

Classificação de Recursos na IoT: Automação de Regras Fuzzy na Seleção de Preferências do Cliente *

Patrick Fernandes * Renato Dilli ** Eduardo Monks ***
Renata Reiser *** Adenauer Yamin *

* *Mestrado em Engenharia Eletrônica e Computação, Univ. Católica de Pelotas, RS, (e-mail: patrick.fernandes, adenauer@sou.ucpel.edu.br).*

** *Departamento de Ensino de Grad. e de Pós-grad., Instituto Federal Sul-rio-grandense, RS (e-mail: renatodilli@ifsul.edu.br)*

*** *Programa de Pós-Graduação em Computação, Univ. Federal de Pelotas, RS (e-mail: emmonks, reiser@inf.ufpel.edu.br)*

Abstract: In the Internet of Things, there is a large number of interconnected sensing and/or acting resources, and each of these resources can offer different services. Specifying client preferences as to the relevance of QoS attributes associated with resources is often accompanied by uncertainty. In this sense, Fuzzy Logic is opportune to deal with uncertain data. As part of the Fuzzy approach, it is necessary to use rules, whose specification can gain complexity when the number of attributes to be considered increases. From this motivation comes the objective of this work, which is the conception of a proposal for automation of Fuzzy rules, called IoT-DFR³. Among its main features, we would highlight: (i) dynamic generation of Fuzzy rules; (ii) selection of client preferences; (iii) resource classification using Interval Type-2 Fuzzy Logic. The results obtained with the classification of resources applying client preferences and the automatic generation of fuzzy rules are presented.

Resumo: Na Internet das Coisas tem-se um elevado número de recursos de sensoriamento e/ou atuação, interconectados, sendo que cada um destes recursos pode oferecer diversos serviços. A especificação das preferências do cliente quanto à relevância dos atributos de QoS associados aos recursos geralmente é acompanhada de incertezas. Neste sentido, a Lógica Fuzzy é oportuna para lidar com dados incertos. Como parte da abordagem Fuzzy se faz necessário o emprego de regras, cuja especificação pode ganhar complexidade quando o número de atributos a serem considerados aumenta. A partir desta motivação decorre o objetivo deste trabalho que é a concepção de uma proposta para automação de regras Fuzzy, denominada IoT-DFR³. Dentre as suas principais funcionalidades, destacam-se: (i) geração dinâmica de regras Fuzzy; (ii) seleção de preferências do cliente; (iii) classificação de recursos utilizando Lógica Fuzzy Tipo-2 Intervalar. Os resultados obtidos com a classificação de recursos aplicando as preferências do cliente e a geração automática de regras fuzzy são apresentados.

Keywords: Internet of Things; Resource classification; Fuzzy Rules Automation.

Palavras-chaves: Internet das Coisas; Classificação de Recursos; Automação de Regras Fuzzy.

1. INTRODUÇÃO

Na perspectiva da Internet das Coisas (IoT) diferentes recursos oferecendo diferentes serviços de sensoriamento e/ou atuação são interconectados por uma infraestrutura de rede largamente distribuída Schenfeld et al. (2016). Até o ano de 2030 a expectativa é que ao redor de 125 bilhões de recursos estejam conectados à IoT IHS Markit (2017), podendo cada um destes recursos, inclusive, oferecer mais de um serviço. Deste modo, a seleção dos recursos cujos serviços que melhor atendam os requisitos de um cliente, entre os vários recursos aptos, pode resultar em uma tarefa complexa.

Uma proposta de seleção deve considerar tanto os requisitos funcionais como os não funcionais dos recursos da IoT que estão sendo considerados. Os requisitos funcionais indicam aquilo que os serviços devem oferecer. Os requisitos não funcionais, por sua vez, são associados à Qualidade de Serviço (QoS), apontam para as expectativas operacionais dos serviços. Por exemplo, a “disponibilidade”, que é a porcentagem de tempo que um serviço permanece funcionando; e/ou o “tempo de resposta”, que é o tempo necessário para um serviço responder Khutade and Phalnikar (2014).

Para definir se um certo recurso é capaz de atender as demandas de um cliente, são utilizados os requisitos não funcionais. Por sua vez, a avaliação de parâmetros não funcionais de QoS dos serviços fornecidos pelos recursos,

* O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES)

estabelece a base para selecionar entre os recursos apropriados, quais são os mais aptos para atender a demanda de um cliente.

Considerando isto, se mostra necessário classificar os recursos segundo os parâmetros não funcionais, para então selecionar os mais adequados. Nesta classificação, se faz necessário considerar as incertezas dos clientes na caracterização de suas preferências, quanto aos parâmetros de QoS que lhe são mais apropriados.

