

DEFINIÇÃO DE ALGORITMOS EVOLUTIVOS PARA O PROCESSO DE AVALIAÇÃO EM SIMULAÇÕES TERMOENERGÉTICAS DE EDIFÍCIOS

RODRIGO KARINI LEITZKE¹; EDUARDO GRALA DA CUNHA²

¹Universidade Federal de Pelotas – rodrigokarinileitzke@gmail.com

²Universidade Federal de Pelotas – eduardogralacunha@yahoo.com.br

1. INTRODUÇÃO

A necessidade de ampliação dos cenários de simulação computacional termoenergética de edifícios promoveu um importante debate na área do conhecimento nas últimas duas décadas. Para o *EnergyPlus*, software amplamente utilizado com esta finalidade, desenvolvido e mantido pelo departamento de energia dos Estados Unidos (CRAWLEY, 2000), soluções como o *JEPlus* (ZHANG; KOROLIJA, 2010) e a biblioteca em python *Eppy* (PHILIP; TRAN; TANJUATCO, 2019), permitiram com que os elementos da simulação fossem ajustados de forma automatizada a partir de *scripts* desenvolvidos com o uso destas tecnologias.

Contudo, embora as novas estratégias e tecnologias de otimização e parametrização tenham permitido com que as avaliações ampliassem a complexidade dos experimentos propostos pelos pesquisadores e projetistas, o processo de avaliação dos resultados obtidos assumiu um novo grau de complexidade, à medida que amplos conjuntos de dados passaram a ser obtidos a partir destas avaliações.

Tornou-se necessário, portanto, considerar o uso de estratégias numéricas, estatísticas ou de inteligência artificial (IA) como ferramentas capazes de auxiliar no processo de seleção e avaliação dos resultados.

Quanto ao uso da inteligência artificial, trabalhos como Yu et al. (2015), Figueiredo et al. (2016) e Bre e Fachinotti (2017), destacam o uso de algoritmos evolutivos multiobjetivo como uma das possibilidades de avaliação dos modelos. Estes algoritmos permitem com que os indivíduos (modelos de simulação) sejam analisados a partir dos seus genes (elementos configurados no modelo) com o passar das gerações (ciclos de execução dos conjuntos de simulação), assim como ocorre na evolução biológica.

Os algoritmos NSGA-II (DEB et al., 2002) e SPEA2 (ZITZLER; LAUMANN; THIELE, 2001), apresentam-se como as principais soluções evolutivas multiobjetiva, tendo sido utilizadas em mais de 35 mil produções científicas catalogadas nas bases de dados acadêmicos.

Este trabalho faz parte da pesquisa de mestrado intitulada “Algoritmos evolutivos com otimização multiobjetivo para a escolha de PCM's em fechamento *Light Steel Frame* no Brasil” do Programa de Pós-Graduação em Arquitetura e Urbanismo da UFPEL (PROGRAU), tendo por objetivo apresentar as duas soluções evolutivas em destaque na literatura (apresentadas acima) em contraste com duas novas soluções evolutivas com propósito de rápida convergência para simulação térmica e energética de edifícios.

2. METODOLOGIA

O método do trabalho pode ser compreendido em três etapas, sendo a primeira referente a apresentação dos quatro algoritmos evolutivos mencionados

na introdução, a segunda etapa referente à discussão das estratégias evolutivas apresentadas e, por fim, na terceira etapa, a contextualização quanto ao uso destes algoritmos nas avaliações térmicas e energéticas de edifícios.

Quanto aos algoritmos NSGA-II e SPEA2, observa-se uma diferença nas estratégias evolutivas.

O NSGA-II (DEB et al., 2002) se utiliza do conceito de Dominância para avaliar cada indivíduo da sua população, de modo que, sendo p e q dois indivíduos da população P , p domina q se p for melhor do que q em pelo menos um dos seus objetivos, sendo também o restante dos objetivos de p não piores do que os de q . Essa estratégia permite que o algoritmo faça uma classificação dos indivíduos mais aptos e determine a distância de cada um deles do ponto ótimo (os autores sugerem que o centro da curva de pareto seja utilizado como ponto ótimo). Assim, quanto maior o número de indivíduos dominados por p e menor a sua distância para o ponto ótimo, melhor será a sua classificação.

