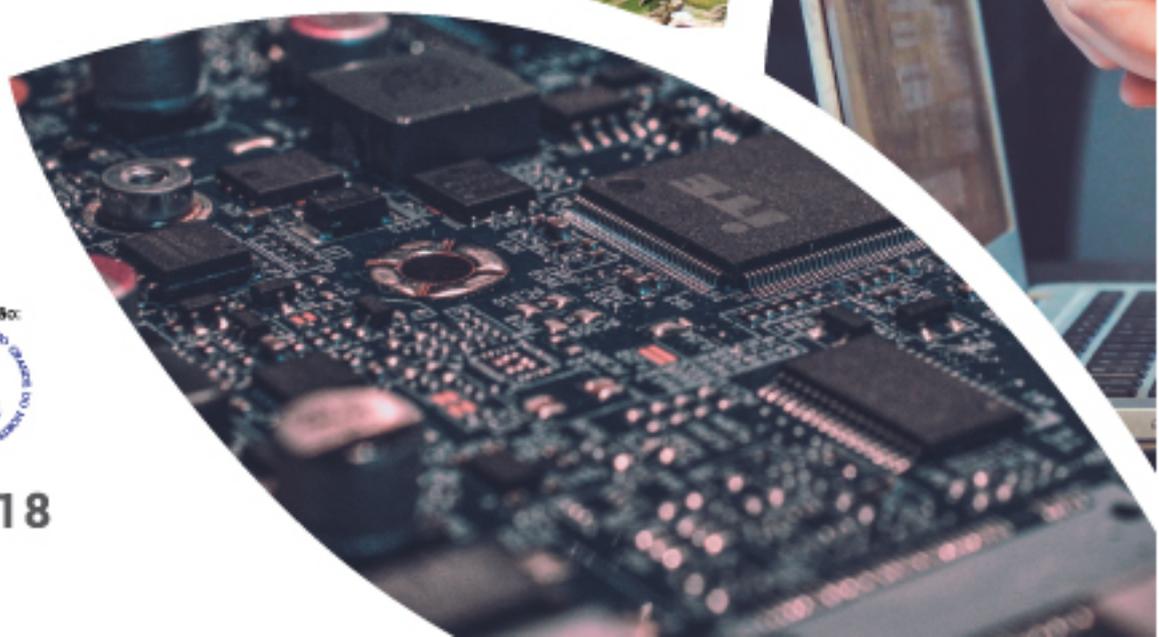


# anais 2018

XXXVIII CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO  
45º SEMISH – SEMINÁRIO INTEGRADO DE SOFTWARE E HARDWARE  
CENTRO DE CONVENÇÕES | NATAL•RN | 22 A 26 DE JULHO DE 2018  
#COMPUTAÇÃOESUSTENTABILIDADE



NATAL, 2018

# cnais 2018

XXXVIII CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO  
CENTRO DE CONVENÇÕES | NATAL•RN | 22 A 26 DE JULHO DE 2018  
#COMPUTAÇÃOESUSTENTABILIDADE



## **Coordenador Geral**

Francisco Dantas de Medeiros Neto (UERN)

## **Comissão Organizadora**

Bartira Paraguaçu Falcão Dantas Rocha (UERN)

Camila Araújo Sena (UERN)

Everton Ranielly de Sousa Cavalcante (UFRN)

Felipe Torres Leite (UFERSA)

Ilana Albuquerque (UERN)

Isaac de Lima Oliveira Filho (UERN)

Priscila Nogueira Krüger (UERN)

## **Realização**

Sociedade Brasileira de Computação

## **Organização**

Universidade do Estado do Rio Grande do Norte

# **CSBC 2018**

## **XXXVIII Congresso da**

### **Sociedade Brasileira de Computação**

#### **Apresentação**

Estes anais registram os trabalhos apresentados durante o XXXVIII Congresso da Sociedade Brasileira de Computação (CSBC 2018), realizado em Natal-RN, de 22 a 26 de julho 2018. O evento teve como tema central a Computação e Sustentabilidade, pois se compreende que o avanço da computação e as questões ambientais devem caminhar lado-a-lado, tendo em vista que as técnicas computacionais necessitam ser usadas para possibilitar o desenvolvimento sustentável, e, desse modo, equilibrar as necessidades ambientais, econômicas e sociais.

Organizar o maior evento acadêmico de Computação da América Latina foi um privilégio e um desafio. Foi enriquecedor promover e incentivar a troca de experiências entre estudantes, professores, profissionais, pesquisadores e entusiastas da área de Computação e Informática de todo o Brasil. Ao mesmo foi desafiador termos que lidar, principalmente, com às dificuldades impostas pelo momento de crise que o nosso Brasil vem enfrentando. Uma crise que afeta diretamente nossas pesquisas e, conseqüentemente, o desenvolvimento e inovação do nosso amado Brasil.

Por meio de seus 25 eventos, o CSBC 2018 apresentou mais de 300 trabalhos, várias palestras e mesas-redondas. O Congresso ainda abrigou diversas reuniões, que incluem a reunião do Fórum de Pós-Graduação, a reunião do CNPq/CAPES, a reunião dos Secretários Regionais SBC, a reunião das Comissões Especiais e a reunião do Fórum IFIP/SBC.

O sucesso do CSBC 2018 só foi possível devido à dedicação e entusiasmo de muitas pessoas. Gostaríamos de agradecer aos coordenadores dos 25 eventos e aos autores pelo envio de seus trabalhos. Além disso, gostaríamos de expressar nossa gratidão ao Comitê Organizador, por sua grande ajuda em dar forma ao evento; e, em especial, à equipe da Sociedade Brasileira de Computação (SBC), por todo apoio.

Por fim, reconhecemos a importância do apoio financeiro da CAPES, do CNPq, do CGI.br, do Governo do Estado do Rio Grande do Norte, da Prefeitura Municipal do Natal, da Prefeitura Municipal de Parnamirim, da CABO Telecom, da ESIG Software e Consultoria, da DynaVideo e do SENAI.

Natal (RN), 26 de julho de 2018.

**Chico Dantas (UERN)**  
Coordenador Geral do CSBC 2018

**Anais do CSBC 2018**

**45° SEMISH – SEMINÁRIO INTEGRADO DE  
SOFTWARE E HARDWARE**

## **Coordenação Geral**

José Marcos Silva Nogueira (UFMG)

## **Coordenação Local**

Anderson Abner (UERN)

## **Comitê de Programa**

- Andrey Ricardo Pimentel, UFPR
- Antonio Alberti, INATEL
- Antonio Lopes Apolinário Júnior, UFBA
- Celso Alberto Saibel Santos, UFES
- Cláudia Linhares Sales, UFC
- Cristiano Maciel Silva, UFSJ
- Edison Ishikawa, UNB
- Edson Norberto Cáceres, UFMS
- Eduardo Cunha de Almeida, UFPR
- Edward David Moreno Ordonez, UFS
- Eliana Silva de Almeida, UFAL
- Fabíola Nakamura, UFAM
- Fernando S. Osório, USP-SCAR
- Heloisa de Arruda Camargo, UFSCar
- José Augusto Suruagy Monteiro, UFPE
- Jose Marcos Nogueira, UFMG – Coordenador
- José Maria Nazar David, UFJF
- Kelly Rosa Braghetto, USP
- Kiev Gama, UFPE
- Liliane dos Santos Machado, UFPB
- Luis Rivero, UFAM
- Márcia Ito, IBM
- Marco Antonio Casanova, PUC-RIO
- Plácido Rogério Pinheiro, UNIFOR
- Rosiane de Freitas Rodrigues, UFAM
- Simone de Lima Martins, UFF
- Taisy Weber, UFRGS
- Thais Vasconcelos Batista, UFRN
- Wagner Meira, UFMG

## SUMÁRIO

<b>Cara de Aprender: Uma Ferramenta para Trabalhar Emoções e Aprendizagem utilizando Expressões Faciais.</b>	7
Carla Marina C. Paxiúba, Celson Pantoja Lima	
<b>Classifying Smart IoT Devices for Running Machine Learning Algorithms.</b>	18
Aluizio Rocha Neto, Bárbara Soares, Felipe Barbalho, Luis Santos, Thais Batista, Flávia C. Delicato, Paulo F. Pires	
<b>Estratégias para a Redução de Consumo e Aumento de Confiabilidade em IoT.</b>	30
Ricardo Reis	
<b>Controladores, Tratamentos de Sinais e Programação Aplicados à Piscicultura.</b>	42
Gabriel Oliveira Ferreira, Luís Filipe Pereira Silva	
<b>EstAcqua: Proposta de solução integrada de Hardware, Software e Internet das Coisas para monitoramento ambiental.</b>	53
Alan Afif Helal, Roberto Colistete Júnior, Fábio da Cunha Garcia, Gilberto Fonseca Barroso, Rodolfo da Silva Villaça	
<b>Uma Contribuição à Ciência de Contexto no Middleware EXEHDA Explorando Fog-Computing.</b>	65
Leonardo João, Verônica Tabim, Anderson Cardoso, Roger Machado, João Lopes, Gerson Cavalheiro, Ana Marilza Pernas, Adenauer Yamin	
<b>SoyRetrieval - Técnicas de Aprendizado e Recuperação de Imagens para Análise do Vigor de Sementes de Soja.</b>	77
Rafael S. Bressan, Marcelo de Souza Junior, Douglas F. Pereira, Pedro H. Bugatti, Priscila T. M. Saito	
<b>Extração de dados de fontes textuais: uma abordagem para enriquecimento de dados abertos interligados.</b>	89
Karen Torres Teixeira (UFRJ), Maria Luiza Machado Campos (UFRJ), João C. P. da Silva (UFRJ)	
<b>Sustentabilidade de Foto-memórias na Era Digital: Desafios e Oportunidades para a Computação.</b>	101
Paulo L. S. Brizolar, Leonardo Cunha de Miranda	
<b>Rumo à melhoria de produtividade e sustentabilidade agrícola por meio da classificação automática do vigor de sementes de soja.</b>	113
Marcelo de Souza Junior, Rafael S. Bressan, Douglas F. Pereira, Priscila T. M. Saito, Pedro H. Bugatti	

# Cara de Aprender – Uma Ferramenta para Trabalhar Emoções e Aprendizagem Utilizando Expressões Faciais

Carla Marina C. Paxiúba<sup>1</sup>, Celson Pantoja Lima<sup>1</sup>

<sup>1</sup>Programa de Computação– Universidade Federal do Oeste do Pará (UFOPA) – Santarém, PA - Brasil

{[Carla.paxiuba@ufopa.edu.br](mailto:Carla.paxiuba@ufopa.edu.br), [celson.lima@ufopa.edu.br](mailto:celson.lima@ufopa.edu.br)}

**Abstract.** *Nowadays is widely accepted that emotions significantly influence the learning process, but how to recognize the student's emotions, and how to relate the various types of emotions to learning, remains an open question. This article presents a tool that uses the student's emotions to improve the teaching-learning process. Students' facial expressions are automatically obtained through a facial expression recognition tool - Learning Face. Thus, it is possible to establish relationships between facial expressions, emotions, teaching methodologies and student performance.*

**Resumo.** *Atualmente é amplamente aceito que as emoções influenciam significativamente no processo de aprendizagem, porém, como reconhecer as emoções dos alunos, e, como relacionar os vários tipos de emoções com a aprendizagem, continua a ser uma questão em aberto. Este artigo apresenta uma ferramenta que utiliza as emoções do aluno para melhorar o processo de ensino-aprendizagem. As expressões faciais dos alunos são automaticamente obtidas através de uma ferramenta de reconhecimento de expressões faciais – Cara de Aprendizagem - CADAP. Assim, é possível estabelecer relações entre expressões faciais, emoções, metodologias de ensino e desempenho dos estudantes.*

## 1. Introdução

Vários estudos apontam que a emoção está constantemente associada ao aprendizado [Damasio,1994]. Entende-se também que as emoções podem influenciar fortemente o conhecimento e os objetivos gerais dos alunos [Piaget, 1989]. A conexão entre aprendizado complexo e emoções tem sido bem documentada em várias disciplinas relacionadas, como psicologia [Vygotsky,1994], educação [Mora, 2013] e ciência da computação [Picard, 1997]. Mora (2013) diz que tudo o que promove a aquisição de conhecimento, como curiosidade, atenção, memória para tomada de decisão, requer a energia que conhecemos como emoção. Detectar problemas relacionados à emoção pode se tornar um trabalho central para o futuro da educação. O trabalho de Izard (1984) mostra que as emoções negativas induzidas prejudicam o desempenho em tarefas cognitivas, e as emoções positivas têm um efeito oposto. Reconhecendo o papel significativo das emoções, Picard (1997) explica a necessidade de monitorar sinais emocionais e como isso está presente com os seres humanos quando ela afirma:

"Qualquer que seja sua estratégia, o bom professor detecta importantes pistas afetivas do aluno e responde de maneira diferente por causa delas. Por exemplo, o professor pode deixar dicas ou pistas sutis para o aluno descobrir, preservando assim o senso de descoberta autopropulsionada do aprendiz. Se o assunto envolve expressão emocional deliberada, como é o caso da música, ou é um tópico "não emocional" como a ciência, o professor que atende ao interesse, ao prazer e ao sofrimento do aluno é percebido como mais eficaz do que o professor que não faz isso. Bons professores sabem que a frustração geralmente precede o desistir e sabem como redirecionar ou motivar o aluno nesses momentos. Eles conhecem seu aluno, incluindo o quanto de angústia o aluno pode suportar antes de quebrar o aprendizado". No entanto, conhecer todos os alunos e compreender a reação emocional de cada aluno em um ambiente de aprendizagem é uma tarefa complicada e desafiadora.

