení, vyberie sa kombinácia s najnižšími nákladmi a zodpovedajúca konfigurácia (typ a počet) zariadení systému predstavuje celkovo optimálnu konfiguráciu systému. [5]

Metodológia podľa Yang et al. (2008)

Táto metodológia zahŕňa v optimalizačnom procese niekoľko rozhodovacích premenných a to: N_{pv} - počet fotovoltických modulov, N_{wt} - počet veterných turbín, N_{ba} - počet batérií, β' - uhol sklonu fotovoltických modulov, H_{wt} - výška veterných turbín.

Počiatočná populácia 10 chromozómov, predstavujúca prvú generáciu, je náhodne vygenerovaná pričom obmedzenia (počty fotovoltických panelov, veterných turbín a batérií musia byť väčšie ako 0, výška veterných turbín musí byť v určitom definovanom rozmedzí a uhol sklonu fotovoltických panelov musí byť v rozmedzí 0 – 90.) sa vyhodnocujú pri každom chromozóme. Ak niektorý z chromozómov počiatočnej populácie porušuje



obmedzenie, je nahradený novým chromozómom, ktorý je vygenerovaný náhodne a spĺňa tieto obmedzenia. Výkon fotovoltaických panelov sa vypočíta podľa modelu, ktorý využíva špecifikácie fotovoltaického panelu, vonkajšiu teplotu a podmienky slnečného žiarenia. Pri výpočte výkonu veterných turbín je potrebné brať do úvahy účinky inštalačnej výšky veterných turbín. Batérie s danou celkovou nominálnou kapacitou je možné využívať (vybíjať) až do limitu definovaného hĺbkou vybitia, ktorá je špecifikovaná tvorcom systému na začiatku optimalizácie. Konfigurácia systému sa potom optimalizuje s využitím genetického algoritmu, ktorý dynamicky vyhľadáva optimálnu konfiguráciu, s cieľom minimalizovať priemerné ročné náklady systému. Pre každú konfiguráciu systému sa skúma či pravdepodobnosť výpadku prúdu (PVP) systému je v súlade s cieľovou požiadavkou (danou cieľovou PVP napr. 1%). Potom konfigurácie, ktoré spĺňajú cieľovú požiadavku s nižšími nákladmi, sú predmetom operácií genetického algoritmu (kríženia a mutácie) za účelom vytvorenia ďalšej generácie, a to až kým sa dosiahne vopred stanovený počet generácií alebo konvergenčné kritérium. Takže pre požadovanú (cieľovú) hodnotu PVP, je možné zo súboru konfigurácií identifikovať optimálnu konfiguráciu z hľadiska technického aj ekonomického, ktorá zabezpečí dosiahnutie najnižších na rok prepočítaných nákladov na systém za splnenia požiadavky na PVP. [6]

Táto metodológia využíva nasledovný optimalizačný postup využívajúci genetický algoritmus (upravené z [6]):

1. Počiatočný odhad N_{pv} , N_{wt} , N_{ba} β' , H_{wt}
2. Vyhodnotenie obmedzení u chromozómov a nahradenie tých, ktoré ich nespĺňajú novými
3. Výpočet modelu pre veterné turbíny a modelu pre fotovoltaické panely (tieto modely vychádzajú z modelov pre stanovenie výšky veternej turbíny, resp. modelov solárneho žiarenia, ktoré využívajú štandardné meteorologické dáta za rok)
4. Výpočet modelu pre batérie (vstupom do tohto modelu je „predpokladaný“ profil spotreby energie)
5. Vyhodnocovanie fitness (ohodnocovacej) funkcie (a) PVP menšie alebo rovné ako cieľové PVP, b) minimálne náklady na systém prepočítané na rok
 - a. Ak sú splnené tieto kritériá potom sa konfigurácia (reprezentovaná jedným z chromozómov aktuálnej generácie) zapíše ako priebežne optimálna konfigurácia N_{pv} , N_{wt} , N_{ba} β' , H_{wt} a pokračuje sa krokom 6 (Pozn. Keď sa dosiahne vopred stanovený počet generácií alebo konvergenčné kritérium, tak sa algoritmus zastaví)
 - b. Ak nie sú splnené tieto kritériá potom sa pokračuje krokom 6
6. Operácia výberu: s kritériom minimálnych nákladov na systém prepočítaných na rok
7. Operácie kríženia a mutácie
8. Nová generácia konfigurácie, skok späť na krok 2

