

Avaliação qualitativa dos algoritmos TOPSIS, WSM e GRA aplicado no Contexto de Internet das Coisas

Adriller Gênova Ferreira¹, Luiz Henrique Nunes^{1,2}, Julio César Estrella¹

¹Instituto de Ciências Matemáticas e Computação – Universidade de São Paulo (USP)
São Carlos – SP – Brasil

²Instituto Federal de São Paulo (IFSP)
Araraquara – SP – Brasil

adriller.ferreira@usp.br, lhnunes@icmc.usp.br, jcezar@icmc.usp.br

Abstract. *Currently, the number of devices connected to the Internet has increased exponentially creating the Internet of Things (IoT). Thus, there will be many sensors available on Internet that can be used indirectly to provide data as a service for specific applications. In this context, multicriteria decision analysis (MCDA) techniques can support the sensor selection process for such applications, which are context sensitive. The objective of this work is to analyze the quality of selection provided by the algorithms that use MCDA techniques such as TOPSIS, WSM and GRA in IoT context. The results show that the number of context properties used and the number of sensors selected directly influence the selection quality of the MCDA algorithms.*

Resumo. *Atualmente, o número de dispositivos conectados a Internet tem aumentado exponencialmente contribuindo para a criação da Internet das Coisas (IoT). Como consequência, haverá muitos sensores disponíveis que podem ser utilizados de maneira indireta, provendo dados em forma de serviço para aplicações específicas. Dessa maneira, técnicas de análise de decisão multicritérios (MCDA) podem auxiliar o processo de seleção de sensores para tais aplicações, que são sensíveis ao contexto. O objetivo deste trabalho é analisar a qualidade de seleção fornecida pelos algoritmos que utilizam a abordagem MCDA como o TOPSIS, WSM e GRA no contexto de IoT. Os resultados obtidos mostram que o número de propriedades de contexto utilizadas e o número de sensores escolhidos influenciam diretamente a qualidade de seleção dos algoritmos MCDA.*

1. Introdução

Dia após dia, o número de sensores que auxiliam a vida das pessoas vêm aumentando, sendo encontrados em dispositivos eletrônicos, carros, aparelhos domésticos, roupas, entre outros objetos que atendem as mais diversas necessidades, dando face a Internet das Coisas (IoT). As funcionalidades desses dispositivos geralmente têm um propósito único, limitando as informações geradas somente ao próprio aparelho, muitas vezes por questões de segurança. Porém, com a tendência cada vez maior de compartilhamento de dados, os dispositivos tendem a trocar informações entre si, contribuindo para o surgimento de novas aplicações. Entretanto, ainda é um desafio escolher quais sensores fornecerão os dados para obtenção de informações adequadas para uma aplicação. Dessa maneira, é

esperado que os serviços oferecidos neste ambiente sejam sensíveis ao contexto e considerem as preferências e as necessidades dos usuários, definidas como propriedades de contexto. O objetivo deste trabalho é verificar a utilização de algoritmos de Análise de Decisão Multicritérios (MCDA) descritos na literatura, mais especificamente os algoritmos *Technique for the Order of Prioritisation by Similarity to Ideal Solution* (TOPSIS), *Weighted Sum Model* (WSM) e *Gray Relational Analysis* (GRA) para auxiliar a seleção de sensores no contexto IoT, bem como avaliar a qualidade das soluções oferecidas por eles.

2. Algoritmos de Análise de Decisão Multicritérios (MCDA)

Os algoritmos MCDA visam auxiliar o julgamento da tomada de decisão por meio de um conjunto de objetivos e critérios, estimando sua importância e estabelecendo a contribuição de cada opção de acordo com cada critério analisado [Dodgson et al. 2009] O algoritmo TOPSIS explora os valores dos critérios para fornecer um conjunto ordenado de alternativas de acordo com a distância Euclidiana para a solução ideal e ideal-negativa. A solução ideal corresponde ao melhor valor possível de cada critério, enquanto a solução ideal-negativa representa o pior valor de cada critério [Tzeng and Huang 2011, Nunes et al. 2016b]. O WSM consiste em encontrar uma pontuação para cada alternativa somando-se o valor de cada alternativa multiplicada pelo peso do critério [Triantaphyllou 2000]. Entretanto, essa técnica não usa normalização, sendo assim, podendo somar valores discrepantes. Com o GRA podemos abstrair algumas informações visto que ele é muito utilizado quando não temos muitas informações sobre as alternativas disponíveis. Graças a essa abstração, conseguimos gerar resultados diferentes, porém ainda satisfatórios que serão adequados para uma comparação de soluções [Razi 2014].

