

## AVALIAÇÃO DO EMPREGO DE ALGORITMOS MCDA E ÁRVORES DE DECISÃO NO RANQUEAMENTO DE RECURSOS IOT

FELIPE CAMARGO GRUENDEMANN<sup>1</sup>; JUAN BURTET<sup>2</sup>; RENATO DILLI<sup>3</sup>;  
ADENAUER CORRÊA YAMIN<sup>4</sup>

<sup>1</sup>*Universidade Federal de Pelotas – [fcgruendemann@inf.ufpel.edu.br](mailto:fcgruendemann@inf.ufpel.edu.br)*

<sup>2</sup> *Universidade Federal de Pelotas – [jburtet@inf.ufpel.edu.br](mailto:jburtet@inf.ufpel.edu.br)*

<sup>3</sup> *Universidade Federal de Pelotas – [renato.dilli@inf.ufpel.edu.br](mailto:renato.dilli@inf.ufpel.edu.br)*

<sup>4</sup> *Universidade Federal de Pelotas – [adenauer@inf.ufpel.edu.br](mailto:adenauer@inf.ufpel.edu.br)*

### 1. INTRODUÇÃO

A Internet das Coisas (*IoT – Internet of Things*) é caracterizada por ser um ambiente heterogêneo composto por uma grande quantidade de objetos que se conectam de maneira transitória e disponibilizam uma grande quantidade de serviços (PERERA, 2017). Estima-se que até 2025 se atinja o número de 100 bilhões de objetos conectados (BIS, 2017). Essas características evidenciam a importância de estudos e pesquisas para auxiliar com os mecanismos de seleção de recursos visando prover uma alta escalabilidade em ambientes de constituição dinâmica e heterogênea (BASTOS, 2014).

Para realizar a seleção do melhor recurso nesta infraestrutura provida pela Internet, o processo de descoberta e ranqueamento de recursos precisa analisar tanto os requisitos funcionais, quanto os não-funcionais. Assim, após a devida identificação e localização dos recursos, é necessário classificá-los em ordem de Qualidade de Serviço (QoS).

A Análise de Decisão de Múltiplos Critérios (MCDA - *Multiple Criteria Decision Analysis*) refere-se à tomada de decisões na presença de critérios múltiplos, geralmente conflitantes. Os algoritmos MCDA visam auxiliar no julgamento da tomada de decisão utilizando um conjunto de objetivos e critérios, estimando seus pesos de importância relativa e estabelecendo a contribuição de cada opção em relação a cada critério de desempenho. MCDA é uma perspectiva específica para lidar com problemas de tomada de decisão (Figueira et al. 2005).

Por sua vez, a aprendizagem de máquina tem como objetivo entender a lógica dos programas para aprimorar o desempenho das máquinas em determinadas tarefas, através de experiência previa (Suchithra e Ramakrishnan 2015).

Considerando todos esses fatores, tomou-se como objetivo central deste trabalho explorar alternativas para contribuir com a arquitetura de software do mecanismo de descoberta de recursos do middleware EXEHDA, em desenvolvimento no grupo de pesquisa utilizando abordagens MCDA e de Árvores de Decisão.

### 2. METODOLOGIA

Primeiramente foi realizada uma revisão bibliográfica dos conceitos sobre Internet das Coisas, Descoberta e Ranqueamento de Recursos, Middleware EXEHDA, Algoritmos de Árvore de Decisão e Algoritmos de Decisão de Multicritérios (MCDA).

Após a revisão bibliográfica, foram analisados algoritmos de Árvores de Decisão e algoritmos MCDA. Foram feitas abordagens para geração e ranqueamento de recursos no contexto da IoT, com objetivo de avaliar o

desempenho do algoritmo MCDA proposto. Para a parte que trata de MCDA foi concebido um método de ranqueamento, um gerador e classificador para o ranqueamento de recursos.

Já para os algoritmos de Árvore de Decisão a metodologia adotada foi a análise de alguns algoritmos de Árvores de decisão. Os algoritmos analisados foram aplicados sobre o *dataset Quality of Web Service*(QWS) usando a ferramenta de *Data Mining WEKA*. O objetivo da análise foi verificar a acurácia dos algoritmos na classificação de serviços considerando os valores de atributos de QoS, bem como examinar o tempo de construção de modelo de cada algoritmo selecionado.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1 Algoritmos MCDA

O processo de descoberta de recursos engloba a seleção dos recursos mais adequados à requisição do cliente. Nesta seção é apresentado o algoritmo MCDA proposto para o processo de ranqueamento de recursos utilizado neste trabalho. O algoritmo MCDA proposto é uma adaptação dos algoritmos *The Simple Additive Weighting* (SAW)(TZENG e HUANG 2011) e *Web Service Relevancy Function* (WsRF) (AL-MASRI e MAHMOUD 2007), com a primeira etapa de normalização de dados proposta por (LIU et al. 2004).