Záver

Popísané metodologie a ich aplikácie vo všeobecnosti potvrdzujú vhodnosť aplikovania genetických algoritmov v oblasti optimalizácie počtu, typu, prípadne iných charakteristík zariadení v energetických systémoch, ktoré zahrňujú viac zdrojov energie (konkrétne slnečnú a veternú). Podľa Ismail et al. (2014) má genetický algoritmus vynikajúce vlastnosti, ktoré ho kvalifikujú pre účely optimalizácie, najmä pre hybridné systémy. Je vysoko efektívny pri hľadaní globálneho optima a je veľmi vhodný pre optimalizačné problémy z veľkým počtom



optimalizovaných parametrov. V porovnaní s inými algoritmami sa pomerne ťažšie kóduje a vyžaduje viac výpočtového času na riešenie optimalizačných úloh [4].

Z popisu metodológií je tiež zrejmé, že vždy nejakým spôsobom potrebujú využívať okrem samotného genetického algoritmu aj matematické modely generovania elektrickej (prípadne aj tepelnej) energie podľa zadaných špecifických podmienok (napr. geografickej polohy). V prípade, že potrebujeme do optimalizácie zapojiť ďalší typ zdroja potrebujeme mať generovanie elektrickej energie z tohto zdroja matematicky popísané. Takéto modely sú už dnes zväčša dostupné v rôznych vedeckých článkoch, napríklad v prípade zapojenia biomasy a zariadenia pracujúceho na báze Organického Rankinového cyklu (viď [7]) alebo v prípade zapojenia geotermálnej energie a zariadenia pracujúceho na báze Organického Rankinového cyklu (viď [8]). Rozšírenie a prispôbenie popísaných metodológií práve o tieto ďalšie alternatívne zdroje vidíme ako výskumnú výzvu do budúcnosti.

PodĎakovanie

Tento príspevok bol podporený výskumným grantom KEGA: 079TUKE-4/2013 (Inovácia laboratórnych výučbových technológií v študijnom programe Priemyselné inžinierstvo) a projektom „Zlepšenie efektívnosti využitia obnoviteľných zdrojov energie“, kód ITMS: 26220220174, spolufinancovaným zo zdrojov Európskeho fondu regionálneho rozvoja.

Použitá literatúra

- [1] MITCHELL, M. An Introduction to Genetic Algorithms, Cambridge, MIT Press, 1996.
- [2] Wikipedia, „Genetic Algorithm,“ 2015. [Online]. Available: https://en.wikipedia.org/wiki/Genetic_algorithm. [Cit. 2015].
- [3] KUMAR, A. „Encoding Schemes in Genetic Algorithm,“ International Journal of Advanced Research in IT and Engineering, zv. 2, %1. vyd.3, 2013.
- [4] ISMAIL, M., MOGHAVVEMI M. a MAHLIA, T. „Genetic algorithm based optimization on modeling and design of hybrid renewable energy systems,“ Energy Conversion and Management, zv. 85, pp. 120-130, 2014.
- [5] KOUTROULIS, E., KOLOKOTSA, D., POTIRAKIS, A. a KALAITZAKIS, K. „Methodology for optimal sizing of stand-alone photovoltaic/wind-generator systems using genetic algorithms,“ Solar Energy 80, zv. 2006, %1. vyd.80, p. 1072–1088, 2006.
- [6] YANG, H., ZHOU, W., LU, L. a FANG, Z. „Optimal sizing method for stand-alone hybrid solar–wind system with LPSP technology by using genetic algorithm,“ Solar Energy , zv. 2008, %1. vyd.82, p. 354–367, 2008.
- [7] ALGIERI, A. a MORRONE, P. „Energetic analysis of biomass-fired ORC systems for micro-scale,“ Applied Thermal Engineering , zv. 2014, %1. vyd.71 , pp. 751-759, 2014.
- [8] BÖSZÖRMÉNYI, L. a BUJANSKÁ, A. „Hybridná tepelná elektrárňa ako konkurencieschopná alternatívna technológia využívania geotermálnej energie na výrobu elektriny,“ 2013. [Online]. Available: <http://www.tzbportal.sk/kurenje-voda-plyn/hybridna-tepelna-elektraren-ako-konkurencieschopna-alternativna-technologia>. [Cit. 2015].

Kontakt

doc. Ing. Juraj Šebo, PhD.

Technická univerzita v Košiciach, Strojnícka fakulta, Katedra priemyselného inžinierstva a manažmentu, Nemcovej 32, 040 01 Košice, Slovensko

e-mail: juraj.sebo@tuke.sk