



## MODELO DE INTERPRETABILIDADE LOCAL PAUTADO EM RANDOM FOREST PARA CLASSIFICAÇÃO DE USOS DOMÉSTICOS DE ÁGUA

Isabela Almeida de Souza<sup>1</sup>

Tarssio Brito Barreto<sup>2</sup>

Karla Patrícia Santos Oliveira Rodriguez Esquerre<sup>3</sup>

### Resumo

Ao se tratar do uso de recurso hídricos em nível doméstico entende-se que monitorar o consumo de água é crucial na gerência de consumo e desperdícios de água. É através do monitoramento que é possível traçar padrões capazes de auxiliar na governança dos recursos hídricos. Neste sentido surge a proposta de pesquisa na qual este trabalho se insere buscando compreender o uso intradomiciliar água de residências de bairros populares na cidade de Salvador, Bahia. Neste contexto, se propôs o uso da Random Forest para classificar estes consumos por equipamento hidráulico a partir da informação da vazão total. No entanto, dada a complexidade do algoritmo de Random Forest, a interpretação humana é comumente difícil, fazendo-o ter o rótulo de "caixa preta". Considerando a importância de que humanos confiem em algoritmos de aprendizado de máquina e os usem efetivamente, utilizou-se o LIME, um algoritmo capaz de realizar a interpretação local de um modelo complexo. Desta forma, busca-se demonstrar as variáveis mais importantes para o modelo a partir da interpretação local da modelagem de desagregação de dados de consumo de água no nível doméstico. A precisão do modelo de Random Forest foi de aproximadamente 75% para o grupo de teste e cerca de 80% para precisão balanceada. Conclui-se, então, que o algoritmo utilizado para a interpretabilidade do modelo possui boa aderência com a realidade esperada, produzindo boas heurísticas para uma possível classificação preliminar quando não se é possível obtê-las através da medição de todos aparelhos.

**Palavras-chave:** Consumo de água intradomiciliar, Random Forest, Lime.

### Abstract

When dealing with the household use of water resources, we understood that monitoring water consumption is crucial to the management of water consumption and waste. Through monitoring it is possible to trace standards capable of assisting in water governance. In this perspective, the research proposal in which this work is inserted aims to understand the household water use of residences from popular neighborhoods in the city of Salvador, Bahia, Brazil. In this context, we proposed to use Random Forests to classify these consumptions, by hydraulic equipment, using the total flow information. However, given the complexity of the Random Forest algorithm, human interpretation is commonly difficult, giving it the "black box" label. Considering the importance of humans trusting in machine learning algorithms and using them effectively, LIME was used given its capacity of performing a local

---

<sup>1</sup>Universidade Federal da Bahia (UFBA), almeida.isabela94@gmail.com

<sup>2</sup>Universidade Federal da Bahia (UFBA), tarssioesa@gmail.com

<sup>3</sup>Universidade Federal da Bahia (UFBA), karlaesquerre@ufba.br



interpretation of a complex model. Given the background, this paper aims to demonstrate the most important variables for the model from the local interpretation modeling of water consumption data disaggregation in a domestic level. The accuracy of the Random Forest model was approximately 75% for the test group and about 80% for balanced precision. We concluded, then, that the algorithm used for the interpretability of the model has good adherence to the expected reality, producing good heuristics for a possible preliminary classification when it is not possible to obtain them by measuring all the devices.

**Keywords:** Household water consumption, Random Forest, Lime.

## Introdução

No contexto do uso doméstico de recursos hídricos, monitorar o consumo de água por equipamento hidráulico fornece informações fundamentais para entender e gerir o consumo e perdas de água da concessionária ao consumidor. Isto por que, o monitoramento permite identificar padrões temporais e socioeconômicos que podem ser utilizados no desenvolvimento de políticas públicas ajustadas à realidade dos cidadãos e aprimorar a previsão da demanda de água, tornando a melhoria da governança da água transdisciplinar, intersetorial e resolutiva (Brasil, 2018). Em contrapartida, entende-se que a medição instrumentalizada em cada equipamento é economicamente inviável dado o número de equipamentos hidráulicos e residências envolvidos em se tratando da dimensão municipal.