Nesta proposta está previsto o emprego de Lógica Fuzzy para o tratamento da incerteza. Entretanto, na abordagem Fuzzy se faz necessário o emprego de regras, cuja especificação pode ganhar elevada complexidade quando o número de atributos a serem considerados aumenta. Deste cenário surge o desafio de pesquisa, que é reduzir o esforço associado à criação manual de regras para um sistema Fuzzy Tipo-2 Intervalar.

Neste sentido, o objetivo geral deste trabalho é conceber uma proposta denominada IoT-DFR³ (*IoT-Dynamic Fuzzy Rules for Resource Ranking*), para geração dinâmica de Regras Fuzzy, explorando o método de Wang-Mendel (WM) Wang and Mendel (1992). A arquitetura de software IoT-DFR³ foi desenvolvida com o intuito de ser integrada à proposta EXEHDA-RR Dilli et al. (2018), direcionada à seleção de recursos na IoT.

Este trabalho está organizado do seguinte modo: na Seção 2 são indicados os trabalhos relacionados, na Seção 3, a proposta IoT-DFR³, na Seção 4, o cenário de uso e por fim, na Seção 5 as considerações finais.

2. TRABALHOS RELACIONADOS

Esta revisão contribuiu para as discussões quanto às funcionalidades a serem propostas para a arquitetura de software do IoT-DFR³.

O trabalho Tripathy and Tripathy (2018), aborda o uso de Lógica Fuzzy para seleção de recursos, composição e adaptação de QoS em tempo de execução. Utiliza atributos de QoS como entrada de um Sistema Baseado em Regras Fuzzy (SBRF). O sistema implementa um conjunto de mecanismos de adaptação com base no monitoramento da saída e na nova seleção automática de serviços.

Em Ezenwoke (2018) é apontado um modelo baseado em Lógica Fuzzy para seleção de serviços em mercado eletrônico conforme as preferências dos clientes. Esse modelo, denominado de FOCUSS, possui os métodos Fuzzy AHP para obter os pesos dos atributos de QoS, Fuzzy DM para obter os valores de QoS desejados pelo usuário e por fim, um módulo de Fuzzy MOP para avaliar os serviços com relação às preferências do cliente.

A proposta Belouaar et al. (2018) apresenta também, um modelo baseado em Lógica Fuzzy com o intuito de ajudar os consumidores de serviços da Web a classificar o serviço mais adequado, considerando suas preferências.

Um outro modelo Fuzzy para seleção de serviços em nuvem, considerando os atributos de QoS, é abordado em Kumar et al. (2017). Este modelo emprega o método do AHP (processo de hierarquia analítica) para calcular

os pesos e Fuzzy TOPSIS (preferência de ordem por similaridade à solução ideal) para a classificação final.

Considerando o foco central desta pesquisa e após analisar as contribuições desses trabalhos, é proposta uma arquitetura de software denominada IoT-DFR³ para geração de regras Fuzzy e também permite que o cliente selecione suas preferências para cada atributo de QoS de forma confortável, oferecendo suporte a eventuais incertezas no momento desta definição. Destaca-se que o principal diferencial da IoT-DFR³ é a geração automatizada de regras Fuzzy.

3. IOT-DFR³: ARQUITETURA E FUNCIONALIDADES

Esta seção apresenta a concepção da proposta IoT-DFR³. A premissa central buscada é gerar automaticamente as Regras Fuzzy, tendo os dados de entrada como base, que serão aplicadas para classificação de recursos na IoT, tendo em vista também a integração da arquitetura de software da IoT-DFR³ ao EXEHDA-RR.

3.1 Explorando a Geração Automática de Regras Fuzzy

O Método de Wang Mendel adotado na proposta IoT-DFR³ proporcionará agilidade ao gerar as regras Fuzzy de forma automática e contribuirá com a redução no número de regras. Por exemplo, ao utilizar 3 atributos, teríamos um total de 27 regras. Ao aplicar o Método de Wang Mendel para os mesmos 3 atributos, alcança-se uma redução superior a 50% no número total dessas mesmas regras. Vale ressaltar que quanto maior o número de atributos, conseqüentemente maior o número de regras.

A IoT-DFR³ permite também, além do método de Wang Mendel, a inserção manual de regras na Base de Regras Fuzzy. Assim, é possível acrescentar um conjunto de regras específicas para certas preferências. Deste modo, a IoT-DFR³ aprimora o funcionamento da arquitetura de software do EXEHDA-RR no desenvolvimento e na manipulação das regras para a classificação de recursos. A Figura 1 apresenta a arquitetura de software da proposta IoT-DFR³.

