

UMA ARQUITETURA IOT BASEADA EM FIWARE PARA DETECÇÃO DE ANOMALIAS NA AGRICULTURA

João Victor Fernandes de Souza¹, Guilherme Wachs Lopes²

^{1,2} *Ciência da Computação, Centro Universitário da FEI*

unifjsouza@fei.edu.br, gwachs@fei.edu.br

Resumo: A aplicação das tecnologias de *IoT* no setor agrícola deu origem ao fenômeno do Smart Farming (SF), e permitiu um melhor gerenciamento de recursos naturais, garantindo benefícios ao setor em geral. Os dispositivos *IoT* usados, geralmente estão em campo aberto, logo, é fundamental que se possa detectar anomalias nos dados de entrada. Portanto, esse trabalho propõe uma plataforma *IoT* para detecção de anomalias na agricultura, baseada em informações sensoriais de temperatura e umidade providas de solos para cultivo.

1. Introdução

Atualmente, o crescimento das tecnologias ligadas à Internet das Coisas tem possibilitado a captação e processamento de grandes volumes de dados dos mais diversos tipos de sensores, o que permite a manipulação destas informações em cenários computacionais distribuídos e complexos.

Com esse crescimento, diversos ramos da indústria foram beneficiados, como é o caso do setor agrícola. Neste cenário, pode-se observar recentemente uma maior taxa de implementação do cultivo sensoreado e assistido por dispositivos conectados à internet, este fenômeno foi denominado como Smart Farming (SF) [1], e impactou positivamente a produtividade agrícola em geral, permitindo melhorias no gerenciamento de recursos naturais e hídricos pela falta de rastreabilidade dos terrenos. Isso representa uma relevante alteração no processo rural tendo em vista que este setor é responsável pelo consumo de até 70% da água potável no Brasil [3].

Apesar do acentuado desenvolvimento da *IoT*, ainda não existe um consenso na literatura acerca da arquitetura de software a ser utilizada para disponibilizar as informações dos dispositivos. Além disso, parece que a tecnologia de microsserviços pode contribuir para a área. Finalmente, uma vez que esses dispositivos estão em campo aberto – na maioria das vezes – é fundamental ter um modelo capaz de detectar anomalias nos dados de entrada.

Nesse trabalho, propomos uma plataforma *IoT*, com base no sistema FIWARE, para Detecção de Anomalias na agricultura, analisando dados contextuais de umidade e temperatura providas de sensores dos solos para cultivo, para isso utilizando uma arquitetura de microsserviços.

2. Detecção de Anomalias

Detecção de anomalia consiste em encontrar padrões nos dados que não se adequam a um comportamento esperado. Essa área também pode ser encontrada com o nome de *Outlier Detection* [2]. Dentre suas principais aplicações estão: a detecção de tumores malignos, do

uso indevido de cartões de crédito, do envio de dados sensíveis a redes não autorizadas, entre outras.

O problema de detecção de anomalias também pode ser visto como um classificador binário entre as classes “normal” e “anormal”. Outra interpretação deste conceito é a remoção de ruídos, uma vez que esses não fazem parte do conjunto “normal” de dados. Para essa tarefa existem diversos modelos computacionais disponíveis.

O problema de detecção de anomalias abordado nesse trabalho utilizará um modelo para detecção baseado em informações contextuais. Essa forma de detecção considera que parte dos dados de entrada pode ou não ser uma anomalia, dependendo do contexto no qual aparecem.

Na detecção de anomalias condicional, dois conjuntos de atributos são definidos:

- a) Atributos contextuais: utilizados para definir o contexto em que um dado ocorre.
- b) Atributos Comportamentais: são atributos que não pertencem ao conjunto contextual.

Em [4], os autores descrevem um método para detecção de anomalias em séries temporais. O modelo proposto segregava os dados de treinamento em conjuntos, os quais são usados para a construção de um autômato capaz de validar se uma sequência de estados é válida ou não.

3. Metodologia

A arquitetura proposta por este trabalho baseia-se no uso do FIWARE como plataforma agregadora dos dados.

Para a construção da arquitetura foram utilizados 3 dos módulos disponibilizados pelo FIWARE, junto com uma base de dados relacional e uma não relacional, sendo estes:

i) *IoT Agent*: responsável por receber e transmitir os dados de sensores e atuadores. Disponibiliza interfaces para diversos protocolos e converte as informações captadas para o formato NGSI, utilizado pelos demais componentes.

ii) *Orion Context Broker*: principal serviço da plataforma. Nele são criadas as entidades do sistema, que são armazenadas na base MongoDB. Pode-se utilizar também sua funcionalidade de subscrições para conectar os demais serviços da plataforma.

iii) *Draco*: gerencia dados temporais. Esse componente utiliza o sistema de subscrições do *Context Broker* para ser notificado quando uma entidade é atualizada e armazena os dados históricos em uma instância do MySQL.

iv) *MongoDB*: base de dados não relacional. É responsável por armazenar as informações do *Orion Context Broker*.

v) MySQL: base de dados relacional utilizada para o armazenamento e consulta de dados temporais.

A Figura 1 ilustra o fluxo de informações dentro da arquitetura proposta.