Mesmo reconhecendo que a emoção é uma parte fundamental de nossa vida cotidiana, ela geralmente tem sido ignorada pela tecnologia ao longo dos anos. Essa falta de qualquer interação emocional, em muitos aspectos, tornou a tecnologia frustrante para os seres humanos. Porém, existem agora pesquisadores especializados em computação afetiva - concentrando suas pesquisas nas novas tecnologias que promovem a compreensão básica da emoção e seu papel na experiência humana. Pesquisadores do Grupo de Pesquisa de Computação Afetiva do MIT realizaram investigações em áreas como: novas maneiras pelas quais as pessoas podem comunicar estados afetivo-cognitivos, novas formas de avaliar indiretamente a frustração, o estresse e o humor, e como os computadores podem ser mais emocionalmente inteligentes, assim como outras áreas similares envolvendo aspectos afetivos. A frase *Affective Computing*, foi cunhada por Picard, quando ela publicou um livro intitulado *Affective Computing* in 1997 [Picard, 1997], e o nome tornou-se o termo mais comumente utilizado para esse campo da computação. Em seu livro, ela analisou detalhadamente como imaginava que a computação afetiva progrediria, bem como áreas como possíveis aplicações e possíveis preocupações. Picard argumentou que deveria haver algo como um raciocínio emocional para que houvesse qualquer forma de verdadeira inteligência de máquina. Sua ideia-chave era que deveria ser possível criar máquinas que se relacionassem, se originassem ou influenciassem deliberadamente a emoção e outros fenômenos afetivos. Ela argumentou que os programadores precisavam considerar o efeito ao escrever softwares que interagiam com as pessoas. De acordo com a escola de pensamento de Picard, as emoções (que também são conhecidas como afetos) são estados identificáveis, que podem ser modelados para possibilitar, como humanos, as possíveis interações entre pessoas e máquinas. Claro, que algumas emoções são mais difíceis de detectar do que outras, e, é por isso, que Ekman (1978) considerou que havia apenas seis emoções universais tornadas óbvias pela expressão facial - raiva, nojo, medo, felicidade (alegria), tristeza e surpresa. Posteriormente acrescentou o desprezo.

Considerando todas as questões abordadas acima, este trabalho propõe o desenvolvimento de um software para reconhecer emoções dos alunos a partir de suas expressões faciais e usar essas emoções no processo de ensino-aprendizagem, assim apoiando o desenvolvimento de uma metodologia de ensino que considere as emoções dos alunos em todo seu processo. Sendo assim a seção 2 apresenta uma metodologia de

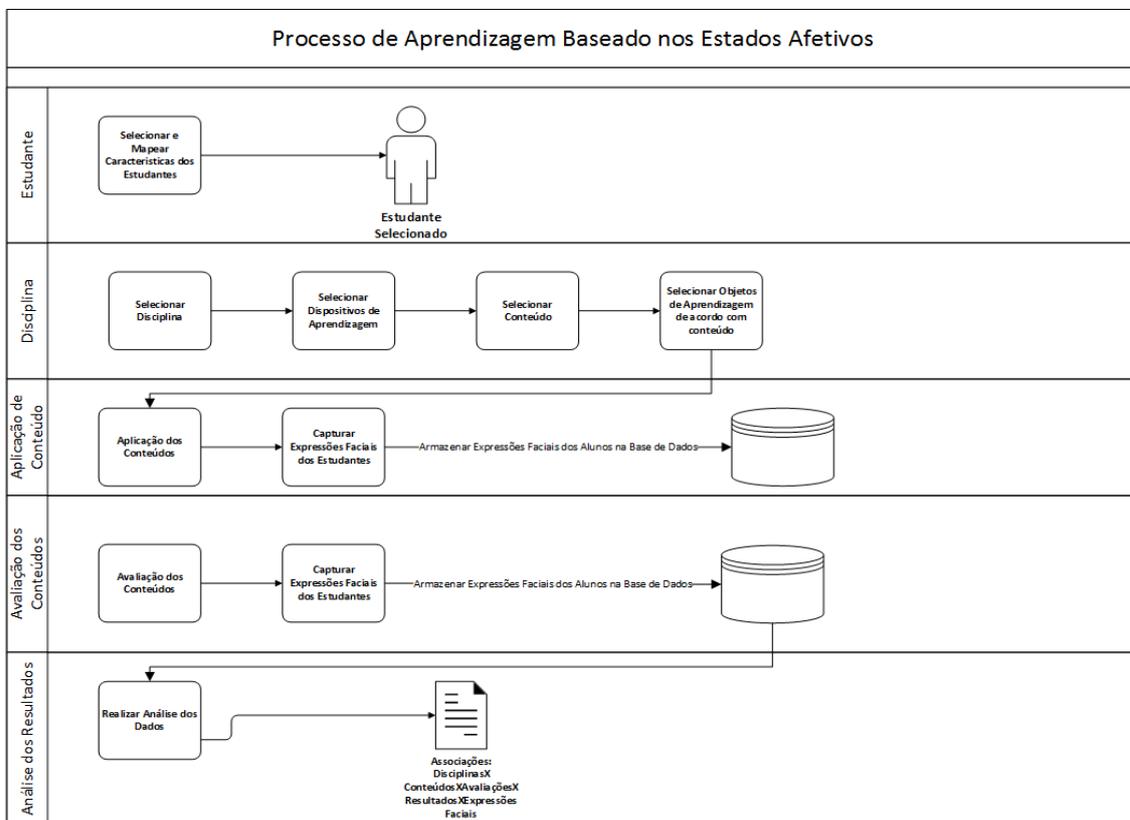
ensino baseada em emoções, a seção 3 a ferramenta que suporta esta metodologia e a seção 4 as considerações finais do trabalho.

## 2. Considerando as expressões dos alunos no processo de ensino para verificação de emoções– Uma abordagem metodológica

Conforme abordado na seção anterior, psicólogos e pedagogos têm apontado como as emoções podem interferir positivamente (quando o aluno está motivado e sentindo emoções positivas) e negativamente (quando o aluno está mal-humorado e deprimido por exemplo) na aprendizagem de um aluno. Dessa forma este trabalho propõe a utilização de uma abordagem metodológica que utiliza as emoções dos alunos para melhorar o processo de ensino – aprendizagem, e, para isto, dentre outras coisas, utiliza o suporte tecnológico de uma ferramenta – CADAP - de captura de expressões faciais dos estudantes durante as aulas, para que posteriormente possam ser feitas correlações entre as expressões faciais dos estudantes, as emoções, e a aprendizagem dos conteúdos.

### 2.1 – A Proposta

A abordagem proposta neste trabalho prevê a utilização de uma ferramenta – CADAP - para captura de expressões faciais dos alunos durante as aulas. Esta ferramenta captura as expressões dos alunos e as classifica em sete tipos distintos de emoções: alegria, tristeza, surpresa, medo, desprezo, desgosto e raiva. A captura é feita em intervalos de tempo pré-definidos pelo docente, e, ao final da aula é emitido um relatório por discente, que apresenta as emoções que predominaram a cada intervalo de tempo. Esta abordagem prevê um processo composto de cinco etapas conforme figura 1.



**Figura 1 – Abordagem Metodológica de Ensino Baseada na Emoção dos Alunos**

Neste processo o primeiro passo deve ser a seleção e categorização dos alunos que participarão das aulas que utilizarão a ferramenta. Posteriormente o docente deve preparar aulas que serão visualizadas na ferramenta, fazendo a seleção dos conteúdos que serão apresentados e dos objetos de aprendizado que serão utilizados. Os alunos assistirão as aulas na ferramenta e enquanto visualizam as aulas e respondem questionamentos sobre o conteúdo, serão filmados e suas expressões faciais serão capturada e correlacionadas com as sete emoções básicas que a ferramenta trabalha – alegria, tristeza, surpresa, desgosto, raiva, medo, desprezo e compromisso. Todas as informações geradas serão mantidas em uma base de dados e utilizadas para posterior geração de correlações das emoções, desempenho dos alunos, objetos de aprendizagem utilizados, conteúdos apresentados, entre outros. Nas próximas seções será realizada o detalhamento de cada etapa do processo.

### **2.1.1 – Etapa 1 - Modelagem do Perfil do Estudante**

Um perfil do aluno é composto por um conjunto de propriedades que caracterizam o estudante como: sua identificação pessoal, suas características pessoais e sociais, seu perfil de aprendizagem, seu conhecimento sobre determinados assuntos, etc. Algumas informações relativas ao perfil do aluno, como sua identificação pessoal, preferências pessoais e sociais, são raramente modificadas. Em contrapartida, informações que envolvem aspectos cognitivos como seu estilo de aprendizagem e seu conhecimento sobre um dado assunto, são constantemente alterados. Além disto, as informações sobre os aspectos cognitivos estão diretamente relacionadas ao ambiente e ao escopo de aprendizagem, fazendo com que seja necessário a ocorrência de alterações dentro deste contexto. [Dolog, 2005], [Lee, 2005].

Uma questão fundamental dentro da área de modelagem do aluno é determinar como construir modelos concisos que representem da melhor forma os aspectos cognitivos de um aluno em relação ao ambiente em que este se encontra. Um dos pontos é identificar qual estilo de aprendizagem está associado ao aluno para que seja possível traçar o perfil de aprendizagem do mesmo. No escopo deste trabalho será adotado o modelo de Felder e Silverman (1988) para classificar os alunos em relação a seu perfil de aprendizagem. Os autores propuseram um modelo de estilos de aprendizagem considerando métodos de ensino que pudessem atender tais estilos. Segundo Felder e Silverman (1988) um aluno pode ser classificado por um conjunto de estilos de aprendizagem. Isto porque cada um dos estilos descritos observa uma dimensão diferente do comportamento do aluno durante a aprendizagem.

Baseado no trabalho de Felder e Silverman (1988) foi criado um instrumento chamado índice de Estilos de Aprendizagem que é utilizado para determinar as preferências nas quatro dimensões (ativo/reflexivo, sensorial/intuitivo, visual/verbal e seqüencial/global). Na utilização do Índice de Estilos de Aprendizagem, o usuário deverá estar atento para dois pontos importantes: 1. Os resultados fornecem uma indicação das preferências individuais de aprendizagem e, provavelmente, uma indicação ainda melhor do perfil de preferências de um grupo de estudantes (por exemplo, uma turma), mas eles devem ser utilizados com cautela. 2. O perfil do estilo de aprendizagem de um estudante fornece uma indicação dos prováveis pontos fortes e possíveis tendências ou hábitos que poderiam estar conduzindo a dificuldades na vida acadêmica. O primeiro passo ao utilizar a abordagem metodológica proposta neste

trabalho é utilizar este formulário (figura 2) para classificar os alunos de acordo com seu estilo de aprendizagem baseado no instrumento. O objetivo de realizar esta classificação na metodologia é possibilitar futuras análises que possam correlacionar o perfil de aprendizagem dos alunos, as emoções expressadas e o desempenho dos discentes nas avaliações dos conteúdos.

The image shows a web browser window displaying a questionnaire. The browser's address bar shows the URL: https://200.139.13.25/cadap/teste/cubismo-turma-16-2. The questionnaire consists of five numbered questions, each with two radio button options (a and b):

1. Eu compreendo melhor alguma coisa depois de
  - a. experimentar.
  - b. refletir sobre ela.
2. Eu me considero
  - a. realista.
  - b. inovador(a).
3. Quando eu penso sobre o que fiz ontem, é mais provável que afluam
  - a. figuras.
  - b. palavras.
4. Eu tendo a
  - a. compreender os detalhes de um assunto, mas a estrutura geral pode ficar imprecisa.
  - b. compreender a estrutura geral de um assunto, mas os detalhes podem ficar imprecisos.
5. Quando estou aprendendo algum assunto novo, me ajuda
  - a. falar sobre ele.
  - b. refletir sobre ele.

**Figura 2. CADAP - Formulário de Felder e Silverman**

### 2.1.2 – Modelagem dos Conteúdos Curriculares.

Esta proposta prevê que os conteúdos curriculares utilizados, devem ser classificados quanto a abordagem utilizada: Baseada em Problemas, Baseada em Projetos, Palestras, com o objetivo de correlacionar os métodos de ensino, com os perfis de aprendizagem, as expressões faciais dos alunos durante a apresentação do conteúdo e o desempenho dos discentes. A ferramenta CADAP permite o registro dos conteúdos(aulas), com suas respectivas classificações.

### 2.1.3 – Aplicação e Avaliação dos Conteúdos

O núcleo da abordagem proposta neste trabalho é a utilização de uma ferramenta de captura e reconhecimento de expressões faciais durante as aulas e as avaliações de conteúdo. Esta ferramenta possibilita analisar as emoções dos alunos e correlaciona-las com fatores como perfil de aprendizagem do aluno, dispositivos de aprendizagem utilizado pelo professor e desempenho do aluno. Para que isto seja possível durante as aulas os alunos são filmados e a ferramenta captura e analisa as expressões faciais dos alunos em intervalos de tempos definidos pelo docente, e, assim constrói sua base de conhecimento dos alunos e de suas emoções. Ao final de cada aula o aluno preenche na própria ferramenta, um questionário (ver figura 3) em que avalia as emoções percebidas por ele durante as aulas, ponderando o quanto percebeu esta emoção entre muito fraco, fraco, mediantemente, forte e muito forte. O objetivo deste questionário é possibilitar a comparação entre as emoções percebidas pelos alunos, com as emoções detectadas pela ferramenta.

6 - Multiplicaciones

Deixe sua opinião sobre essa aula. Seu feedback é importante para melhorarmos nossos materiais!

Fiquei surpreso

Senti-me orgulhoso

Por algum motivo fiquei triste

Fiquei entusiasmado

Achei interessante

Senti-me desvalorizado

Por algum motivo fiquei envergonhado

Fiquei feliz

Senti-me arrependido

Criei expectativa

Senti medo

Fiquei tranquilo

Figura 3. CADAP - Questionário de Emoções Percebidas pelos Alunos

### 2.1.4 - Análise dos Resultados

O objetivo principal desta abordagem metodológica é propor hipóteses e validá-las a partir dos dados coletados durante as aulas e avaliações, além de estabelecer correlações entre os elementos envolvidos no processo. A seguir exemplo de uma possível hipótese e correlação estabelecida a partir da utilização desta proposta.