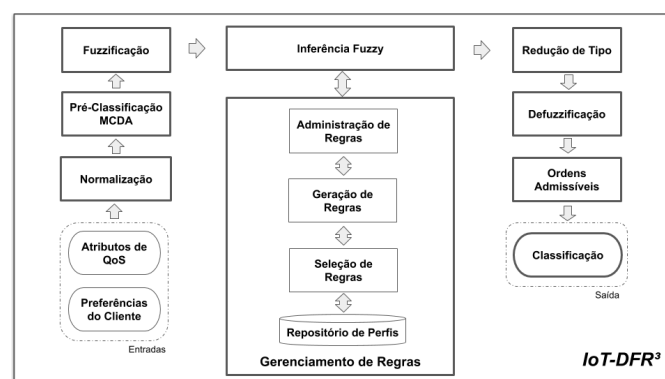


Figura 1. IoT-DFR³: Visão Arquitetural

Através de variáveis linguísticas, o cliente estabelece quais são suas prioridades e com a intervenção de um especialista, pode se atribuir regras adicionais para contemplar essas preferências.

O especialista também desenvolve as funções de pertinência referentes à Lógica Fuzzy Tipo-2 Intervalar para cada atributo presente no conjunto de preferências que está sendo considerado.

A proposta IoT-DFR³ permite que o cliente selecione essas preferências de cada um dos atributos de QoS dos recursos (Figura 2). Esses atributos têm as opções de configuração *Low* (L), *Medium* (M) ou *High* (H).

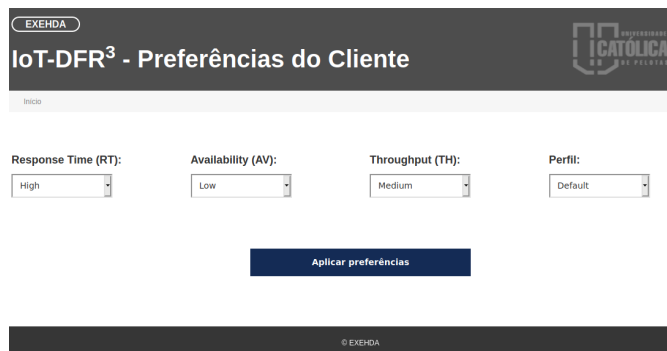


Figura 2. Preferências do Cliente (HLM)

3.2 Bloco de Normalização

O Sistema IoT-DFR3 recebe como entrada um conjunto de recursos (atributos de QoS) e as preferências do cliente. O Bloco de Normalização tem como objetivo normalizar os valores dos atributos de QoS para ficarem com a mesma faixa de valores, em uma escala entre 0 e 100. Esse procedimento é realizado para cada um desses atributos. Porém, os atributos que já possuem definidas as suas escalas de valores entre 0 e 100 não são normalizados. A normalização é executada conforme a Equação Eq.(1) se o critério deve ser maximizado ou Equação Eq.(2) se o critério deve ser minimizado.

$$h_{i,j} = \left[\frac{v_{i,j} * 100}{\max(v_j)} \right] \quad (1) \quad h_{i,j} = \left[\frac{\min(v_j) * 100}{v_{i,j}} \right] \quad (2)$$

3.3 Bloco de Pré-Classificação MCDA

Este Bloco recebe os dados normalizados e possui a finalidade de pré-classificar os recursos descobertos, comparando e avaliando os atributos de QoS. Os recursos são classificados com peso de “1” a “3”, ao qual os melhores recursos são classificados com peso 1 e os piores, com o peso 3. Essa pré-classificação se faz necessária para obter o peso de cada recurso, formando assim o conjunto de dados que será utilizado posteriormente como *dataset* de entrada pelo Método de Wang-Mendel, no Módulo Geração de Regras, para automação.

3.4 Bloco de Fuzzificação

Após a execução do Bloco de pré-classificação MCDA, é realizado o processo do Bloco de Fuzzificação, que transforma um valor crisp (Real) em um Conjunto Fuzzy Tipo-2 Intervalar. No sistema Fuzzy Tipo-2 Intervalar, o conjunto de recursos são submetidos como entrada ao qual, cada um dos atributos é processado. Foram utilizados os

atributos de entrada *Response Time* (RT), *Availability* (AV) e *Throughput* (TH). Após o processo de fuzzificação, é a vez do Bloco de Inferência Fuzzy processar as regras de acordo com o Bloco de Gerenciamento de Regras, descrito a seguir.

