

## ANÁLISE DE CONSISTÊNCIA DE FERRAMENTAS DE ISBSE

Fernando Henrique Kuviatkovski (PIBIC/CNPq/Uem), Aline Maria Malachini Miotto Amaral (orientadora), Willian Marques Freire (coorientador), ra100285@uem.br.

Universidade Estadual de Maringá / Centro de Tecnologia / Maringá, PR.

### Ciência da Computação / Engenharia de Software

**Palavras-chave:** Linha de Produto de Software, Otimização Interativa, Aprendizagem de Máquina.

### RESUMO

O Problema da Próxima Release (NRP) é fundamental no desenvolvimento de software, consistindo na seleção de requisitos a serem incluídos na próxima versão do sistema. A Engenharia de Software Baseada em Busca (SBSE) tem sido amplamente aplicada para resolver problemas complexos na Engenharia de Software (ES) usando técnicas de otimização. Entretanto, alguns aspectos desejáveis em uma solução nem sempre são modelados adequadamente em uma função matemática a ser otimizada, tornando necessária a inclusão da avaliação subjetiva das soluções. Este trabalho investiga a aplicação de abordagens interativas baseadas em Algoritmos Genéticos Interativos (IGA) para a resolução do NRP, considerando diversos modos de incorporação de preferências e a verificação entre as preferências do Tomador de Decisão (DM) e as soluções obtidas. O método utilizado envolveu a análise de abordagens que implementam técnicas de otimização interativa no contexto do NRP e a replicação dos experimentos associados. O objetivo principal deste estudo é analisar e reproduzir diferentes abordagens propostas na literatura para o NRP, visando verificar os mecanismos de incorporação das preferências do DM. Para atingir esse objetivo, o trabalho replicou os experimentos e analisou os resultados, que demonstraram que as resoluções abordadas conseguiram efetivamente incorporar a preferência do DM no processo de otimização, produzindo soluções que condizem com a opinião subjetiva humana ao custo de pouca perda de qualidade em aspectos matemáticos da solução. Os resultados obtidos também indicam que a abordagem interativa é capaz de aumentar a satisfação geral do DM em relação às soluções otimizadas.

### INTRODUÇÃO

A Engenharia de Software Baseada em Busca (SBSE) é um campo crucial na resolução de desafios complexos na Engenharia de Software (ES) por meio da aplicação de técnicas de otimização. Um conceito fundamental desse campo é a interação com o Tomador de Decisão (DM), que pode ocorrer em três fases distintas: antes (*a priori*), durante e após (*a posteriori*) o processo de otimização.

Dentro do contexto da SBSE, surgem abordagens interativas, conhecidas como iSBSE, que são aplicadas a diversos problemas em Engenharia de Software, como Requisitos de Software, Arquitetura de Software, Testes de Software, Projeto de Arquitetura em Linha de Produto de Software e o Problema da Próxima Release (NRP). O NRP é um problema de otimização que consiste em selecionar um conjunto de funcionalidades ou requisitos a serem implementados na próxima versão de um *software*, considerando restrições e metas específicas. O objetivo é escolher um subconjunto de funcionalidades que otimize uma ou mais funções objetivas, como a satisfação do cliente, lucratividade ou tempo de desenvolvimento.

## MATERIAIS E MÉTODOS

O trabalho trata da reprodução dos experimentos realizados por Araújo (2014) e Dantas *et al.* (2015) no contexto da otimização interativa para o NPR. Dessa forma, essa seção é dividida em duas partes, referentes às abordagens de cada autor. O objetivo geral é verificar se a incorporação das preferências do DM durante o processo de otimização é efetivamente realizada. A reprodução utiliza as ferramentas desenvolvidas em cada estudo, enquanto a avaliação dos resultados é feita através da análise de conjuntos de métricas diferentes e específicos para cada abordagem.

### *Experimento 01 - Arquitetura de IGA com Aprendizagem de Máquina para o NRP*

Neste experimento, a abordagem proposta por Araújo (2014) é reproduzida, visando a otimização interativa do NPR. A representação do problema é realizada através da definição do número de clientes, o número de requisitos, as medidas de importância de cada cliente para a empresa de desenvolvimento e os custos de desenvolvimento de cada requisito. Além disso, também se define a importância que cada cliente atribui a cada requisito.

A interação com o DM é simulada a fim da execução de testes exaustivos. Assim, seleciona-se aleatoriamente um subconjunto de requisitos e os considera como preferências do DM. Durante a avaliação de soluções, é verificada a quantidade de requisitos que coincidem entre a seleção e os requisitos presentes na solução, atribuindo uma nota proporcional. A configuração do Algoritmo Genético Interativo (IGA) é feita com base em parâmetros pré-definidos, como tamanho da população, número de gerações, mecanismo de seleção, taxa de cruzamento e mutação, entre outros. Além disso, o orçamento disponível para a *release* é especificado, influenciando a alocação dos requisitos.

Três métricas de avaliação são propostas para analisar a incorporação das preferências do DM no processo de otimização: Grau de Similaridade (GS), Fator de Similaridade (FS) e Preço da Preferência (PP). Somente a métrica GS, que mede a similaridade entre a solução e as preferências do DM será discutida neste documento.

### *Experimento 02 - Planejamento de Release Interativo com Base em Preferências*

A abordagem proposta por Dantas *et al.* (2015) foca no planejamento de release interativo com base em preferências. A representação do NRP envolve informações como os riscos de desenvolvimento associados a cada requisito, o número de *releases* a serem planejadas, seus respectivos orçamentos e outras informações.