Projetar e implementar estratégias efetivas de gerenciamento da demanda de água está se tornando cada vez mais importante para garantir o fornecimento confiável de água e reduzir os custos dos serviços públicos de água nos próximos anos. O advento dos medidores inteligentes disponibilizou novos dados de consumo de água em altíssima resolução espacial e temporal, permitindo uma descrição mais detalhada dos fatores que induzem as pessoas a consumir ou economizar água (Cominola, Giuliani, Piga, Castelletti, & Rizzoli, 2015). Sob esta perspectiva, este trabalho se insere em um projeto cujo objetivo é criar um medidor de consumo hídrico intradomiciliar que se adeque ao perfil de residências de baixa renda do Brasil e que seja capaz de desagregar os dados de consumo de água no nível doméstico para reduzir o processamento manual e as interações humanas intensivas exigidas pelos métodos atuais, utilizando dados coletados remotamente em residências dos bairros de Plataforma e Chapada do Rio Vermelho, na cidade de Salvador, Bahia (Aguar Filho, Mello, Esquerre, Botelho & Kiperstok, 2017).

Para a modelagem do problema optou-se por utilizar Random Forest, um classificador que produz diversas árvores de decisão aleatórias, semelhante ao CART (Classification and Regression Trees), em que cada árvore é cultivada com uma amostra bootstrap diferente



dos dados de treinamento e aproximadamente um terço dos dados de treinamento são omitidos na construção de cada árvore (Breiman, 2001). É, portanto, um algoritmo amplamente utilizado para classificação de dados de sensoriamento remoto (Millard and Richardson, 2015).

O modelos avançados de aprendizado de máquina, tais quais Random Forest, costumam apresentar resultados mais precisos, no entanto, são comumente interpretados como "caixas pretas" por conta do seu complicado funcionamento interno. A capacidade de interpretação do modelo é crucial para a adoção de negócios, documentação do modelo, supervisão regulatória e aceitação e confiança humanas. Sabendo-se que confiança é crucial para a interação humana efetiva com os sistemas de aprendizado de máquina e que explicar as previsões individuais é importante para avaliar a confiança, utiliza-se o LIME (Local Interpretable Model-agnostic Explanations) para determinar as regras de classificação mais importantes da modelagem em questão. LIME é um algoritmo que pode explicar as previsões de qualquer classificador ou regressor de uma maneira fiel, aproximando-o localmente com um modelo interpretável (Ribeiro, Singh & Guestrin, 2016).

No caso em questão, ao se tratar do consumo de água por aparelhos domésticos é intuitivo se pensar um padrão usual de consumo para este, principalmente aqueles que são mais dependentes da regulação por parte dos fabricantes, como bacia sanitária e máquina de lavar. O LIME, então, se adequa bem ao interpretar os resultados da Random Forest e buscar, de forma local, explicitar algumas das regras de classificação que podem balizar uma comparação entre estas e o padrão esperado destes aparelhos.

### **Objetivo**

O presente trabalho busca demonstrar as variáveis mais importantes para o modelo a partir da interpretação local da modelagem de desagregação de dados de consumo de água no nível doméstico.

### **Material e Método**

O banco de dados utilizado é constituído por medições da vazão realizadas a cada 10 segundos e registradas em uma residência localizada no bairro da Chapada do Rio Vermelho, na cidade do Salvador. As informações de vazão foram coletadas no período de novembro de 2011 até janeiro de 2012. Tal medição se deu através da instalação de registradores eletrônicos capazes de armazenar pulsos de resolução igual a 0,1 L/pulso, acoplados a um data logger para armazenamento dos dados. A instalação do equipamento de medição foi realizada na tubulação diretamente conectada a caixa d'água das residência.



A residência em questão conta com 12 pontos de água caracterizados, cada um, como Torneira Interna, Torneira Externa, Bacia Sanitária e Chuveiro.