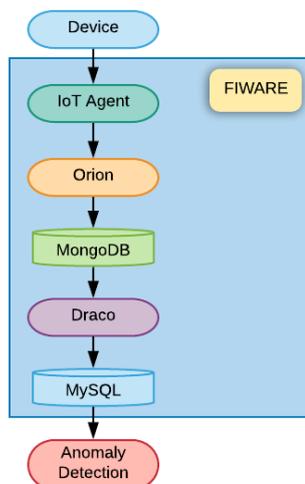


Figura 1 – Fluxo de dados na arquitetura proposta.

O fluxo se inicia através da captação dos dados transmitidos pelos sensores instalados no laboratório IoT-FEI. A transmissão dos dados pode ser feita através do protocolo REST ou através do protocolo ULTRALIGHT 2.0. Esses dados são enviados ao IoT-Agent, o qual é responsável por gerenciar a escrita de dados de cada dispositivo na plataforma.

O IoT-Agent traduz os dados para o formato NGSI e transmite para o Orion. Uma vez que as entidades de Temperatura ou Umidade forem alteradas no Orion, o sistema de subscrições transmitirá os novos valores ao Draco, que fará a persistência do histórico destas informações no banco de dados MySQL. Esse armazenamento é fundamental para que posteriormente seja realizado o treinamento do modelo para detecção de anomalias.

O serviço de detecção de anomalias requisita os dados do MySQL e treina um modelo de redes neurais com as informações contextuais. Para o sensor de temperatura, os atributos contextuais são compostos pelo valor da umidade e suas últimas 5 medições. Já para o sensor de umidade, os atributos contextuais são compostos pela temperatura e suas últimas 5 medições.

A arquitetura da rede neural proposta será composta de uma camada RELU seguida por uma camada SOFT-MAX para classificação. O treinamento e execução se dará através do Tensor Flow, um *framework* muito utilizado para redes neurais.

4. Resultados Parciais

A arquitetura proposta foi inicialmente testada com a utilização do servidor disponível no laboratório IoT-FEI. Para isso foram criadas 5 máquinas virtuais no servidor, sendo cada uma responsável por executar um container Docker com a imagem de seu respectivo serviço do FIWARE. Todas as máquinas virtuais foram interconectadas por meio de uma sub-rede criada no servidor. Para validação da captura de dados pelo sistema, um *probe* foi construído com auxílio de outros

alunos do laboratório de IoT. O dispositivo construído contava com sensores de luminosidade, temperatura do ar, temperatura do solo, umidade do ar e umidade do solo. As informações coletadas foram processadas com o uso de uma placa *Raspberry Pi* e então enviadas para o IoT Agent via JSON. Para acompanhamento dos dados recebidos pela plataforma, um sexto componente do FIWARE foi adicionado à arquitetura, o Grafana, o qual disponibiliza ferramentas para construção de gráficos e dashboards gerenciais. A Figura 2 ilustra a arquitetura final construída.

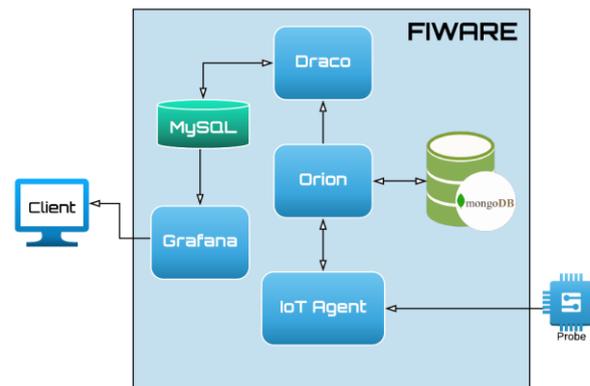


Figura 2 – Arquitetura do projeto

Após a validação da arquitetura, todos os serviços foram transferidos para o servidor público da FEI, dessa vez sem a criação das máquinas virtuais. Para facilitar o gerenciamento dos containers utilizados foi adicionada a ferramenta Docker-Compose, que permite a automação da criação e execução de serviços em baseados na plataforma Docker.

Como próxima etapa para continuação deste projeto, será desenvolvido o serviço de detecção de anomalias com uso de dados contextuais coletados pela plataforma desenvolvida.

5. Referências

- [1] AMANDEEP et al. Smart farming using IOT. 2017 8th IEEE Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), p. 278–280, 2017.
- [2] CHANDOLA, Varun; BANERJEE, Arindam; KUMAR, Vipin. Anomaly detection: A survey. *ACM Comput. Surv.*, v. 41, 15:1–15:58, 2009.
- [3] KAMIENSKI, Carlos et al. SWAMP: an IoT-based Smart Water Management Platform for Precision Irrigation in Agriculture. 2018 Global Internet of Things Summit (GIoTS), p. 1–6, 2018.
- [4] SALVADOR, Stan; CHAN, Philip. Learning States and Rules for Detecting Anomalies in Time Series. *Applied Intelligence*, v. 23, n. 3, p. 241–255, dez. 2005. Disponível em: <<https://doi.org/10.1007/s10489-005-4610-3>>.

Agradecimentos

À instituição Centro Universitário FEI pelo financiamento e infraestrutura necessária

¹ Aluno de IC do Centro Universitário FEI. Projeto com vigência de 04/19 a 03/20.