3.5 Bloco de Gerenciamento de Regras

O Bloco de Gerenciamento de Regras possui o Repositório de Perfis, o Módulo Seleção de Regras, o Módulo Geração de Regras e o Módulo Administração de Regras.

O Bloco de Inferência Fuzzy envia as preferências do cliente para ser processada pelo Bloco de Gerenciamento de Regras, e ao final deste processo, é a vez do Bloco de Inferência Fuzzy (Seção 3.6) ser executado. Cada item do Bloco de Gerenciamento de Regras é destacado a seguir.

Repositório de Perfis O Repositório de Perfis tem como objetivo armazenar as configurações dos clientes, por perfil, bem como, funções de pertinência e conjunto de regras estipulado por um especialista. A IoT-DFR³ possui também um perfil “*Default*”, com configurações de execução padrão. Esse perfil possui funções de pertinência triangular e trapezoidal, prontas para serem ativadas com o conjunto de regras apropriado, de acordo com a preferência do cliente.

Módulo Seleção de Regras O Módulo Seleção de Regras tem o objetivo de identificar o conjunto de dados para serem processados pelo Módulo de Geração de Regras. Este Módulo, recebe informações para serem armazenadas no Repositório de Perfis e também filtra o conjunto de informações, contendo funções de pertinência e conjunto de regras manuais, para serem processado pelo Módulo Geração de Regras.

Módulo Geração de Regras Visto que o EXEHDA-RR gera a Base de Regras manualmente, combinando todas as possibilidades de regras conforme suas entradas. Nesta perspectiva, a premissa central da proposta IoT-DFR³ é abordar a geração de regras Fuzzy dinamicamente, para o processo de classificação de recursos no cenário da IoT, tendo o conjunto de dados de entrada como base para realizar o processo de automação das regras. E também, considerando a redução do número de regras Fuzzy. Para isso, é aplicado o Método de Wang-Mendel (WM).

Módulo de Administração de Regras Responsável por administrar o conjunto de regras e funções de pertinência que serão processadas pelo Bloco de Inferência Fuzzy, que também se encarrega de encaminhar os dados para o Repositório de Perfis. Além disso, permite que o especialista crie perfis com novas regras e funções de pertinência.

Este Módulo executa o algoritmo de Wang Mendel (WM), que possui uma forma rápida para construção de regras Fuzzy orientado a dados numéricos Mutlu et al. (2018), ao que representam as amostras de um determinado conjunto de dados Silva (2015). O Método de WM fornece precisão ao elaborar as regras e ao mesmo tempo são modelos fáceis de serem entendidos e manuseados por não especialistas Santos and Mendoza (2018). O método resulta no modelo de regras do tipo Mamdani.

3.6 Bloco de Inferência Fuzzy

Após o *Bloco de Gerenciamento de Regras* ser processado, é executado o Bloco de Inferência Fuzzy, que tem

o objetivo de processar as regras do *Módulo de Administração de Regras*. O Bloco de Inferência Fuzzy aplica o Método de Mamdani para Conjuntos Fuzzy Tipo-2 Intervalar. Após concluir seu propósito, é necessário modelar o Conjunto Fuzzy Tipo-2 em Conjunto Fuzzy Tipo-1. Para isso, utiliza-se o Bloco Redução de Tipo.

3.7 Bloco Redução de Tipo

O Bloco Redução de Tipo modela o Conjunto Fuzzy Tipo-2 Intervalar em Conjunto Fuzzy Tipo-1. Este Bloco efetua o método do centroide, que utiliza o algoritmo de Karnik-Mendel (KM) para aplicar a modelagem. O Método fornece o intervalo fechado $[C_L, C_R]$ sendo o mínimo (C_L) e o máximo (C_R) dos centroides de Conjuntos Fuzzy Tipo-1, cuja função de pertinência está contida na mancha de incerteza (*Footprint of Uncertainty - FOU*) Cabrera (2014).

3.8 Bloco de Defuzzificação

Após finalizar o processo do Bloco de Redução de Tipo, é a vez do Módulo de Defuzzificação. Nota-se que ao defuzzificar os intervalos para obter um valor crisp com o propósito de ordenar e para fazer a classificação final, em alguns casos o valor defuzzificado de intervalos diferentes permanece o mesmo, o que dificulta no processo da classificação. Por isso, a defuzzificação não é efetuada como a média entre dois valores, onde o primeiro calcula o ponto final esquerdo do intervalo (C_L) e o último calcula o ponto final direito (C_R). Portanto, optou-se por preservar os intervalos e ordená-los por meio de Ordens Admissíveis.