As variáveis que compõem o banco de dados correspondem a categoria do equipamento hidráulico, mediana da vazão, volume total consumido, duração, pico de consumo, moda da vazão, média da vazão e o número de vezes que a vazão corresponde à moda da vazão.

A modelagem da classificação foi realizada através de Random Forest. Este algoritmo é uma ferramenta eficaz na predição, além de serem capazes de evitar sobreajustes, possuir erro convergente, conforme aumenta-se a complexidade do modelo, são capazes de fornecer métricas quanto a qualidade de sua predição e evidenciam a importância relativa de cada uma das variáveis para o modelo final (Breiman, 2001). Caracteriza-se por um algoritmo de aprendizado supervisionado através de um conjunto de árvores de decisão treinadas com subconjuntos das variáveis e observações disponíveis para treinamento com o objetivo de garantir a independência entre as árvores de decisão na predição da floresta (Louppe, 2014).

A interpretação local do algoritmo criado foi realizada através do LIME. O funcionamento do LIME se baseia no pressuposto de que todo modelo complexo é linear em escala local. O LIME então leva essa suposição à sua conclusão natural, afirmando que é possível encaixar um modelo simples em torno de uma única observação que imitará como o comportamento do modelo global naquela localidade. O modelo simples pode então ser usado para explicar as previsões do modelo mais complexo localmente (Pedersen & Benesty, 2018).

Primeiramente, foi separado 5% dos dados de forma estratificada, a fim de manter a mesma proporção dos dados obtidos no banco de dados original, estes dados alimentaram, em momento posterior o LIME. Na etapa da modelagem, optou-se por se utilizar 80% dos dados para o treino e foi realizada a validação cruzada através de dez *k-folds*. O modelo foi criado no pacote *caret* através do algoritmo *ranger*.

Os 5% dos dados separados no início foram testados no algoritmo LIME e foram escolhidas as cinco observações que obtiveram os melhores resultados neste. Por fim, as regras obtidas pelo LIME foram testadas, através da probabilidade associada a estes como classificadores de determinado aparelho, como possíveis heurísticas que auxiliassem uma pré-classificação dos usos.



O modelo foi construído com auxílio da linguagem de programação R (R Core Team, 2018). O pacote *caret*(Kuhn, 2019) foi utilizado como suporte a modelagem e o pacote *LIME*(Ribeiro et al., 2016) ofereceu suporte para a interpretação do modelo criado.

## Resultados e Discussão

Quanto ao resultado da Random Forest, obteve-se, através da validação cruzada, mtry igual a 2. A precisão do modelo foi de aproximadamente 75% para o grupo de teste, ao se pensar na precisão balanceada, visto que os dados não estão na mesma proporção no modelo, observa-se como resultado cerca de 80%, exceto para torneiras internas.

Outra questão interessante é que o modelo gerado possui alta especificidade, para todas as classes exceto torneira inteira, e baixa sensibilidade. Sendo possível inferir que o modelo criado tem alto poder de detectar verdadeiros negativos, ou seja, tem um bom poder de detectar quando um aparelho não é aquele que está em uso.

