

Ranqueamento de Recursos na Internet das Coisas

Explorando Algoritmos MCDA

Juan Burtet, Huberto K. Filho, Renato Dilli,
Felipe C. Gruendemann, Ana Marilza Pernas, Adenauer Yamin

¹Laboratory of Ubiquitous and Parallel Systems – UFPEL
Pelotas, RS - Brasil

{jburttet, hkaiser, renato.dilli, fcgruendemann, marilza, adenauer}
@inf.ufpel.edu.br

Resumo. *A IoT caracteriza-se por possuir uma grande quantidade de dispositivos conectados em rede. O procedimento de descoberta e seleção de recursos neste cenário representa um desafio de pesquisa em aberto. Com o emprego do gerador e classificador de recursos concebidos, foi possível avaliar o desempenho do processo de ranqueamento, considerando uma grande quantidade de recursos. Os resultados com o algoritmo MCDA proposto são promissores.*

1. Introdução

A Internet das Coisas (IoT - *Internet of Things*), caracteriza-se pela presença de uma grande quantidade de objetos que pelo seu perfil operacional realizam conexões transientes na Internet, totalizando uma grande quantidade de recursos disponibilizados [Perera 2017]. Atualmente mais de seis bilhões de coisas estão conectadas à Internet disponibilizando serviços aos clientes e há previsão de 100 bilhões até 2025 [Gartner 2015] [BIS Research 2017].

Os recursos podem ser constituídos por *hardwares* heterogêneos, tais como, sensores e atuadores. O acesso aos dispositivos geralmente é realizado através de um ou mais serviços, caracterizando recursos de diferentes naturezas. Um desafio a ser vencido após a identificação e localização destes recursos é ranquear os serviços oferecidos para selecionar o que melhor atende a solicitação do usuário. Os processos de ranqueamento se concentram nas preferências do usuário, que frequentemente estabelecem uma ordem baseada na 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 não é apenas um conjunto de teorias, metodologias e técnicas, mas também uma perspectiva específica para lidar com problemas de tomada de decisão [Figueira et al. 2005].

Este trabalho apresenta abordagens para geração e ranqueamento de recursos no contexto da IoT, com objetivo de avaliar o desempenho do algoritmo MCDA proposto. O restante do trabalho está organizado da seguinte forma: na Seção 2 é apresentado o método de ranqueamento de recursos utilizado, na Seção 3 é apresentado tanto um gerador,

como um classificador a ser utilizado para o ranqueamento de recursos, e na Seção 4 são feitas as considerações finais.

2. Modelo para Ranqueamento de Recursos Proposto

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 and Huang 2011] e *Web Service Relevancy Function* (WsRF) [Al-Masri and Mahmoud 2007], com a primeira etapa de normalização de dados proposta por [Liu et al. 2004].

Para a normalização da matriz são definidos dois vetores. O primeiro $N = \{n_1, n_2, \dots, n_m\}$. O valor de n_j pode ser 0 ou 1. Será 1 quando o aumento de $q_{i,j}$ beneficia a requisição do cliente e 0 quando o aumento de $q_{i,j}$ não beneficia a requisição do cliente. O segundo vetor $C = \{c_1, c_2, \dots, c_m\}$ contém constantes com o máximo valor normalizado para cada atributo.

As seguintes etapas devem ser realizadas para o cálculo da avaliação dos recursos através do algoritmo MCDA:

1. Normalizar a matriz $Q = (q_{ij})_{n \times m}$ de acordo com a Eq.(1) se o critério deve ser maximizado ou Eq.(2) se o critério deve ser minimizado. Nestas equações, $\frac{1}{n} \sum_{i=1}^n q_{i,j}$ é a média dos atributos de qualidade j na matriz Q [Liu et al. 2004].