3.9 Bloco Ordens Admissíveis

O Bloco Ordens Admissíveis, obtém uma lista de intervalos gerados a partir dos Conjuntos Fuzzy Tipo-2 Intervalar, com muitos elementos que podem não ser comparáveis pela ordem parcial usual, uma ordem total de intervalos apontados com base nas ordens admissíveis, como proposto por Xu and Yager (2006).

Assim, o Bloco Ordens Admissíveis modela as incertezas relacionadas com as preferências do cliente e a imprecisão dos cálculos computacionais. Deste modo, é possível garantir a comparação de todos os dados do intervalo de saída. Assim, considera a ordem de Xu e Yager, ao qual os recursos são classificados em ordem decrescente de intervalos através da ordem admissível.

4. CENÁRIO DE USO

Este cenário visa avaliar a geração de regras Fuzzy conforme as preferências do cliente, adequando a geração de regras para posteriormente classificar os recursos de acordo com a preferência informada.

Neste cenário foram utilizados os atributos RT, AV e TH (descrito na Tabela 1) e 2400 recursos do *dataset* QWS, que teve sua última atualização em novembro de 2019. Foram empregadas as preferências do cliente para HHH, HLM e MHM, para serem geradas as regras Fuzzy utilizando o método de Wang-Mendel. Para adequação das preferências foram definidos pesos equivalentes: H = 1, M

= 0,6 e L = 0,3. Esses pesos foram utilizados para adaptar o método WM para gerar as regras. As Tabelas 3, 4 e 5 apresentam as regras Fuzzy geradas.

Tabela 1. Atributos do QWS *Dataset* 2.0 Considerados

Atributo	Descrição do Atributo
<i>Response Time</i> – RT (Tempo de Resposta)	Tempo gasto para enviar uma solicitação e receber uma resposta
<i>Availability</i> – AV (Disponibilidade)	Número de invocações bem-sucedidas/ total de invocações
<i>Throughput</i> – TH (Taxa de Transferência)	Número total de invocações por um determinado período de tempo
<i>Successability</i> – SU (Sucessibilidade)	Número de solicitação/ resposta de mensagens
<i>Reliability</i> – RE (Confiabilidade)	Taxa de erro em relação ao total de mensagens

Fonte: Al-Masri and Mahmoud (2008)

A Tabela 2 aponta na primeira coluna a quantidade de recursos utilizados, na segunda coluna a quantidade de atributos empregado na avaliação, por sua vez, a terceira coluna apresenta a quantidade de regras a serem geradas pelo especialista. Já na última coluna a Tabela indica a quantidade de regras geradas pelo Método de Wang-Mendel.

Tabela 2. Número de Regras Geradas: Especialista & Método de WM

Recursos	Atributos	Regras Geradas pelo Especialista	Regras Geradas pelo Método WM
2400	3	$3^3 = 27$	17
	4	$3^4 = 81$	19
	5	$3^5 = 243$	34

Nota-se que o número de regras geradas pelo método de Wang-Mendel reduz consideravelmente a quantidade de regras a serem utilizadas.

Mesmo aumentando o número de atributos, a quantidade de regras geradas pelo método de WM ainda é menor do que o total de regras quando estas são especificadas por um especialista. As regras fornecidas pelo especialista geralmente é uma combinação de todas as preferências do cliente com a quantidade de atributos.

Isso provavelmente ocorre por dois motivos, primeiro que a quantidade de recursos permaneceu a mesma e segundo, o mais importante, é que o valor de cada atributo não possui uma variação tão grande, por isso, se torna possível uma redução tão significativa no número de regras. Pois, o método de WM elimina as regras conflitantes e não cria regras desnecessárias. A não criação de regras sem potencial de uso é consequência do método de WM conhecer o *dataset* com os atributos de entrada, sobre o qual as regras serão aplicadas

Os recursos empregados nessa avaliação foram retirados do QWS *dataset*, com os atributos *Response Time* (RT), *Availability* (AV), *Throughput* (TH), *Successability* (SU) e *Reliability* (RE), identificados como os mais apropriados para as demandas do cliente.