A interação com o DM é simulada por meio da geração automática de preferências. A ferramenta permite que o DM insira suas preferências de acordo com diferentes tipos, facilitando a interação e a análise dos resultados. Cinco métricas são adotadas para avaliar a qualidade das soluções otimizadas: Preferências Satisfeitas (PS), Nível de Satisfação (NS), Ganho em Preferências (GP), Preço das Preferências (PP) e Densidade de Preferências (DP). Somente a métrica PS, que avalia a proporção de preferências satisfeitas na solução será discutida neste documento.

## RESULTADOS E DISCUSSÃO

Em relação ao Experimento 01, serão apresentados somente os resultados referentes à métrica GS e o número de interações do DM com o processo de otimização com entradas de diferentes tamanhos (número de requisitos): 50, 100, 150 e 200 requisitos. A partir da Figura 01, é possível observar que a qualidade das soluções otimizadas tende a diminuir à medida que o número de requisitos aumenta, mantendo o número de interações com DM constante. No entanto, ao manter o número de requisitos constante e aumentar as interações com o DM, a qualidade das soluções tende a melhorar. Esse resultado é esperado, pois incorporar as preferências do DM em soluções maiores é desafiador. Além disso, o comportamento crescente de GS ao aumentar o número de interações valida que as preferências do DM estão devidamente sendo incorporadas pelo processo de otimização.

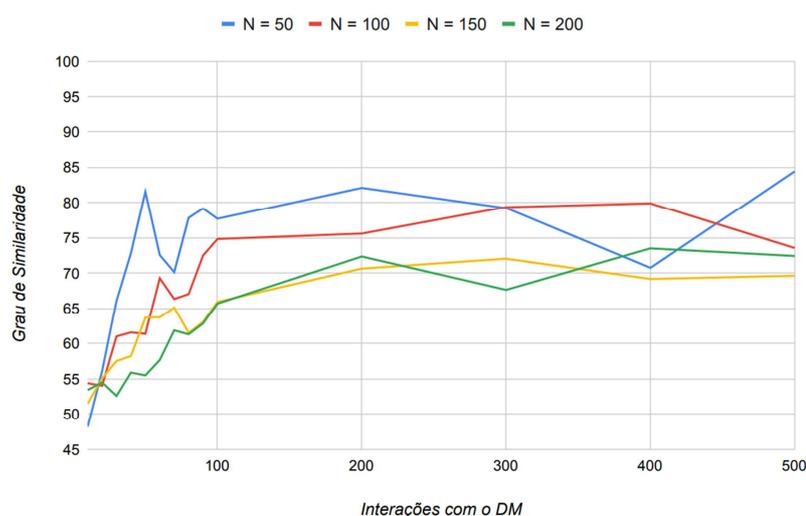


Figura 1 – Relação entre Grau de Similaridade (GS) e número de interações com o DM.

Para o Experimento 02, apresenta-se a métrica PS, de papel semelhante à métrica GS do experimento anterior. São utilizados quatro problemas de diferentes tamanhos na entrada (50, 25, 100 e 150 requisitos). O coeficiente  $\mu$  atua como um fator de escala sobre a avaliação do DM à uma solução. De forma semelhante ao experimento anterior, percebe-se que com o aumento de  $\mu$  a métrica OS tende a aumentar, significando que as preferências do DM estão sendo incorporadas no processo de otimização.

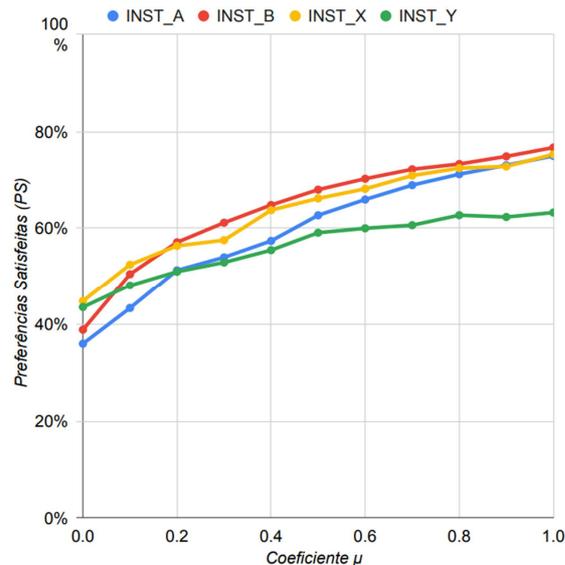


Figura 2 – Relação entre Preferências Satisfeitas (PS) e o coeficiente  $\mu$ .

## CONCLUSÕES

A partir dos resultados apresentados, pode-se afirmar que os objetivos do trabalho foram atingidos com sucesso, visto que os experimentos propostos foram reproduzidos e que a incorporação das preferências do DM nos processos de otimização foi verificada através das métricas propostas pelos diferentes autores.

## AGRADECIMENTOS

Gostaríamos de agradecer ao CNPq pelo apoio financeiro para o desenvolvimento dessa pesquisa.

## REFERÊNCIAS

- ARAÚJO, A. A. **Machine learning for user modeling in an interactive genetic algorithm for the next release problem**. Search-Based Software Engineering, p. 228–233, 2014.
- DANTAS A.; YELTSIN I.; ARAÚJO A. A.; SOUZA J. **Interactive software release planning with preferences base**. Search-Based Software Engineering, p. 341–346, 2015.