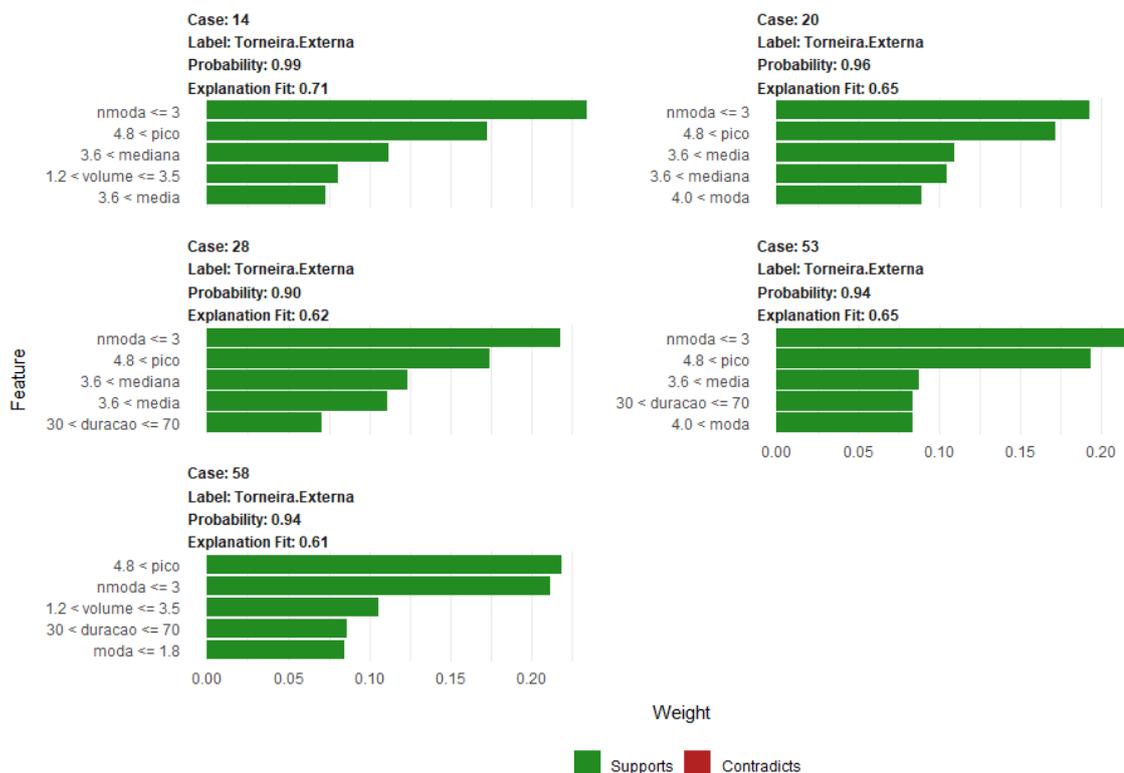


Figura 1 – Importância das variáveis na classificação de Torneira Externas.



**Tabela 1 - Probabilidade que dado uma destas características se obtenha aleatoriamente uma torneira externa em porcentagens.**

Condição	Torneira Externa	
	Taxa de Acertos (%)	Taxa de Erros (%)
Pico > 4.8	57	43
Média > 3.6	48	52
Moda > 4,0	46	54
Nmoda ≤ 3.0	57	43
30s < Duração ≤ 70s	33	67
1.2 L < Volume ≤ 3.5 L	59	41
Mediana > 3.6	48	52

Para as torneiras externas, observa-se na Figura 1 e na Tabela 1 as principais variáveis, bem como a probabilidade que dado uma destas características se obtenha aleatoriamente uma torneira externa.

Destaca-se as seguintes características: pico > 4,0 litros; volume entre 1,2 e 3,5 litros e nmoda < 3,0. Os resultados concordam com a realidade observada, uma vez que o uso das torneiras externas tem funções ligadas a limpeza e a lavagem de roupa, possuindo picos de vazão elevados, mas pouco volume utilizado, uma vez que esta água, geralmente é utilizada para encher recipientes que armazenam água para os propósitos indicados acima.

A Taxa de Erro de 68% para a Duração, mostrada na Tabela 1, a priori caracteriza uma alta taxa de erro. No entanto, faz-se interessante ressaltar que, esta porcentagem representa a soma das probabilidades de que, dada tal característica, se obtenha aleatoriamente qualquer outro equipamento hidráulico considerado pelo modelo que não seja uma torneira interna. Logo, taxas de acerto abaixo de 40% ainda podem ser consideradas satisfatórias. Esta interpretação é válida para todas as características.