Com objetivo de analisar o desempenho do modelo de ranqueamento proposto, foi concebido um gerador de *dataset* que produz, utilizando a biblioteca *random*, um conjunto de recursos com atributos de valores aleatórios. Os valores dos atributos desses recursos respeitam um intervalo de valores mínimo e máximo definidos. Registre-se que estes valores mínimo e máximo tem por base um *dataset* que traduz um cenário real. Ao fim da criação do conjunto de teste, é efetuado o ranqueamento dos recursos gerados.

Com o emprego do programa desenvolvido para geração de recursos, foram criados 4 conjuntos com seus atributos de qualidade. Para o processo de criação destes recursos, optou-se por utilizar conjuntos com 3, 5 e 7 atributos com o objetivo de apontar a diferença de tempo no cálculo MCDA considerando diferentes quantidades de atributos. Além disso, foram criados *datasets* de tamanhos diferentes para analisar o aumento de tempo para conjuntos com diferentes quantidades de recursos e com mesmo número de atributos. O tamanho dos datasets testados foram de [10.000; 100.000; 500.000; 1.000.000] recursos. Com uma análise dos resultados, foi notado que houve um aumento linear no tempo de geração e ranqueamento, conforme o aumento do número de recursos, como ilustrado na Figura 1.

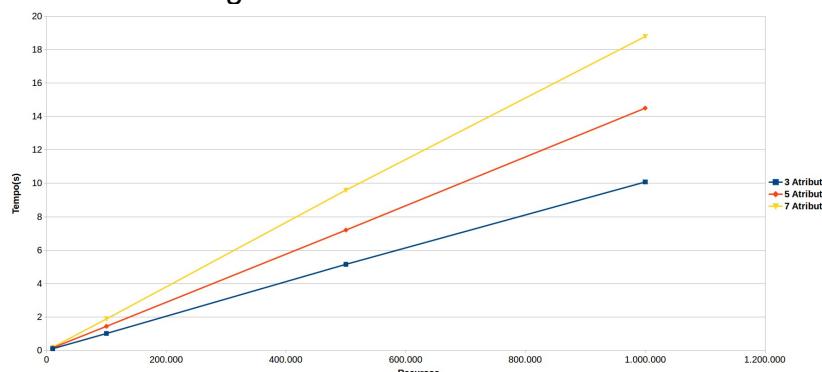


Figura 1 – Tempo de Computação do MCDA

Os testes dos algoritmos MCDA foram feitos em uma máquina com processador Intel I5-3570K CPU @ 3.40 GHz e memória RAM de 4GB.

### 3.1 Algoritmos de Árvores de Decisão

Identificou-se que os algoritmos de Árvore de Decisão são uma opção conveniente para a classificação de recursos. Estes algoritmos são adequados para problemas que envolvem a classificação baseada em decisão e aprendizado adaptativo em um conjunto de treinamento. A árvore de decisão é uma solução bem conhecida para implementar essas táticas, e é uma ferramenta de modelagem de decisão que mostra graficamente o processo de classificação de uma determinada entrada para determinados rótulos de classe de saída (WITTEN et al. 2016).

Utilizando a ferramenta WEKA foram analisados alguns dos algoritmos de árvore de decisão que o software dispõe, ilustrados na Figura 2. A classificação dos serviços foi realizada pelos algoritmos a fim de classificar o atributo *Service Classification* dentre outros cinco atributos do conjunto de dados analisado. Para execução dos testes foram utilizadas as configurações padrão da ferramenta WEKA. Os testes foram executados com *datasets* de 800, 900 e 1000 recursos para cada um dos algoritmos mencionados. Nos resultados dos testes pode-se observar que o algoritmo que, em média, obteve a melhor acurácia foi o LMT. Contudo esse foi também o algoritmo com o mais elevado tempo de construção de modelo. Outros algoritmos que obtiveram acurácia elevada foram o Random Forest e o FT, mantendo um tempo de construção de modelo bastante inferior comparado ao LMT.