3. Proposta para Avaliação dos Métodos

Nossa proposta de avaliação se baseia em um conjunto de dados que será ranqueado de acordo com os algoritmos descritos e com as propriedades de contexto. A metodologia utilizada para a realização dos experimentos é descrita em [Nunes et al. 2016c, Nunes et al. 2016a]. A métrica ONVGR (*Overall Non-Dominated Vector Generation Ratio*) [Collette and Siarry 2013] é utilizada para a avaliação dos resultados, mostrando o número de soluções ótimas na fronteira de Pareto como uma proporção do número de soluções propostas pelos métodos MCDA em cada fronteira. Quanto mais próximo o valor ONVGR é de um, melhor é a solução proposta dessa fronteira. Uma solução é dita ótima de Pareto quando é melhor do que as outras, sendo o seu cálculo feito com base no aspecto de dominância. Por exemplo, dado duas soluções x e y , x domina y se I) x é melhor que y em pelo menos um critério; II) x é pelo menos tão boa quanto y nos demais critérios. As soluções dominadas apenas pela fronteira ótima de Pareto estão localizadas na segunda fronteira de Pareto, e assim por diante. Quatro fatores são considerados para a realização do experimento: I) o número de sensores disponíveis na base de dados (209.555 sensores) II) o algoritmo MCDA (TOPSIS, WSM e GRA), III) o número de sensores selecionados (209 e 2095, que correspondem respectivamente a 1% e 10% dos sensores disponíveis), e IV) o número de propriedades de contexto (2 e 6). Os dados dos sensores foram retirados da API OpenWeatherMap¹ e as propriedades de contexto e objetivos utilizados foram: (1) maximizar a temperatura, (2) maximizar a umidade, (3) maximizar a concentração de

¹<http://openweathermap.org/>

nuvens, (4) minimizar o vento, (5) minimizar a precipitação e (6) maximizar a data de coleta dos dados. O ambiente de testes é composto por uma máquina física com processador AMD Vishera 4.2Ghz, memória de 32GB RAM DDR3 Corsair Vegeance, disco rígido de 2TB Seagate Sata III 7200RPM, sistema operacional Linux Ubuntu Server 14.04 64 Bits LTS configurado com o java JDK 1.7 e banco de dados MongoDB 3.0. Os experimentos foram replicados cem vezes, em que para cada replicação as prioridades das propriedades de contexto foram alteradas.

4. Resultados

A Figura 1 representa o comportamento da seleção de 1% (Figura 1.a) e 10% (Figura 1.b) dos sensores, considerando duas propriedades de contexto (temperatura e umidade). As primeiras fronteiras apresentam um valor do ONVGR alto, significando que os algoritmos conseguiram encontrar um maior número de soluções nessas fronteiras, chegando a alcançar a razão de um (melhor caso). À medida que o número de sensores é aumentado, o valor de ONVGR mantém-se alto nas primeiras fronteiras e aumenta nas fronteiras intermediárias e finais, bem como o número de fronteiras necessárias para propor a solução. Isso ocorre pois mais sensores são selecionados e há poucos sensores disponíveis em cada fronteira devido ao baixo número de critérios conflitantes. É válido destacar que estatisticamente os algoritmos analisados são equivalentes. Além disso, o comportamento médio do algoritmo WSM difere-se dos outros algoritmos em algumas fronteiras, uma vez que nenhuma normalização entre as propriedades de contexto são realizadas neste algoritmo, possibilitando assim comparações entre dados com valores discrepantes.