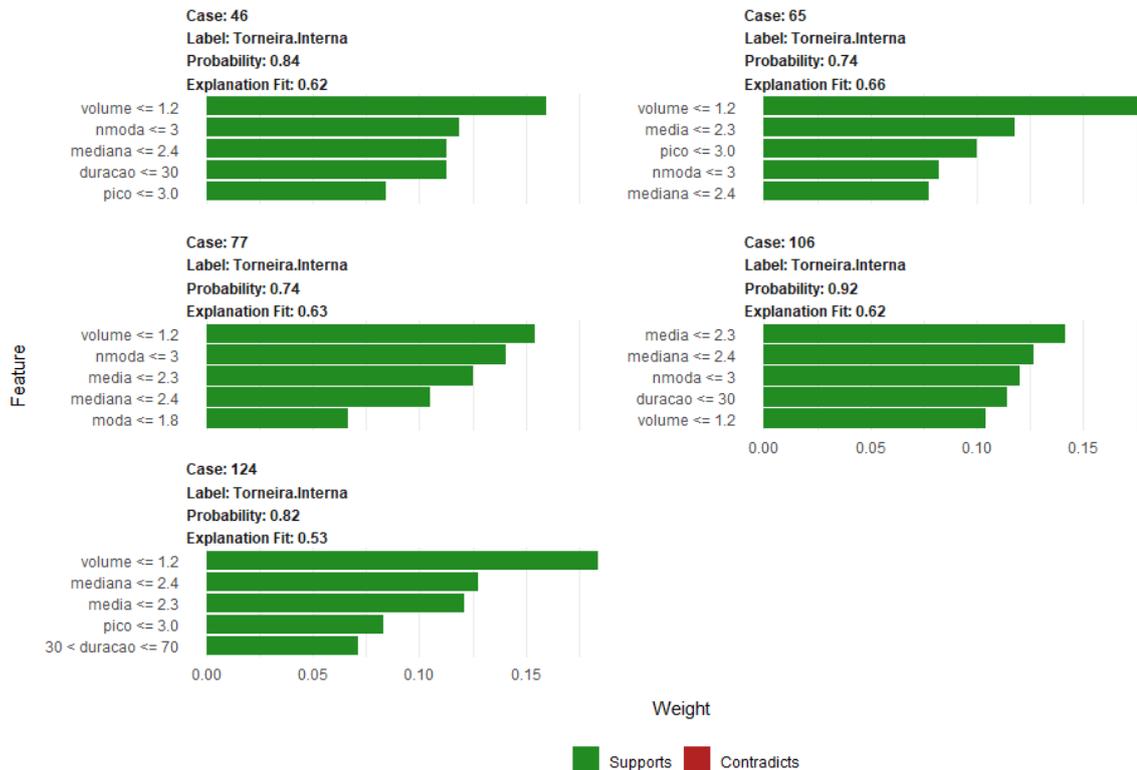


Figura 2 – Importância das variáveis na classificação de Torneira Internas.

Tabela 2 - Probabilidade que dado uma destas características se obtenha aleatoriamente uma torneira interna em porcentagens.

Torneira Interna		
Condição	Taxa de Acertos (%)	Taxa de Erros (%)
Volume $\leq$ 1,2L	90	10
Média $\leq$ 2,3	70	30
Nmoda $\leq$ 3,0	62	38
Mediana $\leq$ 2,4	75	25
Pico $\leq$ 3,0	82	18
Duração $\leq$ 30 s	82	18

Para as torneiras internas, observa-se na Figura 2 e na Tabela 2 as principais variáveis, bem como a probabilidade que dado uma destas características se obtenha aleatoriamente uma torneira interna.

Destaca-se as seguintes características: volume menor ou igual 1,2 litros; mediana menor ou igual a 2,4 e nmoda menor ou igual 3. Os resultados concordam com a realidade



observada, uma vez que o uso das torneiras internas tem funções ligadas a limpeza, cozinha e a higiene pessoal, possuindo pouco volume repetidas vezes, uma vez que esta água, geralmente é utilizada para tarefas que necessitam de pouca quantidade de água para os propósitos indicados acima. Observa-se ainda, através da Tabela 2, que a probabilidade que dado uma destas características se obtenha aleatoriamente uma torneira interna é alta, chegando a 90% dos casos.