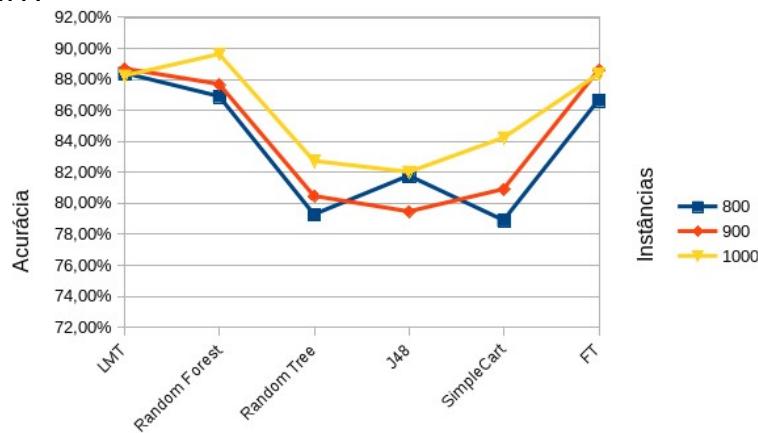


Figura 1 – Acurácia dos Algoritmos

## 4. CONCLUSÕES

A contribuição central desse trabalho foi explorar algoritmos de Árvore de Decisão e algoritmos MCDA, tendo como perspectiva seu emprego na Classificação de Recursos na IoT para contribuição na arquitetura de software do mecanismo de descoberta de recursos do *middleware* EXEHDA.

A utilização do algoritmo MCDA proposto para a classificação de recursos no contexto da Internet das Coisas apresentou um bom desempenho, considerando a literatura na área, mesmo com um grande aumento no conjunto de dados e no número de atributos de qualidade.

Os testes com os algoritmos de Árvore de Decisão aplicados à classificação de recursos apontaram uma acurácia média acima de 80%, o que por se tratar de uma pré-classificação atende as demandas do grupo referentes a

otimização de desempenho do middleware quanto ao ranqueamento de recursos. Também ficou caracterizado que os algoritmos LMT e Random Forest foram os que apresentaram melhores resultados. Sendo que o LMT teve um maior tempo de execução e acurácia média superior se comparado ao Random Forest.

Como atividades futuras pretende se desenvolver uma metodologia de ranqueamento de recursos utilizando MCDA e Árvores de Decisão para integrar a arquitetura do *middleware* EXEHDA em desenvolvimento no grupo de pesquisa.

## REFERÊNCIAS BIBLIOGRÁFICAS

AL-MASRI, E., MAHMOUD, Q. H. QoS-based discovery and ranking of Web services. In **Proceedings - International Conference on Computer Communications and Networks**, p. 529–534, 2007.

BIS RESEARCH. **Global Sensors in Internet of Things(IoT) Devices Market, Analysis & Forecast: 2016 to 2022**. Acessado em 2 ago. 2018. Online. Disponível em: [https://www.researchandmarkets.com/research/bvgxvl/global\\_sensors\\_in](https://www.researchandmarkets.com/research/bvgxvl/global_sensors_in)

FIGUEIRA, J., GRECO, S., EHRGOTT, M. **Multiple criteria decision analysis: state of the art surveys**. New York: Springer-Verlag, 2005.

JR, N. V. D. A.; BASTOS, D. B. Web of Things: Automatic Publishing and Configuration of Devices. In **Proceedings of the 20th Brazilian Symposium on Multimedia and the Web (WebMedia '14)**, New York, USA, p. 67-74, 2014.

LIU, Y., NGU, A. H., ZENG, L. Z. QoS computation and policing in dynamic web service selection. **Proceedings of the 13th international World Wide Web conference on Alternate track papers & posters**, p. 66–73, 2004.

PERERA, C. **Sensing as a Service for Internet of Things: A Roadmap**, Leanpub Publishers, 2017.

SUCHITHRA, M; RAMAKRISHNAN M. A Survey on Different Web Service Discovery Techniques. **Indian Journal of Science and Technology**. v.8, p.1-5, 2015.

TZENG, G. H., HUANG, J. J., **Multiple Attribute Decision Making: Methods and Applications**. Chapman and Hall/CRC, 2011.

WITTEN, I. H., FRANK, E., Hall, M. A. **The WEKA Workbench**, Acessado em 10 ago. 2018. Online. Disponível em: <https://www.cs.waikato.ac.nz/ml/weka/Witten et al 2016 appendix.pdf>