As Tabelas 3, 4 e 5 apresentam as regras geradas para os 2400 recursos. A Tabela 6 apresenta uma comparação do consequente dessas regras para as preferências HHH, HLM e MHM. Na primeira coluna o ID da regra, na segunda o consequente da preferência HHH, na terceira o consequente

Tabela 3. IoT-DFR³ - Regras Fuzzy para Preferência HHH

ID	Regras	Pesos
1	Se HighRT e LowAV e LowTH então LowWeight	0.38
2	Se HighRT e MediumAV e LowTH então MediumWeight	0.58
3	Se MediumRT e LowAV e LowTH então LowWeight	0.99
4	Se LowmRT e LowAV e LowTH então LowWeight	1.0
5	Se MediumRT e MediumAV e LowTH então LowWeight	0.86
6	Se HighRT e MediumAV e MediumTH então MediumWeight	0.05
7	Se HighRT e HighAV e LowTH então MediumWeight	0.80
8	Se MediumRT e HighAV e LowTH então MediumWeight	0.83
9	Se LowRT e MediumAV e LowTH então LowWeight	1.0
10	Se HighRT e HighAV e MediumTH então HighWeight	0.34
11	Se LowRT e HighAV e LowTH então LowWeight	1.0
12	Se MediumRT e HighAV e MediumTH então MediumWeight	0.94
13	Se LowRT e MediumAV e MediumTH então LowWeight	0.18
14	Se HighRT e HighAV e HighTH então HighWeight	0.68
15	Se LowRT e HighAV e MediumTH então MediumWeight	1.0
16	Se MediumRT e HighAV e HighTH então HighWeight	0.44
17	Se LowRT e HighAV e HighTH então MediumWeight	0.50

Tabela 4. IoT-DFR³ - Regras Fuzzy para Preferência HLM

ID	Regras	Pesos
1	Se HighRT e LowAV e LowTH então HighWeight	0.38
2	Se HighRT e MediumAV e LowTH então HighWeight	0.58
3	Se MediumRT e LowAV e LowTH então MediumWeight	0.99
4	Se LowmRT e LowAV e LowTH então LowWeight	1.0
5	Se MediumRT e MediumAV e LowTH então HighWeight	0.86
6	Se HighRT e MediumAV e MediumTH então HighWeight	0.05
7	Se HighRT e HighAV e LowTH então HighWeight	0.80
8	Se MediumRT e HighAV e LowTH então HighWeight	0.83
9	Se LowRT e MediumAV e LowTH então MediumWeight	1.0
10	Se HighRT e HighAV e MediumTH então HighWeight	0.34
11	Se LowRT e HighAV e LowTH então LowWeight	1.0
12	Se MediumRT e HighAV e MediumTH então HighWeight	0.94
13	Se LowRT e MediumAV e MediumTH então MediumWeight	0.18
14	Se HighRT e HighAV e HighTH então HighWeight	0.68
15	Se LowRT e HighAV e MediumTH então HighWeight	1.0
16	Se MediumRT e HighAV e HighTH então HighWeight	0.44
17	Se LowRT e HighAV e HighTH então HighWeight	0.50

Tabela 5. IoT-DFR³ - Regras Fuzzy para Preferência MHM

ID	Regras	Pesos
1	Se HighRT e LowAV e LowTH então HighWeight	0.38
2	Se HighRT e MediumAV e LowTH então HighWeight	0.58
3	Se MediumRT e LowAV e LowTH então MediumWeight	0.99
4	Se LowmRT e LowAV e LowTH então LowWeight	1.0
5	Se MediumRT e MediumAV e LowTH então HighWeight	0.86
6	Se HighRT e MediumAV e MediumTH então HighWeight	0.05
7	Se HighRT e HighAV e LowTH então HighWeight	0.80
8	Se MediumRT e HighAV e LowTH então HighWeight	0.83
9	Se LowRT e MediumAV e LowTH então HighWeight	1.0
10	Se HighRT e HighAV e MediumTH então HighWeight	0.34
11	Se LowRT e HighAV e LowTH então HighWeight	1.0
12	Se MediumRT e HighAV e MediumTH então HighWeight	0.94
13	Se LowRT e MediumAV e MediumTH então HighWeight	0.18
14	Se HighRT e HighAV e HighTH então HighWeight	0.68
15	Se LowRT e HighAV e MediumTH então HighWeight	1.0
16	Se MediumRT e HighAV e HighTH então HighWeight	0.44
17	Se LowRT e HighAV e HighTH então HighWeight	0.50

da preferência HLM e na última coluna o consequente da preferência MHM.

A preferência HHH, apontada na Tabela 6, significa que os atributos de QoS RT, AV e TH, são todos apontados como H (*High*), já na preferência HLM, o RT é identificado como *High*, o AV como L (*Low*) e o TH como M (*Medium*)

e por fim, na preferência MHM, o RT é *Medium*, o AV é *High* e o TH é *Medium*.