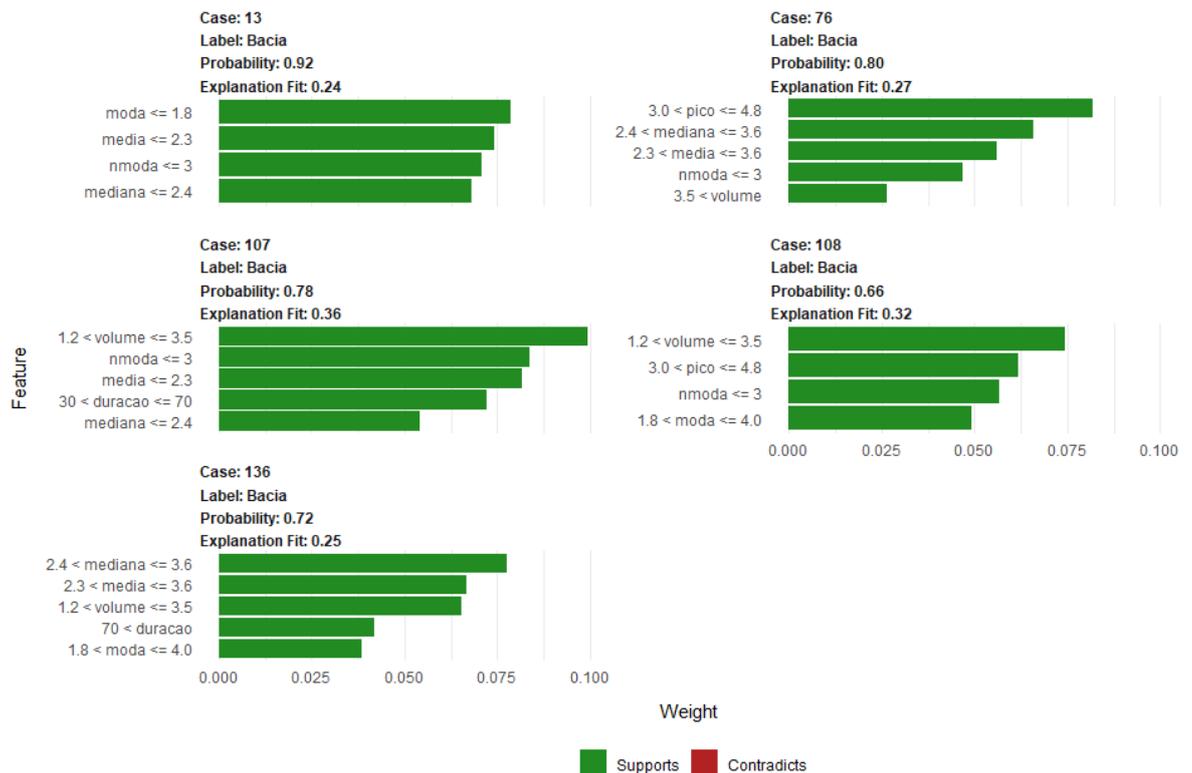


Figura 3 – Importância das variáveis na classificação de Bacias Sanitárias.

Tabela 3 - Probabilidade que dado uma destas características se obtenha aleatoriamente uma bacia sanitária em porcentagens.

Condição	Bacia	
	Taxa de Acertos (%)	Taxa de Erros (%)
Duração > 30	53	47
Média ≤ 3,6	28	72
Volume > 1,2 L	49	51
Nmoda ≤ 3	04	96



Quanto a bacia, pode se observar na Figura 3 e na Tabela 3 quais as características mais relevantes segundo o LIME. Porém, ao se observar as probabilidades de ser uma boa heurística apenas a duração ser maior que 30 segundos se destacou. Pensando que a bacia sanitária é um aparelho regulado pelo fabricante e que ao longo do tempo vai perdendo um pouco desta especificação, pode-se inferir que é possível haver uma certa regularidade quanto ao seu tempo de acionamento, fato que nenhum dos outros aparelhos desta casa possui, por serem aparelhos onde a duração é determinada pelo uso.