**Hipótese** - “*Quanto maior o tempo que um aluno permanece com expressões de alegria, a média da sua avaliação tende a aumentar*”

Após a aplicação da metodologia hipóteses como esta podem ser validadas (ou não) agrupando os alunos por percentual do tempo que permaneceram com a expressão de alegria durante a aplicação dos conteúdos curriculares e avaliando o resultado destes alunos, assim verificando a hipótese de aumento da média conforme aumento do tempo que os alunos permaneceram com expressão facial de alegria.

## 3. A Ferramenta CADAP

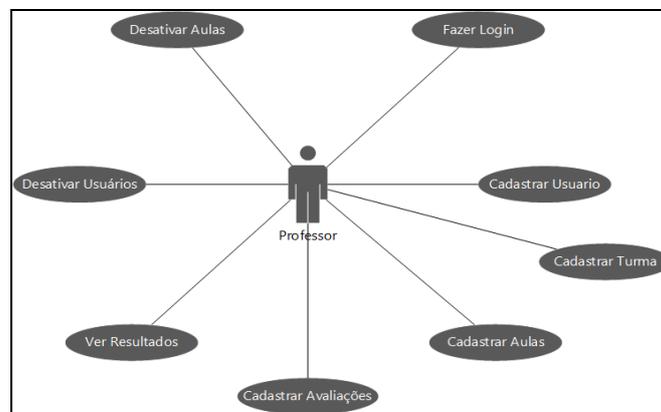
A ferramenta CADAP foi desenvolvido em um contexto que visa estudar as relações entre as emoções do aluno, os dispositivos de aprendizagem, os conteúdos utilizados e a performance dos alunos. Neste contexto, a captação da emoção dos alunos pode ser feita de várias maneiras, batimentos cardíacos, expressões faciais, temperatura, entre outros. Na ferramenta, isso é feito através da captura das expressões faciais dos alunos. A figura 4 exemplifica esse contexto no qual o CADAP atua capturando as expressões faciais dos alunos durante as aulas e avaliações, armazenando estes dados em uma base de dados e posteriormente realizando análises que permitam estabelecer correlações entre perfil de aprendizagem dos alunos, dispositivos de aprendizagem utilizados, emoções registradas e desempenho dos alunos nas avaliações.



**Figura 4. Metodologia CADAP**

### 3.1. Funcionalidades

A ferramenta CADAP permite que sejam cadastradas aulas, turmas, avaliações para os alunos, bem como a visualização de aulas, com a respectiva captura de expressões faciais e emissão dos resultados, por aula e por turma. A figura 5 apresenta o diagrama de caso de uso com as principais funcionalidades da ferramenta disponíveis para o perfil de professor, sendo elas o cadastro de usuários, turmas, aulas e avaliações, bem como a visualização de resultados. Todas estas funcionalidades já estão implementadas na atual versão da ferramenta.



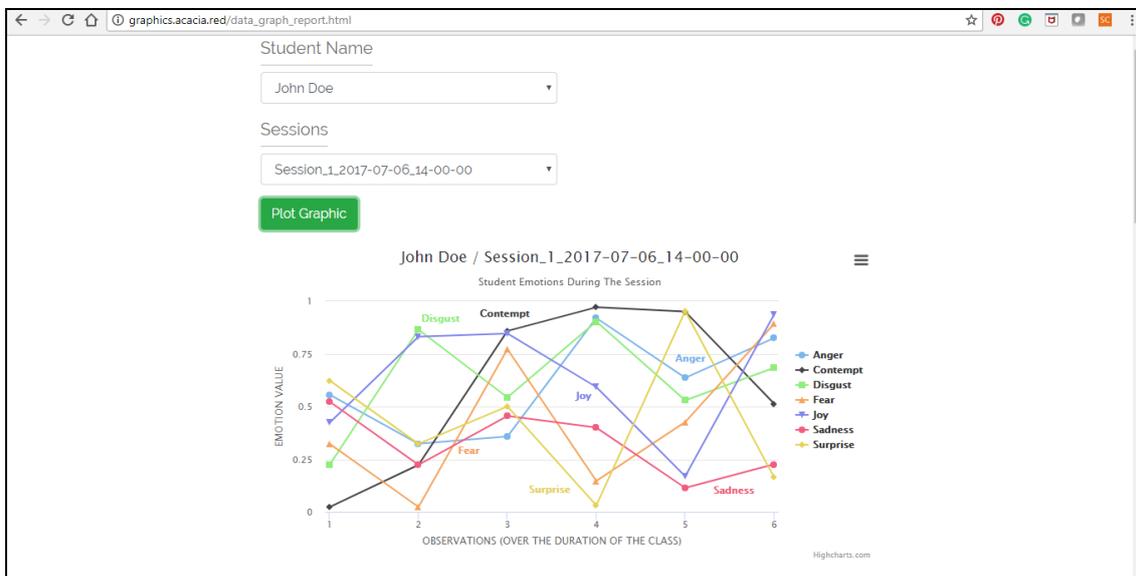
**Figura 5. CADAP - Funcionalidades do Professor**

A figura 6 apresenta a funcionalidade principal do CADAP que permite que as expressões faciais dos alunos sejam capturadas, enquanto estes assistem as videoaulas disponibilizadas na ferramenta. Nesta figura no menu superior direito é possível visualizar a imagem da face do aluno sendo capturada, enquanto este assiste aula na ferramenta. Ao finalizar a aula é gerado um relatório com as emoções que prevaleceram no aluno durante a aula visualizada.



**Figura 6. Tela de Visualização de Aulas e Captura de Expressões Faciais**

A figura 7 mostra um gráfico gerado após o aluno assistir uma videoaula no CADAP. Neste gráfico é possível acompanhar a variação das sete emoções que a ferramenta analisa – alegria, tristeza, surpresa, medo, raiva, desgosto, desprezo e compromisso. Com isso é possível verificar o momento da aula que houve variação significativa de emoções, quais emoções prevaleceram durante a aula, se o desempenho do aluno está relacionado as emoções positivas e/ou negativas observadas no aluno durante a aula, dentre outras possíveis conclusões.



**Figura 7. Gráfico de Variação de Emoções dos Alunos**

### 3.2 Componente de Análise de Expressões Faciais – Affective

O rosto humano fornece uma tela rica para nossas emoções, pois estamos inatamente programados para expressar e comunicar emoção através de expressões faciais. A tecnologia desenvolvida pelo Affective [D. McDuff, 2013] identifica primeiro um rosto humano em tempo real ou em uma imagem ou vídeo. Os algoritmos de visão computacional identificam os principais pontos de referência no rosto - por exemplo, os

cantos das sobrancelhas, a ponta do nariz, os cantos da sua boca. Os algoritmos de aprendizado de máquina então analisam pixels nessas regiões para classificar as expressões faciais. As combinações dessas expressões faciais são então mapeadas para as emoções. A tecnologia *Affective* mede sete métricas de emoção: raiva, desprezo, desgosto, medo, alegria, tristeza e surpresa. A tecnologia de reconhecimento emocional do *Affective* está disponível em vários produtos como SDK e API que podem ser acopladas em diversas ferramentas. No escopo deste trabalho a ferramenta CADAP acopla esta tecnologia para reconhecimento das expressões faciais dos alunos durante as aulas, pois acredita-se que as métricas de engajamento e atenção obtidas pela ferramenta são indicadores fundamentais de compreensão dos alunos, permitindo uma intervenção precoce para melhorar a retenção de conteúdo.

#### 4. Discussão de Resultados

Estão sendo realizados vários experimentos de utilização da ferramenta, onde os docentes preparam aulas e disponibilizam na ferramenta CADAP para que os alunos assistam e suas emoções sejam monitoradas. Estes experimentos estão sendo realizados em diferentes áreas do conhecimento, como eletrônica digital, química, literatura, entre outros com objetivo de analisar diversos cenários. A Figura 8 apresenta um destes experimentos. Baseado nestes cenários, análises estão sendo feitas para que a ferramenta possa auxiliar em medições como apresentadas nas próximas seções;



Figura 8. Experimento de Utilização do CADAP

##### 4.1 Desempenho de Aluno por Aula

Com os dados gerados pela ferramenta é possível analisar a média de emoções positivas e negativas de cada aluno nas aulas e posteriormente correlacionar estas informações com as avaliações realizadas sobre os assuntos tratados nas aulas.

## 4.2 Acompanhamento das Emoções da Turma

A ferramenta permite analisar a média das emoções dos alunos durante as aulas, possibilitando aos docentes saberem se os objetos de aprendizagem utilizados na disciplina despertam emoções positivas ou negativas nos alunos. No exemplo da figura 8, após a utilização da ferramenta na aula de literatura, com tema futurismo, é possível ao docente saber que esta aula despertou um maior percentual de emoções positivas como alegria e surpresa.

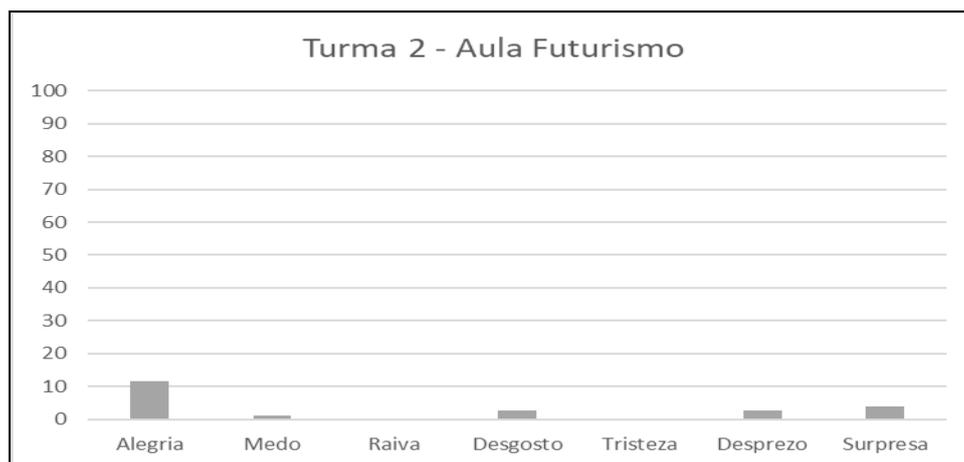


Figura 8. Acompanhamento de Emoções da Turma

## 4.3 Acompanhamento Individual dos Alunos

Baseado nos dados coletados pela ferramenta, é possível analisar a variação individual das emoções dos alunos, e com isso, o docente pode verificar como cada aluno reage ao conteúdo aprendido e analisar as possíveis causas de variação de emoções para cada aluno. Sabe-se que a variação das emoções dos alunos, nem sempre estarão relacionadas ao ambiente de aprendizagem, pois o aluno pode já estar com estado emocional afetado por outras condições externas, porém a ferramenta pode auxiliar o professor a identificar estas situações. Um aluno que mesmo com a variação de conteúdos e objetos de aprendizagem sempre permanece com um determinado estado emocional, tristeza por exemplo, pode estar passando por alguma dificuldade, e a utilização de uma ferramenta como a proposta neste trabalho, pode ajudar ao professor a perceber esta situação.

## 5. Considerações Finais e Trabalhos Futuros

Neste artigo, foi apresentada uma ferramenta que utiliza as emoções do aluno para apoiar o processo de ensino-aprendizagem. As expressões faciais do aluno são coletadas automaticamente utilizando esta ferramenta de reconhecimento de expressão facial – CADAP - e posteriormente estas expressões são interpretadas e classificadas em sete emoções básicas, alegria, tristeza, desgosto, surpresa, raiva, medo e desprezo. As emoções detectadas servirão de base para estabelecimento de correlações entre emoções, dispositivos de aprendizagem, metodologias de ensino e desempenho dos estudantes, para isto serão implementados métodos de *deep learning* para investigação mais profunda destas correlações. Atualmente estão sendo realizados experimentos em disciplinas utilizando esta ferramenta com objetivo de validar metodologia e coletar

dados para futuras análises. A intenção da ferramenta é possibilitar aos docentes conhecer as emoções despertadas por suas aulas, para as turmas e para cada aluno possibilitando aos docentes correlacionar estas informações e atuar quando for necessário, ajustando seus conteúdos e apoiando os discentes individualmente no seu processo de aprendizagem.

## 6. Agradecimentos

A Universidade Federal do Oeste do Pará e ao Projeto ACACIA pelo apoio e suporte financeiro ao desenvolvimento deste trabalho.