Mesmo com as preferências do cliente sendo especificadas diferentemente, os pesos das regras atribuídos pelo método WM mantiveram-se os mesmos. Isso ocorre porque os 2400 recursos com os valores dos atributos RT, AV e TH são os mesmos utilizados no processo para gerar as regras para cada preferência.

Na Tabela 6, podemos identificar que apenas as regras de ID 4, 10, 14 e 16 mantiveram-se iguais. Isso identifica que se alterarmos a preferência do cliente, conforme sua necessidade, a relevância das regras para cada recurso tem uma mudança considerável no seu resultado.

Tabela 6. IoT-DFR³ - Comparação entre os Consequentes das Regras para as Preferências HHH, HLM e MHM

ID	HHH	HLM	MHM
1	Low	High	High
2	Medium	High	High
3	Low	Medium	Medium
4	Low	Low	Low
5	Low	High	High
6	Medium	High	High
7	Medium	High	High
8	Medium	High	High
9	Low	Medium	High
10	High	High	High
11	Low	Low	High
12	Medium	High	High
13	Low	Medium	High
14	High	High	High
15	Medium	High	High
16	High	High	High
17	Medium	High	High

Pode-se observar, como exemplo, que a regra de ID 11 possui como antecedente RT (*Low*), AV (*High*) e TH (*Low*). Essa regra teve um consequente diferente para as preferências HLM e MHM. Na preferência HLM o cliente prioriza o RT, especificando como *High*, sendo assim, esta regra não atende a preferência e seu consequente por tanto é *Low*. Já na preferência MHM, o cliente prioriza o AV, especificando como *High*, desta forma, a regra atende a preferência e seu consequente é *High*.

A Tabela 7 apresenta os valores dos atributos de entrada antes e após sua normalização de 13 recursos que serão classificados com as regras geradas pelo método WM.

Tabela 7. Amostra com 13 Recursos do QWS Dataset

ID	Original			Normalizado			W
	RT	AV	TH	RT	AV	TH	
01	221,48	90	10,9	99,77	90	98,20	1
02	239,22	85	7,7	92,37	85	69,37	2
03	261,09	85	5,4	84,63	85	48,65	3
04	256,39	85	5,1	86,18	85	45,95	3
05	220,96	87	11,1	100	87	100	1
06	243,91	85	7,1	90,59	85	63,96	2
07	223,83	92	10,8	98,72	92	97,30	1
08	250,74	86	7	88,12	86	63,06	2
09	246,43	85	9,7	89,66	85	87,39	1
10	277,35	86	6,3	79,67	86	56,76	2
11	280,39	86	6,4	78,80	86	57,66	2
12	275,87	85	6,5	80,10	85	58,56	2
13	267,43	86	5,7	82,62	86	51,35	2

A classificação final dos recursos é feita empregando Ordens Admissíveis. Neste momento é efetuada uma compa-

ração de todos os intervalos (centroide inferior e centroide superior), identificando o melhor recurso como 1 e o pior recurso como 13, conforme a última coluna da Figura 3.

ID	Response Time(RT)	Availability (AV)	Throughput (TH)	Centróide Inferior	Centróide Superior	Classificação
1	99,77	90,00	98,20	81,05	83,86	2
2	92,37	85,00	69,37	60,27	69,59	5
3	84,63	85,00	48,65	52,45	62,45	9
4	86,18	85,00	45,95	52,81	63,09	8
5	100,00	87,00	100,00	81,09	83,89	1
6	90,59	85,00	63,96	58,35	63,85	6
7	98,72	92,00	97,30	80,90	83,75	3
8	88,12	86,00	63,06	57,51	62,70	7
9	89,66	85,00	87,39	79,40	82,65	4
10	79,67	86,00	56,76	53,90	58,96	12
11	78,80	86,00	57,66	53,47	58,68	13
12	80,10	85,00	58,56	54,10	59,11	11
13	82,62	86,00	51,35	53,40	60,77	10

Figura 3. Classificação Considerando a Preferência HLM

Assim, este cenário de uso demonstrou o quanto é importante empregar preferências conforme as demandas do cliente, para que os recursos ao serem classificados tenham uma maior precisão para o mesmo.

5. CONSIDERAÇÕES FINAIS

A classificação de recursos IoT, pode tornar-se complexa devido a grande quantidade de recursos. O cliente também pode apresentar incertezas quanto à relevância dos atributos de QoS de cada recurso que irá considerar. Desta forma, torna-se necessária a geração de regras Fuzzy para o tratamento desta incerteza.