Quanto as outras características, pode-se esperar que haja pouca especificidade, uma vez que o uso dos outros aparelhos podem, por vezes, ter padrões de pico e volume semelhantes à bacia sanitária.

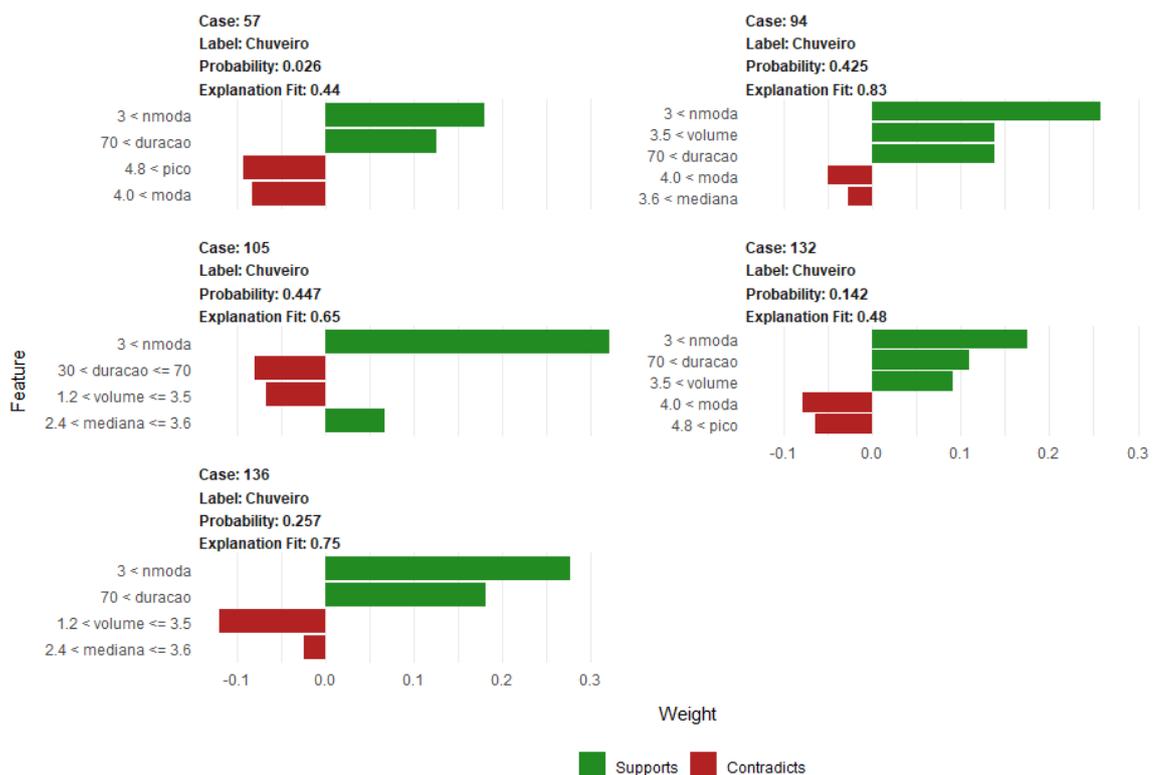


Figura 4 – Importância das variáveis na classificação de Chuveiros.



**Tabela 4 - Tabela 1 - Probabilidade que dado uma destas características se obtenha aleatoriamente um chuveiro em porcentagens.**

Condição	Chuveiro	
	Taxa de Acertos (%)	Taxa de Erros (%)
Nmoda > 3,0	48	52
Volume > 1,2 L	61	39
Duração > 30 s	43	57
Moda > 4,0	34	66
Pico > 4.8	36	64

Para os chuveiros, observa-se na Figura 4 e na Tabela 4 as principais variáveis, bem como a probabilidade que dado uma destas características se obtenha aleatoriamente chuveiro.

Destaca-se as seguintes características: nmoda maior que 3; duração maior que 30 segundos e volume maior que 1,2 litros. Os resultados concordam com a realidade observada, uma vez que o uso de chuveiro tem funções ligadas à higiene pessoal, possuindo repetições e durações regulares de acordo com o costume do usuário.