$$v_{i,j} = \begin{cases} \frac{q_{i,j}}{\frac{1}{n} \sum_{i=1}^n q_{i,j}} & \text{if } \frac{1}{n} \sum_{i=1}^n q_{i,j} \neq 0 \\ & \text{and } \frac{q_{i,j}}{\frac{1}{n} \sum_{i=1}^n q_{i,j}} < c_j \\ & \text{and } n_j = 1 \\ c_j & \text{if } \frac{1}{n} \sum_{i=1}^n q_{i,j} = 0 \\ & \text{and } n_j = 1 \\ & \text{or } \frac{q_{i,j}}{\frac{1}{n} \sum_{i=1}^n q_{i,j}} \geq c_j \end{cases} \quad v_{i,j} = \begin{cases} \frac{\frac{1}{n} \sum_{i=1}^n q_{i,j}}{q_{i,j}} & \text{if } q_{i,j} \neq 0 \\ & \text{and } n_j = 0 \\ & \text{and } \frac{\frac{1}{n} \sum_{i=1}^n q_{i,j}}{q_{i,j}} < c_j \\ c_j & \text{if } q_{i,j} = 0 \\ & \text{and } n_j = 0 \\ & \text{or } \frac{\frac{1}{n} \sum_{i=1}^n q_{i,j}}{q_{i,j}} \geq c_j \end{cases} \quad (1) \quad (2)$$

2. Calcular o vetor pontuação de cada opção disponível. Cada pontuação pode ser calculada usando a Eq.(3)a e o operador $\max(v_j)$ representando o maior valor de atributo normalizado na coluna j . Portanto, precisamos definir uma matriz que represente a contribuição de pesos para cada recurso, onde $w = \{w_1, w_2, w_3, \dots, w_j\}$. Cada peso nesta matriz representa o grau de importância ou fator de peso associado a uma propriedade QoS específica. Os valores de desses pesos variam de 0 a 1. A Eq.(3)b soma todos os atributos de qualidade para o recurso R_i , onde N representa o número de atributos.

$$h_{i,j} = w_j \left[\frac{v_{i,j}}{\max(v_j)} \right]; \quad R_i = \sum_{j=1}^N h_{i,j} \quad \text{e} \quad MCD(A_i) = \left[\frac{100 * R_i}{\max(R)} \right]. \quad (3)$$

3. Prototipação e Testes

Com objetivo de analisar o desempenho do modelo de ranqueamento proposto, foi concebido um gerador de recursos na linguagem Python, adotada pelo grupo de pesquisa, que produz utilizando a biblioteca *random*, um conjunto de recursos aleatórios. Para cada atributo é selecionado um valor aleatório entre os valores mínimo e máximo definidos pelo seus atributos. Registre-se que estes valores mínimo e máximo tem por base o dataset [Al-Masri and Mahmoud 2007], que traduz um cenário real. Ao fim da criação do conjunto, é feito o ranqueamento de todos os recursos gerados.

As Tabelas 1, 2 e 3 apresentam o processo de ranqueamento de dez recursos produzidos pelo gerador, e após processados pelo classificador de recursos proposto.

Tabela 1. Exemplo de Dataset					Tabela 2. Atributos Normalizados					Tabela 3. Atributos Classificados					
RT	AV	TH	RE	LA	RT	AV	TH	RE	LA	RT	AV	TH	RE	LA	R
302,75	89	7,1	73	187,75	1,70	1,07	0,97	1,06	0,21	0,24	0,91	0,33	0,94	0,00	61
482,00	85	16	73	1	1,07	1,02	2,19	1,06	38,56	0,15	0,87	0,75	0,94	0,70	86
3321,4	89	1,4	73	2,6	0,15	1,07	0,19	1,06	14,83	0,02	0,91	0,07	0,94	0,27	56
126,17	98	12	67	22,77	4,07	1,18	1,64	0,98	1,69	0,57	1,00	0,56	0,86	0,03	76
107,00	87	1,9	73	58,33	4,80	1,04	0,26	1,06	0,66	0,67	0,89	0,09	0,94	0,01	66
107,57	80	1,7	67	18,21	4,78	0,96	0,23	0,98	2,12	0,67	0,82	0,08	0,86	0,04	62
255,00	98	1,3	67	40,8	2,02	1,18	0,18	0,98	0,95	0,28	1,00	0,06	0,86	0,02	56
136,71	76	2,8	60	11,57	3,76	0,91	0,38	0,87	3,33	0,53	0,78	0,13	0,77	0,06	57
102,62	91	15,3	67	0,93	5,00	1,09	2,10	0,98	41,46	0,70	0,93	0,72	0,86	0,75	100
200,00	40	13,5	67	41,66	2,57	0,48	1,85	0,98	0,93	0,36	0,41	0,63	0,86	0,02	58

A primeira etapa da classificação é a normalização dos dados. Para tanto, consideramos os vetores $N=\{0,1,1,1,0\}$ e $C=\{5,2,3,2,50\}$. Os atributos *Response Time* e *Latency* qualificam o recurso com valores baixos obtidos pela Eq.(1) e *Availability*, *Throughput* e *Reability* qualificam com valores altos pela Eq.(2).