## Referências

- Damasio, António. *Descartes, Error: emotion, reason, and the human brain*. New York: 1994.
- D. McDuff, R. El Kaliouby, T. Se nechal, M. Amr, J. F. Cohn, and R. Picard. "Affectiva-mit facial expression dataset (AM-FED): Naturalistic and spontaneous facial expressions collected in-the-wild". In *Computer Vision and Pattern Recognition Workshops (CVPRW), 2013 IEEE Conference on*, pages 881–888. IEEE, 2013.
- Dolog, Peter And Shaefer, Michael. *A Framework for Browsing Manipulating and Maintaining Interoperable Learner Profiles*. Proceedings of UM2005 - 10th International Conference on User Modeling, Springer Verlag, United Kingdom, 2005.
- Ekman, P. And Friesen W. V. *Facial Action Coding System*. Palo Alto: Consulting Psychologists Press, 1978
- Felder, Richard And Silverman, Linda K. *Learning and Teaching Styles in Engineering Education*. *Engineering Education*, vl. 78, n. 7, pp674-681. 1988
- Izard, c. *Emotion-cognition relationships and human development*. In: izard, c. 1984;
- Lee, Catherine H M et al. *What affect student cognitive style in the development of hypermedia learning system?* *Computer and Education*, vl. 45, n.1, pp 1-19, 2005.
- Mora, Francisco. *NeuroEducación, Solo se puede aprender aquello que se ama*. Madri, 2013. pp 65-72
- Piaget, Jean. *A psicologia da criança*. 17ed. Rio de Janeiro: Bertrand Brasil, 1989
- Picard, r. *Affective computing*. Cambridge: mit press, 1997. 262 p.
- Vygotsky, l. *The problem of the environment*. In: veer, r. V.; vlasiner, j. (ed.). *The vygotsky reader*. Cambridge, ma: blackwell, 1994. P. 338-354

# Classifying Smart IoT Devices for Running Machine Learning Algorithms

Aluizio Rocha Neto<sup>1</sup>, Bárbara Soares<sup>2</sup>,  
Felipe Barbalho<sup>1</sup>, Luis Santos<sup>1</sup>, Thais Batista<sup>1</sup>  
Flávia C. Delicato<sup>3</sup>, Paulo F. Pires<sup>3</sup>

<sup>1</sup>Departamento de Informática e Matemática Aplicada (DIMAp) –  
Universidade Federal do Rio Grande do Norte, (UFRN), Natal – RN – Brazil

<sup>2</sup>Departamento de Engenharia de Computação e Automação (DCA) –  
Universidade Federal do Rio Grande do Norte, (UFRN), Natal – RN – Brazil

<sup>3</sup>Departamento de Ciências da Computação – Universidade Federal do  
Rio de Janeiro (UFRJ), Rio de Janeiro – RJ – Brazil

{aluiziorocha,barbaragabriellass}@gmail.com

{felipebarbalho.95,santosfluis19,thaisbatista}@gmail.com

{fdelicato,paulo.f.pires}@gmail.com

**Abstract.** *Tiny computers called System-on-a-Chip like Raspberry Pi have revolutionized the development of applications for Smart Home and Smart City. Some Machine Learning algorithms have been used to process a large amount of data produced by these Internet of Things (IoT) devices. An important issue in the context of processing IoT data is the decision on where the machine learning algorithm will run. To support this decision, it is necessary to classify the IoT devices according to their capabilities to run these algorithms, in terms of CPU performance, required memory, and energy demand. The aim of this paper is to classify IoT devices according to their capabilities to run machine learning algorithms, and reporting real experiments that validate the proposed classification.*

## 1. Introduction

The Internet of Things (IoT) paradigm [Atzori et al. 2010] has gained more and more notoriety in recent years. It encompasses an infrastructure of hardware, software, and services integrating objects from the physical world with the Internet. This scenario brings the opportunity for creating advanced applications, such as smart home, smart building and smart cities. These applications generally use several tiny and low-power sensors and networked devices, usually called System-on-a-Chip - SoC [Aitken et al. 2011]. Arduino<sup>1</sup> and Raspberry Pi<sup>2</sup> are two popular examples of these devices.

In the initial development of IoT, all data produced by any sensor should be transferred to servers normally hosted in Cloud Data Centers. This architecture places ever-increasing demands on communication and computational infrastructure with inevitable

---

<sup>1</sup><https://www.arduino.cc/>

<sup>2</sup><https://raspberrypi.org>

adverse effect on Quality-of-Service and Experience, given that over 25 billion devices are estimated to be added to the Internet by 2020, excluding PCs, tablets, and smartphones<sup>3</sup>. To address this challenge, the paradigms of Fog [Dastjerdi and Buyya 2016] and Edge Computing [Varghese et al. 2016] have emerged to allow the edge and end-user devices to be more Cloud independent. The main idea in these models is to process the data close to where it is generated, reducing the traffic and bandwidth consumption of the network. For instance, images from cameras capturing the objects and movements of what is happening in a variety of scenarios are very common as the main data for modern smart applications, such as information about vehicle traffic, crowded spaces or flood level of the river crossing the city, for example. To prevent sending all images from all cameras to a Cloud Data Center to process these datasets and to provide a fast response, this image processing should run on the embedded IoT devices.

However, image processing can only be done if the IoT image device has Computer Vision capabilities [Sebe et al. 2005], a method of Artificial Intelligence (AI) for acquiring, processing, analyzing and understanding digital images to extract high-dimensional data from the real world in order to produce numerical or symbolic information, i.e., models. The AI algorithms used in these analysis are in constant evolution to improve their accuracy. Machine Learning (ML) techniques have been used for automating the data model acquisition and updating processes, adapting task parameters and representations, and using experience for generating, verifying and modifying hypotheses about these models [Sebe et al. 2005]. Traditionally all Machine Learning algorithms run on powerful computers due to high demand for computation and memory requirements. In the context of IoT, the data is produced by devices located at the edge of the Cloud that have limited hardware resources. In order to balance processing with network traffic to the Cloud a question that arises is the decision of where the machine learning algorithm will run. Some researches have shown that if the IoT device have the ability to extract and send to the Cloud only the information learned, this reduces considerably the network demand and improves the responsiveness of the systems.

However, to run these learning algorithms it is necessary to classify the IoT devices according to their capabilities to run them, in terms of CPU performance, required memory, and energy demand. As far as we are concerned, the literature does not present such a classification. The goal of this paper is twofold: (i) to classify the IoT devices according to their capabilities to run machine learning algorithms. (ii) to report real experiments that validate the proposed classification. As contribution, we hope to provide useful information to guide the decision making of IoT application designers/developers. The remainder of the paper is organized as follows. In section 2 we present a background review of recent research works related to Machine Learning and Edge Computing. Section 3 presents the proposed classification for the "smart" IoT devices. Section 4 shows some experiments we conducted using the IoT devices to evaluate the performance of ML algorithms in such devices. Finally, section 5 brings our final remarks.

## 2. Background review

Machine learning is a research field that formally focuses on the theory, performance and properties of learning systems and algorithms. It is a highly interdisciplinary field build-

---

<sup>3</sup><http://www.gartner.com/newsroom/id/2636073>

**Table 1. Comparison of machine learning technologies [Qiu et al. 2016].**

Learning types	Data processing tasks	Distinction norm	Learning algorithms
Supervised learning	Classification / Regression / Estimation	Computational classifiers	Support Vector Machine
		Statistical classifiers	Naive Bayes Hidden Markov model Bayesian networks
		Connectionist classifiers	Neural networks
Unsupervised learning	Clustering / Prediction	Parametric	K-means Gaussian mixture model
		Nonparametric	Dirichlet proc. mix. model X-means
Reinforcement learning	Decision-making	Model-free	Q-learning R-learning
		Model-based	TD learning Sarsa learning

ing upon ideas from many different kinds of fields such as artificial intelligence, optimization theory, information theory, statistics, cognitive science and many other disciplines of science [Qiu et al. 2016].

Generally, the field of machine learning is divided into three subdomains: supervised learning, unsupervised learning, and reinforcement learning. Briefly, supervised learning requires training with labeled data which has inputs and desired outputs. Unsupervised learning does not require labeled training data and the environment only provides inputs without desired targets. Reinforcement learning enables learning from feedback received through interactions with an external environment [Qiu et al. 2016]. Table 1 presents these three machine learning techniques from different perspectives.

Supervised and unsupervised learning mainly focus on data analysis while reinforcement learning is preferred for decision-make problems. Most traditional ML based systems are designed with the assumption that all the collected data would be completely loaded into memory to start processing. Nowadays, there is a great need to develop efficient and intelligent learning methods to cope with future data processing demands [Qiu et al. 2016].

Deep Learning (DL) is part of a broader family of machine learning methods based on learning data representations, as opposed to task-specific algorithms. DL enables computational models that are composed of multiple processing layers to learn representations of data with multiple levels of abstraction. These methods have dramatically improved the state-of-the-art in speech recognition, visual object recognition, object detection and many other domains [LeCun et al. 2015].

Currently, deep learning algorithms are not widely used on IoT devices because they are often very resource consuming for the system (e.g., memory, computing and power). In [Lane et al. 2015a], the authors present a measurement study of running common deep learning models (AlexNet [Krizhevsky et al. 2012], SVHN [Netzer et al. 2011], DeepKWS [Chen et al. 2014], and DeepEar [Lane et al. 2015b]) to process audio and image sensor data on representative mobile and embedded platforms:

- Qualcomm Snapdragon 800 is widely used in smartphones and tablets (3 processors: a Krait 4-core 2.3 GHz CPU, an Adreno 330 GPU and a 680 MHz Hexagon

**Table 2. Execution time (msec) for running DL algorithms in three hardware platforms [Lane et al. 2015a].**

	Type	Size (bytes)	Tegra		Snapdragon		Edison
			CPU	GPU	CPU	DSP	CPU
Deep KWS	DNN	241K	0.8	1.1	7.1	7.0	63.1
DeepEAR	DNN	2.3M	6.7	3.2	71.2	379.2	109.0
SVHN	CNN	313K	15.1	2.8	1,615.5	-	3,352.3
AlexNet	CNN	60.9M	600.2	49.1	159,383.1	-	283,038.6

DSP, 1GB of RAM).

- Intel Edison, the smallest and least computational powerful of all tested hardware (500MHz dual-core Atom “Silvermont” CPU assisted by a 100 MHz Quark processor, 1 GB of RAM).
- Nvidia Tegra K1 developed for extreme GPU performance in IoT context (Kepler 192-core GPU, 2.3 GHz 4-core Cortex CPU, 2GB of RAM).

Table 2 shows the times in milliseconds the authors have obtained for running two Deep Neural Networks (DNN) - Deep KWS and DeepEar, and two Convolutional Neural Networks(CNN) - SVHN and AlexNet, on these devices. They found that almost all DL model and processor combinations can run on such platforms. Even large-scale models like AlexNet (60.9MB size) are supported by the weakest of the processors they used (an Intel Edison). This result suggests that DL models of similar architecture targeting different inference tasks will also function to some degree. They conclude that the range of inference tasks offered by this set of DL models is enormous, and comprise tasks generally not seen on IoT hardware.

[Kamath et al. 2016] introduced EdgeSGD, a decentralized Stochastic gradient descent algorithm suitable for machine learning and analytics on the edge of the network. This method can be applied to a wide range of problems arising in decentralized machine learning. In the paper, they used the proposed algorithm to learning/predicting seismic anomalies via real-time imaging and evaluated the performance of the algorithm on an edge computing testbed - a cluster composed of 16 BeagleBone Black<sup>4</sup> (CPU single-core 1GHz, 512MB of RAM). They also compared the proposed solution with other existing distributed computation methods such as MapReduce, DGD and EXTRA, and examined in particular the effects of node/link failure and communication cost. Such a comparative analysis showed that edge processing with EdgeSGD is quite feasible.

In recent years, a significant amount of research has been done using the Raspberry Pi as the edge node to process IoT data. [Anandhalli and Baligar 2017] proposes a video processing algorithm that detects, tracks and counts vehicles on a road, applying a Kalman filter to track vehicles, and applying individual vehicle detection through the HSV (Hue, Saturation, Value) color spectrum. The algorithm runs on a Raspberry Pi 3 (1.2GHz quad-core ARMv8, 1GB of RAM) with an embedded camera and uses the OpenCV<sup>5</sup> (Open Source Computer Vision Library) that contains a set of filters for image processing. The work also compares the performance of running the same algorithm on a

<sup>4</sup><https://beagleboard.org/black>

<sup>5</sup><https://opencv.org/>

desktop PC (2.5 GHz dual-core, 4GB of RAM) and it took 72.7 ms to process one frame whereas Raspberry Pi needed 81.589 ms, only 9 ms slower.

In [Sajjad et al. 2017] the authors developed a face recognition framework for law-enforcement services in smart cities. This framework uses a small-sized portable wireless camera mounted on a police officer's uniform to capture a video stream, which is passed to a Raspberry Pi 3 in the officer's car for face detection and recognition. To accomplish the facial recognition, they use initially the Viola-Jones face detection algorithm to find all the faces present in the live video stream sent by the camera. Then, the ORB (Oriented FAST and Rotated BRIEF) method is executed to extract from the identified faces all their features which are transmitted to a trained support vector machine classifier in the cloud. Instead of sending the entire captured image, only the features extracted from the face are sent, thus saving transmission power and bandwidth.

An issue that came up in reading these articles was what criteria were applied to choose the IoT devices used in the experiments to process data at the edge of network. What hardware specifications were important for running the ML algorithms. This paper analyses these aspects, proposes a classification for choosing an IoT device to run ML algorithms, and reports some experiments using IoT devices to learn with its own data.

### 3. Smart IoT Device Classification

The ability to process and understand the IoT data to obtain some higher level information is fundamental for the Machine Learning techniques. From a basic statistic, like the average temperature in a room, to a complex information, such as "how many people are in the room right now?" all these informations require the data analysis for extracting useful features and representations of the data. These kinds of data processing requires different levels of hardware resources to be done. Thus, we proposed an IoT device classification so that we can match the algorithm resources demand with the hardware class of the most popular IoT devices found on the market.