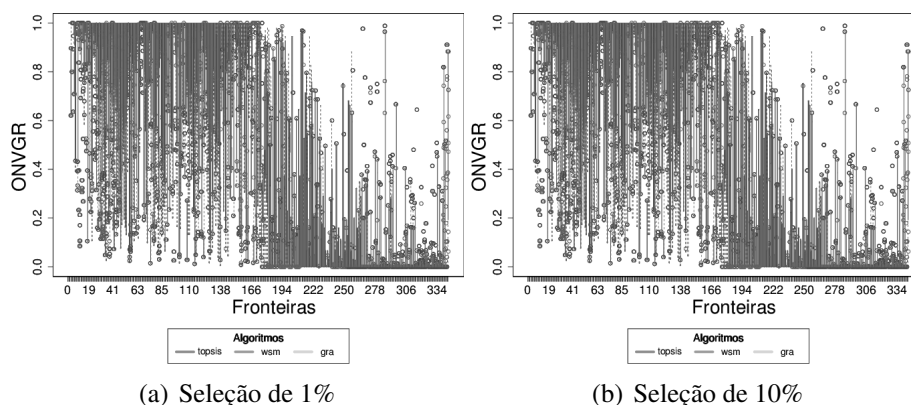


Figura 1. ONVGR para duas propriedades de contexto

A Figura 2 representa o comportamento da seleção de 1% (Figura 2.a) e 10% (Figura 2.b) dos sensores considerando seis propriedades de contexto (temperatura, humidade, concentração de nuvens, vento, precipitação e data). É possível observar que o aumento das propriedades de contexto influenciou a qualidade da solução oferecida, já que há mais conflitos entre as propriedades de contexto analisadas e consequentemente o aumento no número de soluções de cada fronteira. Apesar de observar um valor próximo do ONVGR nas primeiras fronteiras, na média o algoritmo GRA propõe soluções com qualidade superior ao algoritmo TOPSIS quando mais sensores são selecionados. O WSM foi inferior, conforme o esperado já que além de ter que trabalhar com critérios conflitantes, também não faz sua normalização.

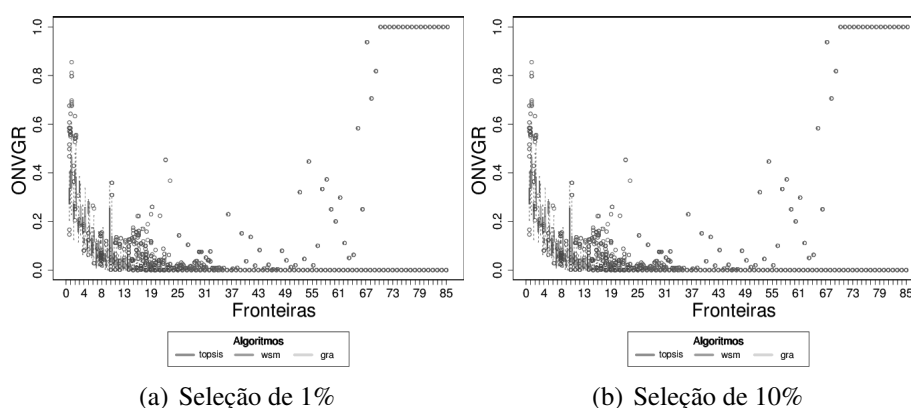


Figura 2. ONVGR para seis propriedades de contexto

5. Conclusão

No ambiente de Internet das Coisas é esperado que os serviços oferecidos sejam sensíveis ao contexto e considerem as especificações de cada usuário. Os resultados apresentados neste artigo, verificou que o número de propriedades do contexto influenciam diretamente o número de soluções ótimas obtidas por cada algoritmo MCDA, uma vez que o número de conflitos entre as propriedades de contexto aumenta e consequentemente o número de soluções não dominadas disponíveis em cada fronteira. Com relação aos algoritmos, foi possível observar que os algoritmos TOPSIS e GRA apresentam na média uma qualidade de seleção superior ao algoritmo WSM, por normalizarem os valores das propriedades de contexto utilizadas. Em trabalhos futuros serão realizados estudos considerando a escalabilidade desses algoritmos e outras métricas para a análise da qualidade das soluções.

Agradecimentos

Agradecemos à FAPESP (Processo: 2015/25793-9) pelo apoio financeiro e ao LaSDPC pela infraestrutura oferecida durante o desenvolvimento do projeto.

Referências

- Collette, Y. and Siarry, P. (2013). *Multiobjective optimization: principles and case studies*. Springer Science & Business Media.
- Dodgson, J., Spackman, M., Pearman, A., and Phillips, L. (2009). *Multi-criteria analysis: a manual*.
- Nunes, L. H., Estrella, J. C., Delbem, A. C. B., Perera, C., and Reiff-Marganiec, S. (2016a). The effects of relative importance of user constraints in cloud of things resource discovery: A case study. In *Proceedings of the 9th International Conference on Utility and Cloud Computing*.
- Nunes, L. H., Estrella, J. C., Nakamura, L. H. V., Libardi, R. M. D. O., Ferreira, C. H. G., Jorge, L., Perera, C., and Reiff-Marganiec, S. (2016b). A distributed sensor data search platform for internet of things environments. *International Journal of Services Computing (IJSC)*, 4(1):1–12.
- Nunes, L. H., Estrella, J. C., Perera, C., Reiff-Marganiec, S., and Delbem, A. N. (2016c). Multi-criteria iot resource discovery: A comparative analysis. *Software: Practice and Experience*, -(–):–. *In print*.
- Razi, F. F. (2014). A hybrid grey relational analysis and nondominated sorting genetic algorithm-ii for project portfolio selection. *Advances in Operations Research*, 2014.
- Triantaphyllou, E. (2000). *Multi-criteria Decision Making Methods: A Comparative Study*. Springer US, Boston, MA.
- Tzeng, G. and Huang, J. (2011). *Multiple Attribute Decision Making: Methods and Applications*. A Chapman & Hall book. Taylor & Francis.