Já o SPEA2 (ZITZLER; LAUMANN; THIELE, 2001) utiliza duas populações durante a sua execução, uma denominada população evolutiva (P) e outra denominada população externa (Q), denota-se P_x e Q_x as populações P e Q na geração x . Na inicialização, as populações são criadas, Q é povoada com a população inicial gerada aleatoriamente, P em um primeiro momento fica vazia. Realizada a primeira iteração, as soluções não dominadas, ou seja, ineficientes para análise pretendida, são armazenadas em P , já o recorte de interesse é armazenado em Q_{x+1} . Caso o número de soluções seja maior do que uma das populações, um corte é realizado para reduzir o número de soluções. A ideia principal do algoritmo é que o processo de evolução demonstre uma convergência rápida em Q , sem desconsiderar potenciais bons resultados em P . Desta forma, passadas algumas gerações, valores de P são combinados com os bons resultados de Q e caso apresentem resultados interessantes, integram o conjunto da população Q . Essa estratégia garante uma reavaliação dos dados não dominados em um primeiro momento do algoritmo, dificultando o descarte de potenciais bons indivíduos.

NSGA-II e SPEA2 utilizam a curva de pareto ótimo para estabelecer a região com os melhores resultados, tanto na maximização quanto na minimização das funções-objetivo.

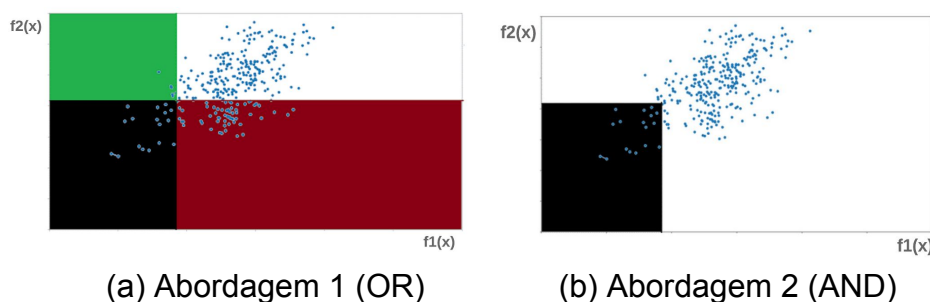
Além dos dois algoritmos apresentados, duas abordagens foram elaboradas para avaliação dos modelos de simulação: abordagem 1 (OR) e abordagem 2 (AND), trata-se de dois métodos evolutivos multiobjetivo elitistas, que utilizam a distribuição normal para avaliar o comportamento de cada variável a partir de um recorte dos seus indivíduos.

Pensando na representação visual de um método evolutivo multiobjetivo com duas funções-objetivo, cada uma delas pode ser representada em um eixo cartesiano. Na abordagem 1, são selecionados os indivíduos que apresentem os 25% melhores resultados no eixo X ou no eixo Y do plano cartesiano de representação, ou seja, mesmo que um determinado indivíduo apresente funções-objetivo não satisfatórias para fazer parte do grupo de selecionados no objetivo do eixo X, este ainda pode ser considerado um indivíduo apto se apresentar resultados da sua função-objetivo do eixo Y dentro do grupo de seleção. Os pontos positivos desta abordagem estão associados ao não descarte de potenciais bons resultados por serem pouco representativos em um dos seus objetivos (assim como o SPEA2) e também pela maior exploração do conjunto amostral.

Já na abordagem 2, são selecionados 25% dos indivíduos da geração que apresentaram os melhores resultados em ambos os objetivos, ou seja, serão

selecionados apenas 1/4 dos indivíduos que correspondem aqueles que apresentaram os menores ou maiores valores conforme a necessidade das funções-objetivo (minimização ou maximização). A busca pelo elitismo é uma das características principais desta abordagem, nela apenas os melhores indivíduos são selecionados. Esta situação influencia diretamente na convergência dos resultados através das gerações, visto que em poucas iterações é possível convergir para regiões com resultados satisfatórios. Entretanto, o potencial exploratório de cada uma das funções-objetivo não é considerado na Abordagem 2. Este cenário permite o descarte de potenciais bons indivíduos caso estes não façam parte do grupo de aptos nas primeiras gerações.