In order to perform this type of data analysis, the device must have the ability to fuse (combine) all the data and extract the useful information. For example, a suddenly temperature of 16 degree when the average temperature is 24 degree can be interpreted as a data noise and it must be discarded. According to [Nakamura et al. 2007], *Information Fusion* deals with three levels of data abstraction: measurement, feature, and decision, and it can be classified into four categories:

- *Low-Level Fusion*. Also referred to as *signal (measurement) level fusion*. Raw data are provided as inputs, combined into new piece of data that is more accurate (reduced noise) than the individual inputs.
- *Medium-Level Fusion*. Attributes or features of an entity (e.g., shape, texture, position) are fused to obtain a feature map that may be used for other tasks (e.g., segmentation or detection of an object). This type of fusion is also known as *feature/attribute level fusion*.
- *High-Level Fusion*. Also known as *symbol* or *decision level fusion*. It takes decisions or symbolic representations as input and combines them to obtain a more confident and/or a global decision.
- *Multilevel Fusion*. When the fusion process encompasses data of different abstraction levels — when both input and output of fusion can be of any level (e.g.,

**Table 3. Classification of Smart IoT devices according to their capacities.**

Class	Hardware capacity	Power consumption	Suitable algorithms	Main application
1	No storage, low CPU and memory	$\leq 1W$	Basic computation	Data generation
2	storage $\leq 4GB$ , memory $\leq 512MB$ CPU single-core	$\leq 2W$	Basic statistic	Low-level data fusion
3	storage $\leq 8GB$ memory $\leq 2GB$ CPU quad-core	$\leq 4W$	Classification / Regression / Estimation	Mid-level data fusion
4	storage $\geq 16GB$ memory $\geq 4GB$ CPU and GPU	$\leq 8W$	Prediction / Decision-making	High-level data fusion
5	High	High	Any	Autonomous system

a measurement is fused with a feature to provide a decision) — multilevel fusion takes place.

Since any device connected to the Internet can generate and process data to some degree, it is important to define a classification for such devices so that we can identify which ML algorithms can be deployed to each equipment model. Usually, ML algorithms have to process a huge amount of data, requiring powerful CPU and large memory. These kind of resources are very limited in the majority of IoT devices. In addition, intense CPU usage has a significant use of power which is also limited in IoT devices.

Table 3 shows the proposed Smart IoT Device Classification. The hardware capacity and power consumption data for each class are based on related researches and our experiments using some IoT devices running intelligent solutions. This classification considers only IoT devices for applications used in smart cities, buildings or home, i.e. we are not considering hardwares used in mobile devices, such as phones or tablets.

The main purpose of class 1 devices is to collect data from their sensors where the dataset is small, analogical and continuous, such as sensors measuring temperature, humidity, presence, noise, gases, etc. This kind of device also have some actuators such as LEDs, relay module and servo motors to do some actions in the ambient whenever it is needed. Class 2 devices are a step further in the ability of collecting, processing, and storing data. Unlike class 1 devices that have microcontrollers, they have true CPU, RAM memory and an operating system to control the whole system. But, due to their limited resources they can only process some basic statistics to produce the low-level data fusion.

Devices class 3 and 4 are the ones really used for running Machine Learning algorithms on the edge. The main difference between them is that class 4 devices have a powerful GPU for parallel processing, which is very important in the execution of algorithms of training and using neural networks. Class 3 device can use a trained neural network to make the medium-level fusion of the data and extracting the relevant features of the context, like a detection of an object. Class 4 device can go further and taking

**Table 4. Examples of IoT devices and their classifications.**

Class	Device	CPU	GPU	Memory / Storage	Power Consump.
1	Arduino Mega	Microcontroller ATmega 8-bit 16 MHz	None	32 KB / None	$\leq 408\text{mW}$
	NodeMCU ESP-12	Microcontroller ESP8266 32-bit 80 MHz	None	80 KB / None	$\leq 561\text{mW}$
2	Raspberry Pi Zero	ARM1176 single-core 1 GHz	Broadcom VideoCore IV	512 MB / MicroSD card	0.5W - 1.2W
	Beaglebone Black	ARM Cortex-A8 single-core 1 GHz	PowerVR SGX530	512 MB / 4GB + card	1.1W - 2.15W
3	Raspberry Pi 3	ARM Cortex-A53 quad-core 1.2 GHz	Broadcom VideoCore IV	1 GB / MicroSD card	1.2W - 3.7W
	ODROID XU4	ARM Cortex-A15 octa-core 2 GHz	ARM Mali-T628	2 GB / MicroSD card	2.1W - 13.2W
4	NVIDIA Jetson TX2	ARM Cortex-A57 quad-core 2 GHz + NVIDIA Denver2 dual-core 2GHz	NVIDIA Pascal 256 CUDA cores	8 GB / 32GB + SATA	7.5W - 15W

decisions using a set of higher level data fusion. It can also retrain the neural network for running into a class 3 device.

A class 5 is a multilevel-fusion device and can be considered as an autonomous system, which can act automatically to prevent a situation in the scenario. The best example of such a device is the computational system used into self-driven vehicles. These systems are expected to operate flawlessly irrespective of weather conditions, visibility, or road surface quality and have the capacity to deal with terabytes of datasets produced by their sensors<sup>6</sup>.

Table 4 shows the instantiation of classification applied to some IoT devices found in the market. The power consumption range was obtained from the manufacturer specifications and forums of users on the Internet. Most of the IoT devices use a MicroSD card slot as a storage unit for their data, and the BeagleBone Black comes with an internal 4GB flash memory.

#### 4. Probing the Smart IoT Device Classification

To validate our proposed classification, this section describes some of our experiments that we have developed using IoT devices to make systems more smarter. The main characteristic of these experiments is the application of edge computing paradigm, i.e., the processing of the sensors data in the device that produces these data, reducing network delays and bandwidth.

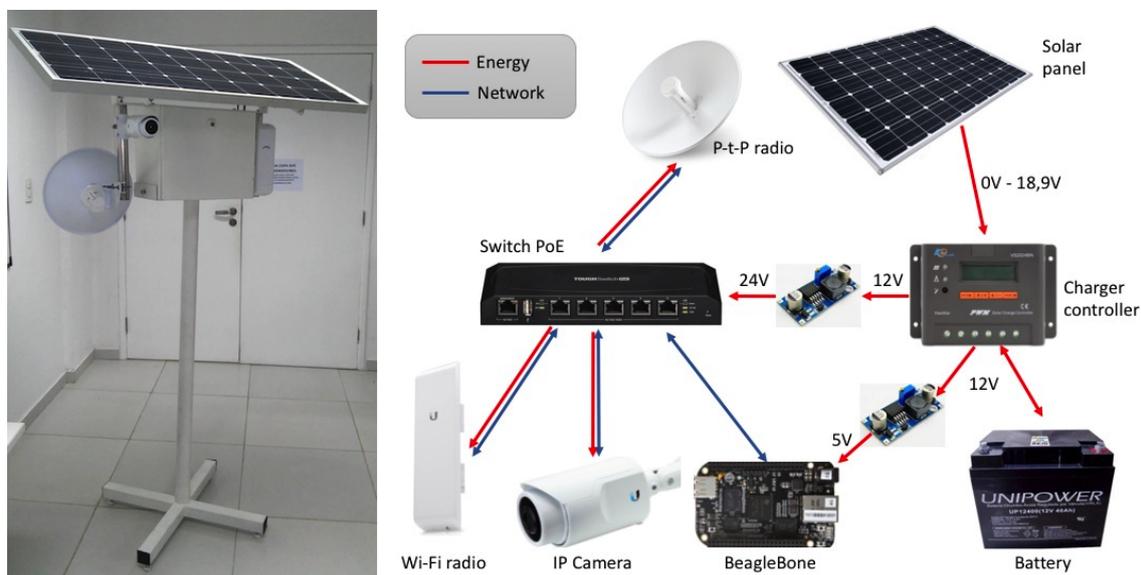
##### 4.1. Smart Pole Project

The first solution is related to our Smart Campus project where we have developed a Smart Pole powered by solar panel that acts as a sensing and connectivity infrastructure for smart cities. This solar city pole is carried with Wi-Fi radios, IP camera, and an

<sup>6</sup><https://devblogs.nvidia.com/training-self-driving-vehicles-challenge-scale/>

IoT device and some of the services it can offer to the citizens are: Internet Wi-Fi Hot-spot, sensing of environmental pollution, spot for an automated parking space availability system, autonomous and intelligent lighting spot, and place for digital panels with useful information updated in real time.

The main issue of any solar powered system is the battery setup and how the embedded equipment will use the energy produced by the solar panel and stored into battery for the usage at night or raining days. We have been using the solar charger controller EPsolar VS2024BN<sup>7</sup> to manage the energy in the pole. Its main function is to limit the rate at which electric current is added to or drawn from battery and it cuts off electric current from battery if its voltage reaches an under boundary. The connectivity and energy for Wi-Fi radios and IP camera is provided by a Power over Ethernet (PoE<sup>8</sup>) Switch. Figure 1 shows a picture of the pole and the schema of the energy and network topologies.



**Figure 1. The Smart Pole and its energy and network topologies.**

The IoT device Beaglebone Black used in the pole is the sensing platform and the data collector and analyzer for the energy produced and consumed in the system. As a class 2 device, it does the low-level fusion of sensors data and can compute several statistics about the pole operation and datasets. Every 5 minutes the Beaglebone asks the charger controller via an RS-485 interface all data about the energy management in the system. All data are stored on the device in a SQLite<sup>9</sup> database and after one year this database has approximately 100 thousand records that occupies only 12MBytes of the BeagleBone's 4GB internal storage flash memory. By mining this dataset the BeagleBone can predict a critical situation when the battery charge is getting too low and the charger controller will cut off all the energy that powers the equipments. Before this situation happens, the BeagleBone can act by sending SNMP<sup>10</sup> set commands to the switch to

<sup>7</sup>[http://www.epsolarpv.com/en/index.php/Product/pro\\_content/id/166/am\\_id/136](http://www.epsolarpv.com/en/index.php/Product/pro_content/id/166/am_id/136)

<sup>8</sup>[https://en.wikipedia.org/wiki/Power\\_over\\_Ethernet](https://en.wikipedia.org/wiki/Power_over_Ethernet)

<sup>9</sup><https://www.sqlite.org/>

<sup>10</sup>Simple Network Management Protocol (<http://www.snmp.com/protocol/>)

**Table 5. Running a complex SQL query in different software and hardware platforms**

	SQL query response time (msec)
MySQL @ Cloud server	2,280
SQLite @ Cloud server	291
SQLite @ Beaglebone	3,113
SQLite @ Raspberry Pi 2	3,143

disable the port(s) connected the IP camera and/or the Wi-Fi radio to save energy until the solar panel can produce power again.

To compare the performance of the BeagleBone running SQL queries that use statistical functions (COUNT, MAX, MIN, and SUM) we have exported this database to a MySQL server (Intel Xeon quad-core 2.6GHz and 4GB of RAM) in the Cloud to get its response time as reference. Table 5 shows the results for running the SQL query that gets all the power cuts and subsequent period of inactivity due to low power in the battery. This query has 3 nested subqueries and applies the MAX function to a 'timestamp' type column of the table. Surprisingly the response time of MySQL running on the Cloud server was close to the time of SQLite running on BeagleBone and Raspberry Pi 2. This suggests that any ML algorithm that needs statistics to learn using large datasets can be done in the edge using a Smart IoT device class 2.

#### 4.2. Smart Place Project

The second solution is also related to our Smart Campus project and it is a system named Smart Place which uses sensors, camera, and Raspberry Pi as the IoT device manager to intelligently control the air conditioners (AC) in smart buildings. This system was developed aiming to contribute to energy saving by automatically managing the usage of AC at the Federal University of Rio Grande do Norte.

The Smart Place system detects the presence of people in the room and automatically turns on the air conditioner and then turns off if nobody has been detected in the last 15 minutes. It also checks the room reservation data for the next minutes before turning the air conditioner off, so that no AC will have its status switched (on-off-on) in a short period of time, which would increase the consumption of energy instead of contributing to any savings.

Initially, only a motion sensor was used to detect the presence of people in the room. But due to its distance limitation, specially in environments that are larger like a classroom, an embedded Raspberry Pi's camera was integrated to improve the efficiency of the system. Figure 2 shows an diagram of the Smart Place system in a room and a schema of the device, sensors, and actuator (infrared LED) used. The Raspberry Pi commands the AC sending infrared signals to its IR receiver, like an AC remote control. All data collected from the sensors and camera (temperature, humidity and presence) is stored in a SQLite database and processed in the Raspberry Pi to make the decision of turning on or off the AC. For monitoring the whole system in all rooms the data is also sent to a Cloud server.

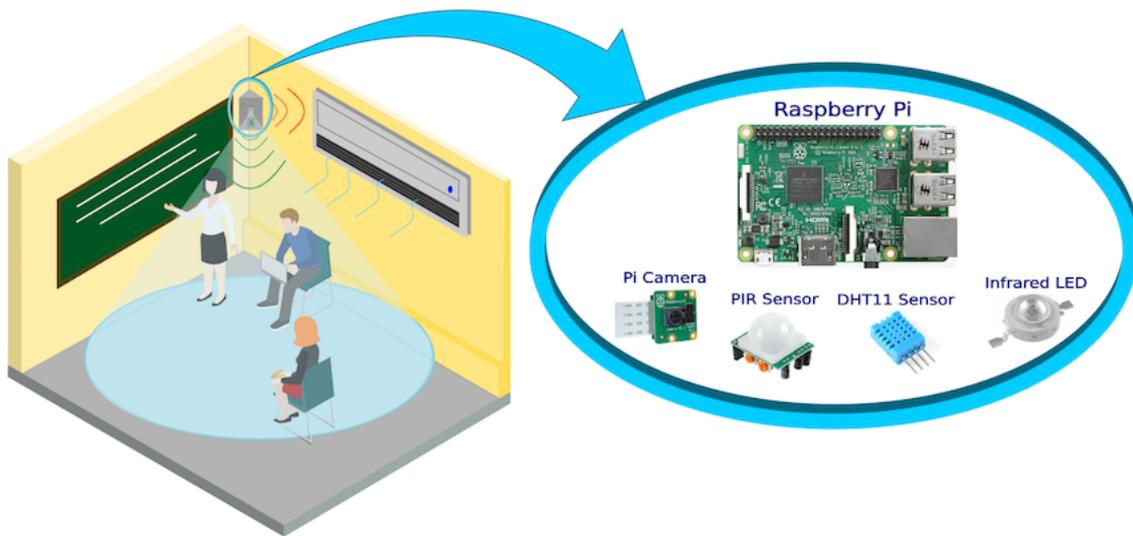


Figure 2. The Smart Place system.