### **Conclusão**

O modelo proposto para a classificação dos usos domésticos de água apresentou um bom resultado, cerca de 75% de precisão geral. Este resultado, a princípio, é de grande valia, uma vez que os usos domésticos, em residências onde se têm poucos pontos de água, pode não apresentar padrões muito claros.

Quanto ao uso do LIME, encontrou-se boas respostas para alguns dos usos, principalmente, para as torneiras internas que, geralmente, são utilizadas para lavar mão, cozinhar e usos menos volumétricos, quando comparado aos demais.

As possíveis regras obtidas com este modelo foram condizentes com a realidade esperada, sendo, então, uma possível abordagem para criação de heurísticas que facilitem a classificação dos usos em uma etapa preliminar.

O ambiente de programação R foi de grande valia neste processo, fornecendo ferramentas para a manipulação, modelagem e interpretação dos dados.



## Referências

AGUIAR FILHO, A.M.; MELLO, M.S.; ESQUERRE, K.; BOTELHO, G. KIPLERSTONE, A. Identificação De Perfil De Consumo De Água Domiciliar Por Equipamento Hidráulico E Modo De Uso Via Fuzzy-Clustering Como Ferramenta De Gestão De Recursos Hídricos No Ambiente Urbano. Congresso da Abes. São Paulo. 2017

BRASIL. Declaração do Ministério Público sobre o Direito à Água. In: FÓRUM MUNDIAL DA ÁGUA, 8., 2018, Brasília Anais eletrônicos... Brasília: EMSPU, 2018. Disponível em: <<http://www.mpf.mp.br/pgf/>> Acesso em 4 e abril de 2018.

BREIMAN, L. Random Forests. *Mach. Learn.* 2001, 45, 5–32.

COMINOLA, A., GIULIANI, M., PIGA, D., CASTELLETTI, A., & RIZZOLI, A. E. (2015). Benefits and challenges of using smart meters for advancing residential water demand modeling and management: A review. *Environmental Modelling & Software*, 72, 198–214. doi:10.1016/j.envsoft.2015.07.012

Hadley Wickham (2017). tidyverse: Easily Install and Load the 'Tidyverse'. R package version 1.2.1. <https://CRAN.R-project.org/package=tidyverse>

LOUPPE, G. (2014). Understanding Random Forests, (July), 1–225. <https://doi.org/10.13140/2.1.1570.5928>

Max Kuhn. Contributions from Jed Wing, Steve Weston, AndreWilliams, Chris Keefer, Allan Engelhardt, Tony Cooper, Zachary Mayer, Brenton Kenkel, the R Core Team, Michael Benesty, Reynald Lescarbeau, Andrew Ziem, Luca Scrucca, Yuan Tang, Can Candan and Tyler Hunt. (2018). caret: Classification and Regression Training. R package version .0-80. <https://CRAN.R-project.org/package=caret>

MILLARD, K., & RICHARDSON, M. (2015). *On the Importance of Training Data Sample Selection in Random Forest Image Classification: A Case Study in Peatland Ecosystem Mapping. Remote Sensing*, 7(7), 8489–8515. doi:10.3390/rs70708489

R Core Team (2018). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

RIBEIRO, M. T.; SINGH, S.; GUESTRIN, C. “Why should I trust you?”: explaining the predictions of any classifier. *Arxiv*, New York, v. 1, 9 ago. 2016.

Thomas Lin Pedersen and Michaël Benesty (2018). lime: Local Interpretable Model-Agnostic Explanations. R package version 0.4.1. <https://CRAN.R-project.org/package=lime>



IV SEMINÁRIO INTERNACIONAL DE ESTATÍSTICA COM R  
R & PYTHON E AS TENDÊNCIAS DE COLABORAÇÃO  
NITERÓI, 21 A 23 DE MAIO DE 2019



**Anexo**

O script de comandos em R está disponível em:  
[https://github.com/tarssioesa/LIME\\_AGUA](https://github.com/tarssioesa/LIME_AGUA)