A Tabela 3 apresenta os valores dos atributos após aplicar a Eq.(3)a, ou seja dividir o valor normalizado da Tabela 2 pelo maior valor normalizado de cada coluna, multiplicado pelos pesos definidos pelo especialista $w=\{0.70,1.00,0.75,0.94,0.75\}$. O valor MCDA é obtido aplicando a Eq.(3)b, que irá somar todos os valores de atributos em cada linha. Após é aplicada a Eq.(3)c que irá qualificar o recurso com um valor que vai de 0 a 100. Será dado o valor 100 para o melhor recurso do *dataset*. O resultado da classificação está informado na coluna "R". A classificação final é apresentada ao cliente em ordem decrescente, ou seja, do recurso mais qualificado ao menos qualificado.

Com o emprego do *software* 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. O desempenho em cada um dos testes é visto na Tabela 4 (Tempo de criação de *datasets*) e na Tabela 5 (Tempo de classificação MCDA)

Tabela 4. Tempo de geração dos recursos e seus atributos

Atrib	Recursos (x 1.000)			
	10	100	500	1.000
3	0.86s	8.69s	45.87s	88.17s
5	1.30s	13.92s	65.38s	130.17s
7	1.77s	17.40s	87.37s	174.49s

Tabela 5. Tempo de ranqueamento dos recursos

Atrib	Recursos (x 1.000)			
	10	100	500	1.000
3	0.10s	1.01s	5.15s	10.08s
5	0.15s	1.44s	7.20s	14.50s
7	0.18s	1.88s	9.59s	18.79s

Todos os testes foram feitos em uma máquina com Intel I5-3570K CPU @ 3.40 GHz e 4.00 GB de RAM. Com uma análise dos resultados, foi notado um ótimo desempenho no algoritmo SAW para classificação de recursos. Também foi notado que houve um aumento linear no tempo de geração e ranqueamento, conforme o aumento do número de recursos.

4. Considerações Finais

A utilização do algoritmo MCDA proposto para a classificação de recursos no contexto da Internet das Coisas apresentou um ótimo desempenho, considerando a literatura na área [Al-Masri and Mahmoud 2007], mesmo com um grande aumento no conjunto de dados e no número de atributos de qualidade.

Em trabalhos futuros, novos testes serão feitos, comparando a acurácia do ranqueamento obtido pelo algoritmo MCDA com novos métodos de ranqueamento, tais como Lógica *Fuzzy* e Aprendizagem de Máquina.

Referências

- Al-Masri, E. and Mahmoud, Q. H. (2007). QoS-based discovery and ranking of Web services. In *Proceedings - International Conference on Computer Communications and Networks, ICCCN*, pages 529–534.
- BIS Research (2017). Global Sensors in Internet of Things (IoT) Devices Market, Analysis & Forecast: 2016 to 2022. Technical report.
- Figueira, J., Greco, S., and Ehrgott, M. (2005). Multiple criteria decision analysis: state of the art surveys. *Multiple Criteria Decision Analysis State of the Art Surveys*, 78.
- Gartner (2015). Gartner says 6.4 billion connected "things" will be in use in 2016, up 30 percent from 2015.
- Liu, Y., Ngu, A. H., and Zeng, L. Z. (2004). QoS computation and policing in dynamic web service selection. *Proceedings of the 13th international World Wide Web conference on Alternate track papers & posters*, pages 66–73.
- Perera, C. (2017). *Sensing as a Service for Internet of Things: A Roadmap*. Leanpub Publishers.
- Tzeng, G. H. and Huang, J. J. (2011). *Multiple Attribute Decision Making: Methods and Applications*. A Chapman & Hall book. Taylor & Francis.