Table 6. Running CNN MobileNet in different computers

	DL algorithm response time (msec)
Notebook	130
Raspberry Pi 3	1,609
Raspberry Pi 2	2,398
Raspberry Pi Zero	16,383

With the image of the room captured with the Raspberry Pi's camera, classification, counting, and localization of people in such place was possible. In order to do these processes, we have been using object detection through Deep Learning techniques available in the OpenCV library. After testing several methods for object detection, Single Shot Detectors (SSDs) [Liu et al. 2016] was the method that better suit our system, being even faster and more precise than the YOLO method [Redmon et al. 2016], and by combining it with the CNN model MobileNet [Howard et al. 2017], we got an efficient and fast deep learning method for object detection which can be used in any resource constrained device, like the Raspberry Pi. Table 6 shows our experiments using a notebook with webcam (MacBook Air Intel dual-core i5 1.3GHz, 4GB of RAM) and three versions of Raspberry Pi to run the CNN MobileNet model in order to detect and count the people in the room.

The response time of the Raspberry Pi 3 and 2 (class 3 devices) is quite interesting. Both have quad-core processors and 1GB of RAM and the difference of Pi 3 time for the notebook time was about 1.5 seconds slower. For this reason and prospecting the potential of such devices in the development of smart applications, the academic community has been researching more computationally efficient neural networks and with a smaller memory/processing requirement. One of such initiative is the SqueezeNet [Iandola et al. 2016].

## 5. Final Remarks

The Internet of Things technology is being increasingly used mainly with the advent of smart solutions (smart city, smart building, home automation, etc.). Due to the rapid evolution of System-on-a-Chip, there is a big marathon for developing intelligent systems where small devices process their own data and take decisions to improve user experiences. This novel paradigm, known as Edge or Fog Computing, will allow the Internet to grow even more, improve the user experience and reduce the dependency on Cloud infrastructures.

Analyzing the machine learning techniques and how the ML algorithms run on resource constrained devices, this paper proposed a Smart IoT Device Classification. This classification helps developers choosing the IoT device that better matches the hardware resources with the data processing and learning requirements for their smart systems. Some experiments of using the IoT devices discussed in this paper were also presented, showing the potential this tiny devices have in smart solutions.

We believe that machine learning algorithms will also evolve along with IoT devices because there is a whole new market for intelligent systems using the Internet as the main infrastructure. This market is pushing forward the development of new hardware, software, and network protocols to address all the challenges present in such systems.

## References

- Aitken, R., Flautner, K., and Goodacre, J. (2011). High-performance multiprocessor system on chip: Trends in chip architecture for the mass market. In Hübner, M. and Becker, J., editors, *Multiprocessor System-on-Chip - Hardware Design and Tool Integration*, pages 223–239. Springer.
- Anandhalli, M. and Baligar, V. P. (2017). A novel approach in real-time vehicle detection and tracking using raspberry pi. *Alexandria Engineering Journal*.
- Atzori, L., Iera, A., and Morabito, G. (2010). The internet of things: A survey. *Computer Networks*, 54(15):2787–2805.
- Chen, G., Parada, C., and Heigold, G. (2014). Small-footprint keyword spotting using deep neural networks. In *ICASSP*, pages 4087–4091. IEEE.
- Dastjerdi, A. V. and Buyya, R. (2016). Fog computing: Helping the internet of things realize its potential. *IEEE Computer*, 49(8):112–116.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *Computer Vision and Pattern Recognition (cs.CV)*.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., and Keutzer, K. (2016). Squeezenet: Alexnet-level accuracy with 50x fewer parameters and <05mb model size.
- Kamath, G., Agnihotri, P., Valero, M., Sarker, K., and Song, W.-Z. (2016). Pushing analytics to the edge. In *GLOBECOM*, pages 1–6. IEEE.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Bartlett, P. L., Pereira, F. C. N., Burges, C. J. C.,

- Bottou, L., and Weinberger, K. Q., editors, *Advances in Neural Information Processing Systems 25: 26th Annual Conference on Neural Information Processing Systems 2012. Proceedings of a meeting held December 3-6, 2012, Lake Tahoe, Nevada, United States*, pages 1106–1114.
- Lane, N. D., Bhattacharya, S., Georgiev, P., Forlivesi, C., and Kawsar, F. (2015a). An early resource characterization of deep learning on wearables, smartphones and internet-of-things devices. In Xu, C., Zhang, P., and Sigg, S., editors, *Proceedings of the 2015 International Workshop on Internet of Things towards Applications, IoT-App 2015, Seoul, South Korea, November 1, 2015*, pages 7–12. ACM.
- Lane, N. D., Georgiev, P., and Qendro, L. (2015b). Deeppear: robust smartphone audio sensing in unconstrained acoustic environments using deep learning. In Mase, K., Langheinrich, M., Gatica-Perez, D., Gellersen, H., Choudhury, T., and Yatani, K., editors, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp 2015, Osaka, Japan, September 7-11, 2015*, pages 283–294. ACM.
- LeCun, Y., Bengio, Y., and Hinton, G. E. (2015). Deep learning. *Nature*, 521(7553):436–444.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Scott Reed, C.-Y. F., and Berg, A. C. (2016). Ssd: Single shot multibox detector. *Computer Vision – ECCV 2016*, 9905:21–37.
- Nakamura, E. F., Loureiro, A. A. F., and Frery, A. C. (2007). Information fusion for wireless sensor networks: Methods, models, and classifications. *ACM Comput. Surv.*, 39(3).
- Netzer, Y., Wang, T., Coates, A., Bissacco, R., Wu, B., and Ng, A. Y. (2011). Reading digits in natural images with unsupervised feature learning.
- Qiu, J., Wu, Q., Ding, G., Xu, Y., and Feng, S. (2016). A survey of machine learning for big data processing. *EURASIP J. Adv. Sig. Proc.*, 2016:67.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 779–788.
- Sajjad, M., Nasir, M., Muhammad, K., Khan, S., Jan, Z., Sangaiah, A. K., Elhoseny, M., and Baik, S. W. (2017). Raspberry pi assisted face recognition framework for enhanced law-enforcement services in smart cities. *Future Generation Computer Systems*, November 2017.
- Sebe, N., Cohen, I., Garg, A., and Huang, T. S. (2005). *Machine Learning in Computer Vision*, volume 29 of *Computational Imaging and Vision*. Springer.
- Varghese, B., Wang, N., Barbhuiya, S., Kilpatrick, P., and Nikolopoulos, D. S. (2016). Challenges and opportunities in edge computing. In *2016 IEEE International Conference on Smart Cloud, SmartCloud 2016, New York, NY, USA, November 18-20, 2016*, pages 20–26.

# Estratégias para a Redução de Consumo de Energia e Aumento de Confiabilidade em IoT

Ricardo Reis

Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)  
Caixa Postal 15.064 – 91.501-970 – Porto Alegre – RS – Brazil

reis@inf.ufrgs.br

**Abstract.** *The Internet of Things (IoT) demands new challenges for the design of computing and electronics components. One of the challenges is the power reduction of this large network of connected devices, where the majority is permanently connected. Another important issue, in a large set of applications, especially on critical areas as health and transport, is reliability. This paper shows an overview of design strategies that we have developed to reduce power consumption and to increase reliability in circuits that are components of the IoT, as reduction of the number of transistors in IoT devices, using optimization techniques and physical design tolerant to radiation effects.*

**Resumo.** *A Internet das Coisas (IoT) demanda novos desafios no projeto dos dispositivos computacionais e eletrônicos. Um destes desafios é a redução de consumo dos componentes desta grande rede de dispositivos conectados, sendo que a maioria permanece em conexão permanente. Outro aspecto importante, em um grande número de aplicações, especialmente em áreas críticas como saúde e transporte é a confiabilidade. Este artigo visa dar um panorama de estratégias de projeto que temos desenvolvido para a redução de consumo e aumento de confiabilidade de circuitos componentes da IoT, tais como redução do número de transistores nos dispositivos, aplicando técnicas de otimização, novas arquiteturas e projeto físico tolerante a efeitos de radiação.*

## 1. Introdução

O aumento de crescente de dispositivos conectados na internet das coisas é um dos motivos pelo crescente aumento no número de transistores produzidos anualmente no mundo. A Figura 1, baseada em [SIA 2005], mostra o número de transistores fabricados anualmente no mundo ano a ano. Este crescimento impressionante é devido a 3 fatores principais: aumento do número de transistores integráveis em um chip, aumento do número de produtos que incluem chips embarcados e aumento do número de exemplares fabricados de cada produto. O custo de fabricação de um transistor é relativamente barato. Em [The Economist 2010] é apresentado uma comparação entre o custo de um grão de arroz com o custo de um transistor. O custo de um grão de arroz pode ser equivalente ao custo de fabricação de mais de 125 mil transistores. Isto indicaria que não há necessidade de economizar o número de transistores em um projeto, já que o custo deles é relativamente pequeno. Porém o custo da energia necessária para a operação de um transistor é cada vez mais elevado. Também temos de considerar que um alto consumo de potencia pode reduzir a vida útil de um sistema, assim como aumentar os efeitos de variabilidade que podem provocar um mau funcionamento de um sistema integrado e/ou reduzir sua vida útil. Com a conexão crescente de dispositivos eletrônicos e computacionais na internet, ou seja, na era da internet das coisas, os

problemas de consumo tendem a se agravar, e muito. Portanto, a palavra chave na internet das coisas passa a ser **otimização**, especialmente a otimização de consumo, que deve ser tratada em todos os níveis de projeto de um sistema computacional ou eletrônico. Uma computação sustentável demanda uma otimização em todos os níveis de projeto de um sistema computacional ou eletrônico.

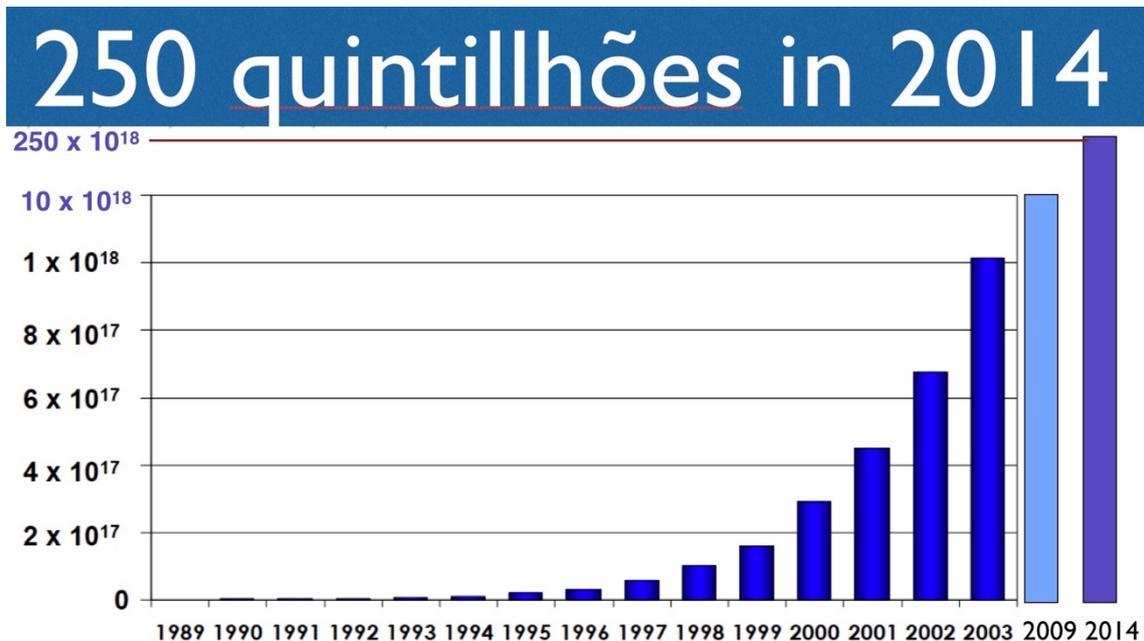


Figura 1. Número de transistores produzidos anualmente no mundo  
[adaptado de SIA 2005]

## 2. Internet das Coisas

O termo Internet das Coisas já deu origem a diversos outros termos, como Internet da Saúde (IoH – Internet of Health), Internet das Pessoas (IoP – Internet of People) e Internet de Tudo (IoE, Internet of Everything). Na realidade, este último termo passa a ser o mais abrangente, mas cada um dos demais tem algumas características específicas. Quando se fala em Internet da Saúde, que inclui o monitoramento em tempo real das condições clínicas de uma pessoa, assim como o monitoramento de equipamento implantados em uma pessoa, a questão de confiabilidade é uma questão primordial. E confiabilidade também está relacionada ao consumo, na maioria dos casos. Quando se fala em internet das pessoas, a questão de segurança e privacidade das pessoas tem uma grande relevância. Mas em todos os casos, cresce mais e mais a importância em otimizar o consumo de energia.

Quando tratamos de otimização, significa, que os sistemas integrados devem ser, cada vez mais, dedicados à aplicação prevista, de forma a otimizarem o número de componentes, ou seja, o número de transistores. Outra estratégia importante visando a otimização é o projeto conjunto de hardware e software, onde pode-se gerir o compromisso entre desempenho, consumo e confiabilidade.