Neste trabalho, foi apresentada a arquitetura de software da proposta IoT-DFR³, cuja principal contribuição está na automação de regras Fuzzy para classificação de recursos na IoT, considerando as preferências do cliente.

No cenário de uso foram apresentadas as regras geradas pelo método de Wang-Mendel para 2400 recursos e 3 atributos, alternando as preferências do cliente entre HHH, HLM e MHM. Qualificando assim, o emprego de preferências do cliente para obter uma precisão maior no momento de gerar as regras Fuzzy para a classificação de recursos na IoT, conforme as demandas do cliente. Um conjunto de 13 recursos foram classificados com a preferência do HLM.

Entende-se que estes resultados mostram-se promissores, uma vez que a proposta IoT-DFR³ propiciou a geração de Regras Fuzzy de forma automática, gerando uma classificação funcional a partir das mesmas. É oportuno destacar que também se observou uma redução significativa no número de regras, contribuindo assim, para uma melhor otimização da Base de Regras Fuzzy.

Dentre os trabalhos futuros, destaca-se a avaliação de outras abordagens para automação de regras para o sistema Fuzzy empregado na IoT-DFR³ e a concepção de uma ferramenta que centraliza os esforços de gerenciamento e visualização das regras Fuzzy geradas.

REFERÊNCIAS

- Al-Masri, E. and Mahmoud, Q.H. (2008). Investigating web services on the world wide web. In *Proceedings of the 17th international conference on World Wide Web*, 795–804.
- Belouaar, H., Kazar, O., and Kabachi, N. (2018). A new model for web services selection based on fuzzy logic. *Courrier du Savoir*, 1(26), 393–400.
- Cabrera, N. (2014). *Aplicação da Extensão de Zadeh para Conjuntos Fuzzy Tipo 2 Intervalar*. Ph.D. thesis, Universidade Federal de Uberlândia.
- Dilli, R., Argou, A., Pernas, A., Reiser, R., and Yamin, A. (2018). EXEHDA-RR : Uma proposta para tratar incertezas e otimizar o processo de classificação de recursos na IoT. *Simpósio Brasileiro de Computação Ubíqua - CSBC*.
- Ezenwoke, A. (2018). Fuzzy Hybrid Approach for Ranking and Selecting Services in Cloud-based Marketplaces. *Journal of Artificial Intelligence*, 11(1), 9–17.
- IHS Markit (2017). The Internet of Things: a movement, not a market.
- Khutade, P.A. and Phalnikar, R. (2014). QoS Aware Web Service Selection and Ranking Framework Based on Ontology. *International Journal of Soft Computing and Engineering (IJSCE)*, 4(3), 77–81.
- Kumar, R.R., Mishra, S., and Kumar, C. (2017). Prioritizing the solution of cloud service selection using integrated MCDM methods under Fuzzy environment. *Journal of Supercomputing*, 73(11), 4652–4682. doi:10.1007/s11227-017-2039-1.
- Mutlu, B., Sezer, E.A., and Akcayol, M.A. (2018). Automatic rule generation of fuzzy systems: A comparative assessment on software defect prediction. In *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, 209–214. IEEE.
- Santos, M. and Mendoza, B. (2018). Identificación borrosa de un cultivo experimental. In *XXXIX Jornadas de Automática*, 888–893. Área de Ingeniería de Sistemas y Automática, Universidad de Extremadura.
- Schenfeld, M.C., Amaral, L., de Matos, E., and Hessel, F. (2016). Arquitetura para fog computing em sistemas de middleware para internet das coisas. In *Anais do XLIII Seminário Integrado de Software e Hardware*, 199–209. SBC, Porto Alegre, RS, Brasil. doi:10.5753/semish.2016.9530.
- Silva, M.C.d.A. (2015). *Aplicação de um Sistema Fuzzy para Classificação de Opinião em Diferentes Domínios*. Ph.D. thesis, Instituto de Matemática. Departamento de Ciência da Computação.
- Tripathy, A.K. and Tripathy, P.K. (2018). Fuzzy QoS requirement-aware dynamic service discovery and adaptation. *Applied Soft Computing Journal*, 68(November), 136–146.
- Wang, L.X. and Mendel, J.M. (1992). Generating Fuzzy Rules by Learning from Examples. *IEEE Transactions on Systems, Man and Cybernetics*. doi:10.1109/21.199466.
- Xu, Z. and Yager, R.R. (2006). Some geometric aggregation operators based on intuitionistic fuzzy sets. *International Journal of General Systems*, 35(4), 417–433. doi:10.1080/03081070600574353.