Figura 1 - Áreas de seleção das abordagens 1 (a) e 2 (b)



Através da Figura 1, verifica-se o padrão de seleção das abordagens 1 (a) e 2 (b), sendo ambas focadas na redução das duas funções-objetivo ($f1(x)$ e $f2(x)$) estipuladas.

3. RESULTADOS E DISCUSSÃO

Os quatro algoritmos apresentados abordam diferentes estratégias de seleção e avaliação dos indivíduos aptos nas análises evolutivas. Iniciando pelos algoritmos NSGA-II e SPEA2, o foco na curva de pareto-ótimo como principal critério evolutivo amplia as regiões de análise dos algoritmos dentro do conjunto de dados, já que o formato da curva contribui para a identificação de diferentes frentes de pareto ao longo da execução, o que permite com que indivíduos predominantemente aptos em uma das funções-objetivo (extremidades da curva), tenham seus dados perpetuados durante as gerações.

Os algoritmos das abordagens 1 e 2, por sua vez, apresentam um propósito de rápida convergência, em detrimento da exploração do conjunto populacional, já que a distribuição normal aplicada entre as variáveis consideradas nos dois algoritmos garante a predominância das soluções próximas ao sino da distribuição normal (região de maior ocorrência entre as melhores saídas).

Quando considerado o contexto particular das simulações computacionais na avaliação destes algoritmos, pontos como o custo computacional em tempo de simulação dos casos, bem como a qualidade em termos de distribuição das saídas obtidas, precisam ser destacados como elementos de decisão quanto à escolha dos algoritmos que serão propagados e/ou preteridos na sequência dos experimentos.

4. CONCLUSÕES

O presente trabalho apresenta quatro possibilidades evolutivas como estratégias de composição para as análises realizadas por meio de simulação computacional termoenergética.

A oferta das quatro estratégias evolutivas apresentadas podem contribuir de formas distintas em aplicações que envolvam o uso da simulação, sendo necessário avaliar os prós e contras de cada estratégia, bem como os custos de simulação e de processamento para definir o algoritmo ideal em cada situação.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

5. REFERÊNCIAS BIBLIOGRÁFICAS

BRE, F.; FACHINOTTI, V. D. A computational multi-objective optimization method to improve energy efficiency and thermal comfort in dwellings. **Energy and Buildings**, [S.l.], v.154, p.283–294, 2017.

CRAWLEY, D. B.; LAWRIE, L. K.; PEDERSEN, C. O.; WINKELMANN, F. C. Energyplus: energy simulation program. **ASHRAE journal**, [S.l.], v.42, n.4, p. 49–56, 2000.

DEB, K. **Multi-objective optimization using evolutionary algorithms**. [S.l.]: John Wiley & Sons, 2001. v.16.

FIGUEIREDO, A.; KÄMPF, J.; VICENTE, R. Passive house optimization for Portugal: Overheating evaluation and energy performance. **Energy and Buildings**, [S.l.], v.118 ,p.181–196, 2016.

PHILIP, S.; TRAN, T.; TANJUATCO, L. **Eppy: scripting language for E+**. Acessado em 25 de fev. de 2020. Online. Disponível em: <https://github.com/santoshphilip/eppy>.

YU, W. et al. Application of multi-objective genetic algorithm to optimize energy efficiency and thermal comfort in building design. **Energy and Buildings**, [S.l.], v.88, p. 135–143, 2015.

ZHANG, Y.; KOROLIJA, I. Performing complex parametric simulations with jEPlus. In: SET2010-9TH INTERNATIONAL CONFERENCE ON SUSTAINABLE ENERGY TECHNOLOGIES, 2010. **Anais**. [S.l.: s.n.], 2010. p.24–27.

ZITZLER, E.; LAUMANN, M.; THIELE, L. SPEA2: Improving the strength Pareto evolutionary algorithm. **TIK-report**, [S.l.], v.103, 2001.