Os dispositivos conectados à internet das coisas (ou internet de tudo), podem ter complexidades muito diferentes. Se analisarmos a complexidade quanto ao número de

componentes, podemos encontrar dispositivos pequenos com poucos transistores e dispositivos grandes com bilhões de transistores, como smartphones com SoC avançados (como será exemplificado mais adiante), ou sistemas de controle de veículo de transporte. Evidentemente que os dispositivos grandes vão consumir muito mais energia, mas temos de considerar que a maioria dos dispositivos na internet das coisas são dispositivos com um baixo número de transistores, mas por serem encontrados em grande quantidade, podem representar um consumo total mais importante do que o consumo dos dispositivos ditos grandes. Portanto, a otimização de consumo deve ser efetuada tanto em dispositivos grandes quanto em dispositivos pequenos que estão presentes em grande quantidade. Outro aspecto a considerar é que alguns dispositivos demandam a aplicação de técnicas de aumento de confiabilidade (como os relacionados a sistemas de transporte ou de saúde), que podem aumentar o número de componentes, enquanto outros dispositivos não são críticos, como câmera fotográfica ou de vídeo, em que um erro na visualização de um pixel da imagem não causa maiores problemas.

A Figura 2 [The Connectivist 2014] mostra uma estimativa do número de dispositivos conectados na internet desde 1992, quando eram cerca de 1 milhão de dispositivos, até 2020 quando é estimado que haverá mais de 50 bilhões de dispositivos ligados na rede, sendo que atualmente existem cerca de 35 bilhões de dispositivos conectados. Em [Ihsmarkit 2018] é apresentado o número de dispositivos conectados à rede em 2018, por setores industriais e comerciais, onde quase a metade é na área de comunicação. O crescimento expressivo do número de dispositivos ligados na internet, tem naturalmente provocado um crescimento importante da energia consumida na internet das coisas. Até quando teremos energia para atender esta demanda crescente? Portanto, faz-se necessário o uso de técnicas para diminuir ao máximo o consumo de energia de cada dispositivo ligado na internet das coisas.

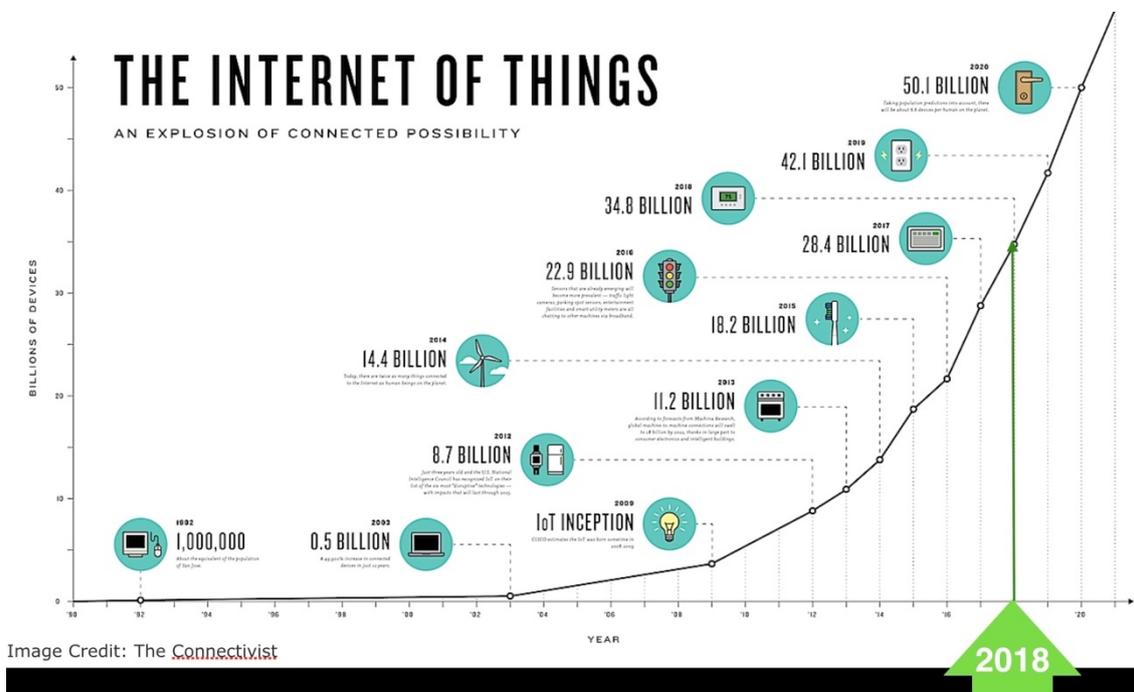


Figura 2. Número de dispositivos conectados na Internet [adaptado de The Connectivist 2014]

Em áreas críticas, como no projeto de dispositivos (chips) implantados em seres humanos (Figura 3), a confiabilidade dos sistemas implantados é evidentemente fundamental. Algumas das técnicas usadas são baseadas na triplicação de circuitos e na análise temporal da propagação de um sinal. Antigamente o projeto de circuitos tolerantes a falhas provocadas por radiação era essencialmente em circuitos que iam para o espaço. Com a redução do valor da tensão de alimentação de circuitos integrados, atualmente, mesmos os circuitos integrados para uso no nível terrestre são sensíveis a erros provocados pela radiação incidente na terra. Portanto, em áreas críticas como em chips implantados em seres humanos, é necessário implementar técnicas de tolerância a efeitos de radiação [Velazco 2007].

Além disso, há o efeito de “aging”, ou seja, o envelhecimento do circuito, que é mais eminente nas tecnologias nanométricas [Vasquez et al 2012]. Um dos efeitos mais importantes é conhecido como NBTI (“*Negative Bias Temperature Instability*”) que altera a tensão de limiar (*threshold*) dos transistores PMOS, degradando o funcionamento do transistor. Outro efeito que provoca falhas em circuitos ao longo de sua vida é o efeito de eletromigração, que pode provocar curto circuitos ou rompimento de conexões. Para aumentar o tempo de vida dos chips é necessário o uso de técnicas de projeto físico que diminuem a probabilidade de ocorrer eletromigração [Posser 2017]



**Figura 3. A implantação de Sistemas em Chip em seres humanos demanda confiabilidade e ultrabaixo consumo**

### 3. Ferramentas de EDA (Electronic Design Automation)

O uso de ferramentas de EDA é fundamental para a otimização do consumo de energia e aumento de confiabilidade. Na Figura 4 podemos visualizar a planta baixa de um circuito integrado, onde as cores mais quentes mostram regiões (*hot spots*) com um

maior consumo de energia, mostrando que em alguns pontos existe uma concentração significativa do consumo. Uma maneira de tratar o problema é modificar o posicionamento das células lógicas no circuito, de forma a distribuir melhor sobre toda a área do circuito as células com maior consumo de energia. Mas isto deve ser efetuado sem comprometer as especificações de área e de frequência de funcionamento (muito depende do roteamento). Outra maneira é diminuir o número de transistores, pois o consumo estático está relacionado com o número de transistores [Reis 2011A].

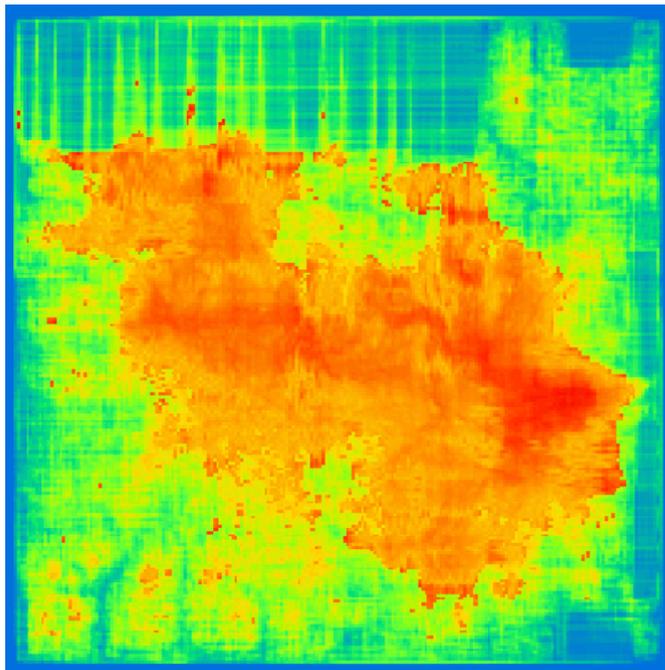
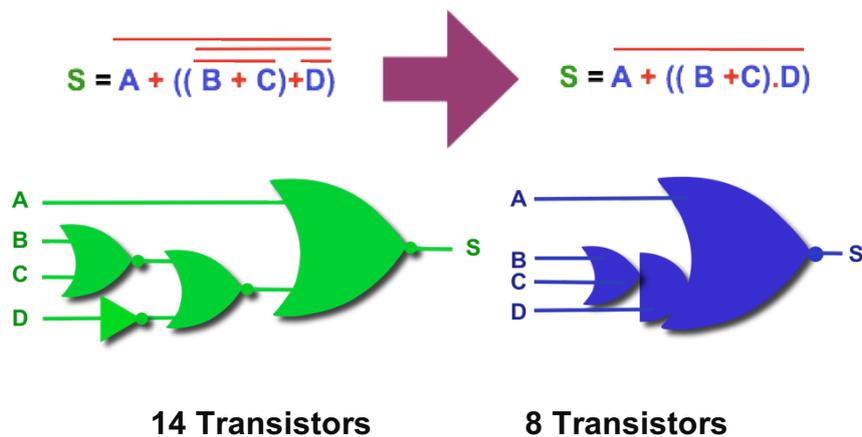


Figura 4. Visualização de densidade de consumo em um chip

#### 4. Redução de consumo através da redução do número de transistores

A redução do consumo de um sistema em um chip é função de uma soma de técnicas e estratégias de projeto aplicadas em diferentes níveis de abstração da concepção de um sistema integrado [Reis 2010]. O somatório dos ganhos é que vai definir o ganho total. Quanto tratamos da síntese física de um sistema em um chip, uma das técnicas é a **otimização** do número de componentes, ou seja, do número de transistores. Na Figura 5 [Reis 2011A] podemos observar duas soluções para a implementação de uma mesma equação. A primeira solução faz uso de 4 portas lógicas básicas (3 portas NOR de 2 entradas e um inversor CMOS), usando um total de 14 transistores. A segunda solução faz uso de apenas uma porta lógica, que executa a mesma função, mas com apenas 8 transistores. Ou seja, a segunda solução, por ter uma redução do número de transistores, também terá um consumo estático proporcionalmente menor. O valor percentual da redução do consumo de potência vai depender do nó tecnológico em que o circuito será implementado. Quanto menor o nó tecnológico, maior tende a ser o consumo estático, devido ao aumento da corrente de fuga. E também varia em função do tipo de tecnologia utilizada, Bulk CMOS, FinFet ou FDSOI, por exemplo. Além disto, no exemplo da Figura 5, podemos ver que a primeira solução possui também 3 conexões entre as portas básicas (e, portanto, também vias e contatos) que são eliminadas na segunda opção com apenas uma porta lógica. Esta eliminação de conexões é cada vez

mais importante, porque diminui o número de conexões a serem implementadas usando as diferentes camadas metálicas. A diminuição do número de conexões diminui a densidade de conexões e, portanto, aumenta a roteabilidade do circuito e contribui também para diminuir o comprimento médio das conexões, o que implica em uma redução do atraso, pois nas tecnologias modernas o atraso em conexões é tão ou mais importante que o atraso no chaveamento das portas lógicas. Um maior espaçamento entre as conexões, também contribui para um aumento da confiabilidade, devido, por exemplo, à redução da possibilidade de eletromigração, conforme já citado anteriormente.



**Figura 5. Duas opções para a implementação de uma mesma função [Reis 2011A]**

A redução do número de transistores passa pela utilização de ferramentas de EDA (*Electronic Design Automation*) eficientes que efetuem a transformação das equações lógicas de um sistema de forma que além de corresponderem a equações mapeáveis em portas CMOS, façam um uso otimizado de portas lógicas complexas. Em [Conceição 2016] apresentamos uma ferramenta visando reduzir o número de transistores de circuito através da fusão de redes de transistores que apresentam fan out igual a 1. Além disto é fundamental o uso de uma ferramenta de síntese automática de leiaute que consiga efetuar a realização física de qualquer função lógica. Não adianta efetuar uma otimização lógica, se depois for necessário mapear (transformar) as equações em função das portas lógicas disponíveis em uma biblioteca de células tradicional [que não possui poucas funções], como ainda é efetuado nos sistemas comerciais de EDA. Com este objetivo, temos desenvolvido ferramentas de síntese automática de leiaute, como o ASTRAN [Ziesemer 2015] (Figura 6), que permite a geração automática do leiaute de qualquer rede de transistores [Reis 2011].

Outra técnica para a redução de consumo é através do dimensionamento dos transistores. As tecnologias modernas de fabricação de circuitos integrados apresentam um aumento expressivo do consumo estático que chega a ser muitas vezes maior do que o consumo dinâmico. Uma maneira de mitigar o consumo, especialmente o estático é efetuar um dimensionamento de transistores visando otimizar o consumo. Em [Reimann 2016] são obtidas diminuições importantes do consumo através de ferramentas de dimensionamento automático de transistores, também denominadas de seleção de células.

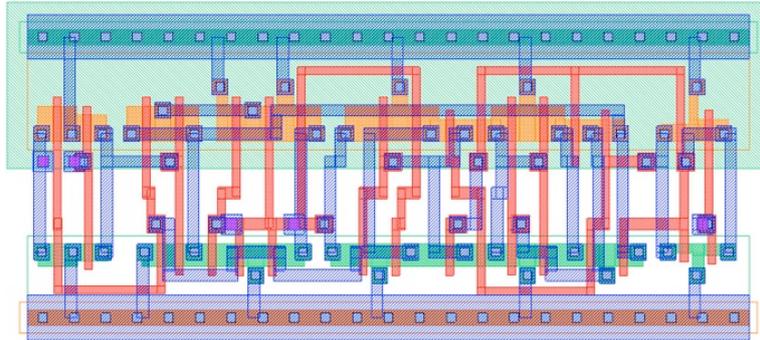


Figura 6. Duas opções para a implementação de uma mesma função [Zieseimer 2015]

## 5. Confiabilidade

Assim como na redução de consumo, no projeto de sistemas críticos, devemos usar técnicas de aumento da confiabilidade em diversos níveis de abstração. No nível arquitetural, uma técnica muito aplicada é a redundância de módulos, especialmente redundância tripla de módulos (TMR) [Kastensmidt 2006]. Outra é a redundância temporal [Nicolaidis 1999] onde um sinal percorre dois caminhos um com retardo e outro sem retardo, retardo este que deve ser maior do que o tempo de vida de um transiente. A comparação do sinal após percorrer os dois caminhos indica se houve a propagação de um transiente ou não. No nível físico podemos aplicar diferentes técnicas para reduzir ou evitar problemas como eletromigração [Posser 2015]. No exemplo da Figura 7, a posição do pino de saída no centro (ponto 4) aumenta o tempo de vida do circuito pois permite reduzir a densidade máxima de corrente nos segmentos da camada metálica.

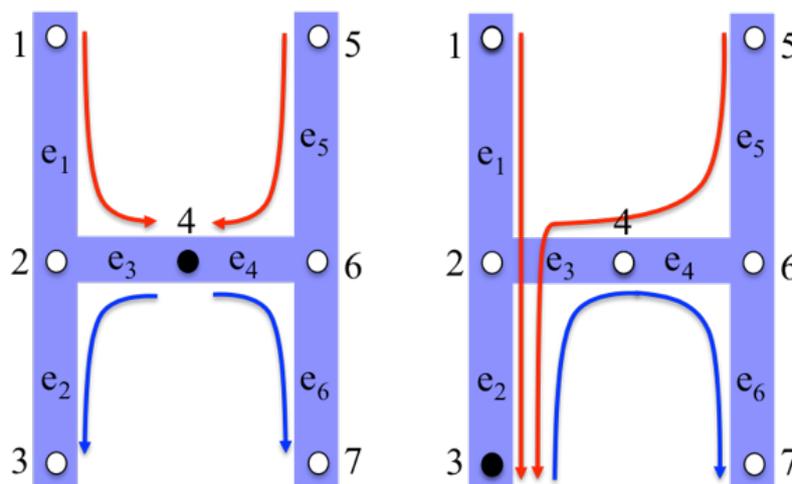


Figura 7. Mudança de densidade de corrente com a mudança de posicionamento do pino de saída [Posser 2015]

Em [Velazco 2007] é apresentado uma série de trabalhos visando mitigar efeitos de radiação em circuitos integrados. Em [Kastensmidt 2006] [Neuberger 2014] [Gennaro 2017] [Aguiar 2016] [Lazzari 2011] [Reis 2011B] são apresentados alguns

dos resultados que obtivemos no desenvolvimento de técnicas visando o projeto tolerante a falhas devido a transientes como os decorrentes de efeitos de radiação.

## 6. Aceleradores de Hardware

A evolução das arquiteturas de computadores, leia-se hoje, arquiteturas de microprocessadores tem sido significativa. Na década de 70, um argumento de marketing dos produtores de microprocessadores era o número de instruções que o microprocessador poderia executar assim como a frequência do relógio do microprocessador. Nas últimas décadas houve uma mudança de paradigma, descontinuando a corrida pelo aumento da frequência do relógio, devido a que o incremento do relógio significa aumento do consumo. Em vez disto houve um incremento do número de núcleos (CPUs) visando o aumento do desempenho. Inicialmente com núcleos homogêneos e posteriormente núcleos de processamento heterogêneos. Muitos dos dispositivos conectados na Internet das Coisas possuem SoCs integrados. Portanto, é importante reduzir o consumo dos mesmos. Um dos dispositivos de grande relevância em IoT são os *smartphones*, que são verdadeiros computadores portáteis, e que possuem SoCs com um conjunto expressivo de funcionalidades e que demandam o uso de técnicas de baixo consumo.

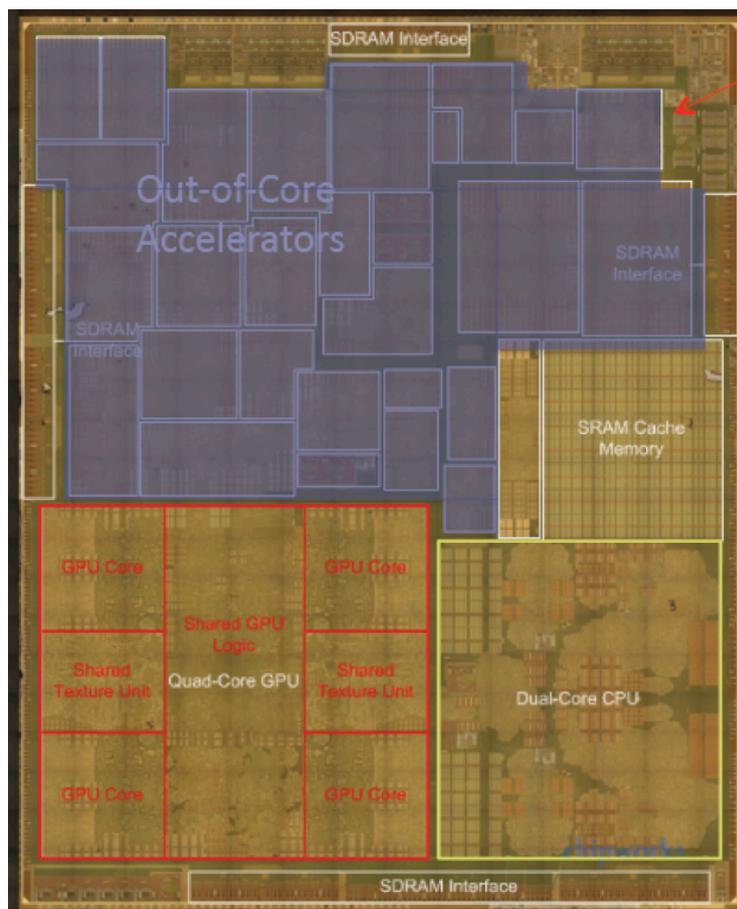


Figura 8. Planta Baixa do Apple 8 com 29 aceleradores de hardware [Anatech, 2014], [SHAO 2016]

Atualmente podemos encontrar chips (sistemas em chip) com várias CPUs e várias GPUs (Processadores Gráficos) na mesma pastilha (como pode ser visto na Figura 8 [Shao 2016] que mostra a planta baixa do microprocessador A8 da Apple). Nesta mesma Figura pode ser observado que cerca da metade da área é ocupada com aceleradores de hardware, que são módulos dedicados à execução de uma função específica. Por exemplo, um módulo de criptografia posicionado junto aos pinos de saída e que vai codificar os dados de saída e decodificar os dados recebidos. Com isto a execução desta função será mais rápida, por ser um módulo dedicado e com apenas o número de componentes para executar aquela função.

Um fato mais importante ainda é que o uso de aceleradores de hardware conduz a uma maior eficiência energética (permitindo uma computação mais sustentável), devido especialmente à redução do número de componentes utilizados para executar uma função. Em um determinado momento, apenas os aceleradores de hardware em uso naquele momento é que são alimentados, ou seja, os aceleradores que não estão em uso, são desconectados da alimentação de energia. Esta estratégia é também conhecida como “Dark Silicon”. Podemos até prever arquiteturas compostas essencialmente por aceleradores de hardware, tendo apenas uma ou duas pequenas CPUs para gerenciar os aceleradores de hardware.

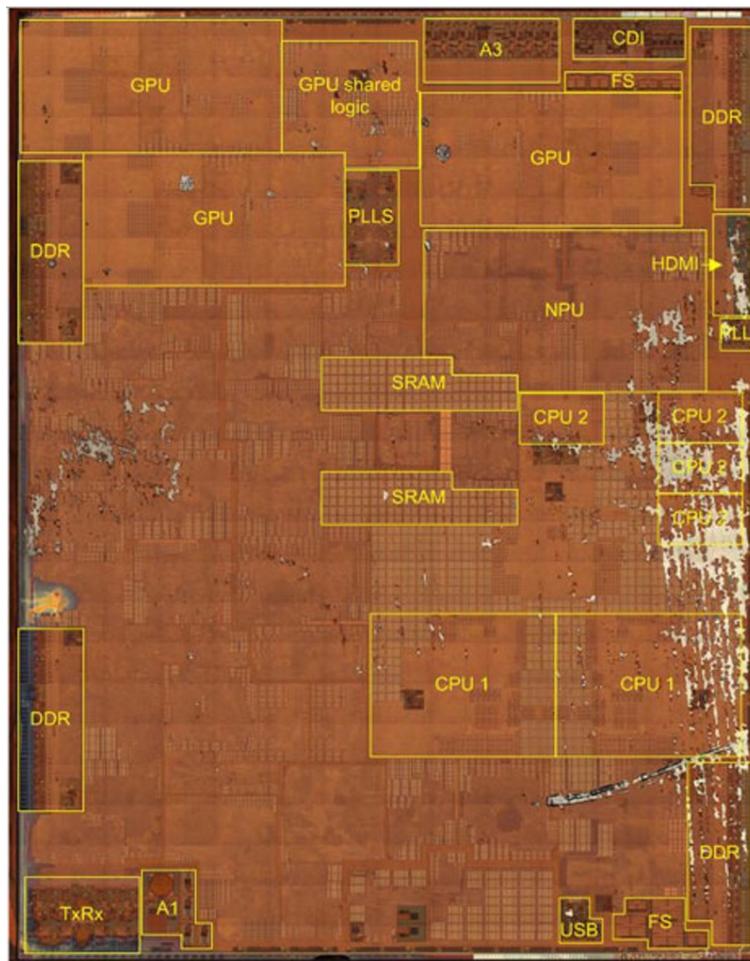


Figure 9. Planta Baixa do Apple 11 com uma NPU [Techinsights, 2017]

Na Figura 9 [Techinsights, 2017] é apresentada a planta baixa do microprocessador A11 da Apple, onde um dos módulos é uma NPU (Neural Processing Unit). A NPU está dedicada essencialmente para o reconhecimento facial [Techinsights, 2017], processando tarefas de aprendizado de máquina de maneira mais eficiente, consumo menos energia do que se fossem realizadas pelas CPUs. As CPUs ocupam cerca de 15% da área do chip e as 6 GPU ocupam cerca de 20%, sendo a maior parte ocupada com aceleradores de hardware. Ou seja, é crescente na arquitetura da linha de microprocessadores da Apple o uso de aceleradores de hardware.

A introdução de uma NPU no A11 é mais um elemento caracterizando a heterogeneidade do SoC (sistema em chip). E podemos esperar arquiteturas cada vez mais heterogêneas, com módulos dedicados para diferentes operações a serem executadas pelo SoC. Com isto podemos esperar dispositivos complexos conectados na Internet das Coisas, mas com um consumo de potência reduzido.

## 7. Conclusões

Para termos uma computação sustentável, onde é crescente o número de dispositivos conectados na internet das coisas, é fundamental o projeto de dispositivos que sejam **otimizados** em termos de consumo de energia. Atualmente, a maioria dos chips produzidos usam muito mais transistores do que o necessário para executar uma função havendo um espaço significativo para a otimização do número de componentes. Em muitos dispositivos relacionados a aplicações críticas, é também fundamental a aplicação de técnicas visando a tolerância a falhas. Quanto ao consumo, a redução do mesmo deve ser tratada em todos os níveis de abstração em um fluxo de síntese de sistemas integrados, desde a especificação dos mesmos em linguagens de alto nível, até a síntese física. Foram apresentados diversos trabalhos que temos desenvolvido visando a redução do consumo e aumento da confiabilidade de sistemas integrados em chip, sendo que maiores detalhes são apresentados nas referências citadas. A palavra chave na era da internet das coisas é **otimização**.

## 8. Agradecimentos

Agradecemos o apoio do CNPq, FINEP, Fapergs e CAPES pelo apoio financeiro ao desenvolvimento dos trabalhos de nossa equipe, assim como aos alunos de mestrado e doutorado do PGMICRO e PPGC e alunos de Iniciação Científica que tem contribuído com os trabalhos de pesquisa que serviram de base para este artigo.

## References

- AGUIAR, Y., ZIMPECK, A., MEINHARDT, C., REIS, R. (2016), “Permanent and Single Event Transient Faults Reliability Evaluation EDA Tool”, *Microelectronics Reliability*, Volume 64, September 2016, Pages 63-67, published by Elsevier B.V., 2016. ISSN: 0026-2714.
- ANANTECH (2014), <https://www.anandtech.com/show/8562/chipworks-a8>
- CONCEIÇÃO, C., MOURA, G., PISONI, F., REIS, R. (2017), “A Cell Clustering Technique to Reduce Transistor Count”, 24<sup>th</sup> IEEE International Conference on Electronics, Circuits and Systems – ICECS2017, Batumi, Georgia, December 5 - 8, 2017, p. 186-189, DOI [10.1109/ICECS.2017.8291996](https://doi.org/10.1109/ICECS.2017.8291996)

- GENNARO, R., ROSA, F., OLIVEIRA, A., KASTENSMIDT, F., OST, L., REIS, R. (2017), “Analyzing the Impact of Fault Tolerance Methods in ARM Processors under Soft Errors Running Linux and Parallelization APIs”, IEEE Transactions on Nuclear Science, Volume: 64, Issue: 8, August 2017, ISSN: 1558-1578, DOI: [10.1109/TNS.2017.2706519](https://doi.org/10.1109/TNS.2017.2706519)
- LAZZARI, C., WIRTH, G., KASTENSMIDT, F., ANGHEL, L., REIS, R. (2011), “Asymmetric Transistor Sizing Targeting Radiation-Hardened Circuits”, Journal on Electrical Engineering, Springer, DOI10.1007/s00202-011-0212-8, June 2011.
- KASTENSMIDT, F., CARRO, L.; REIS, R. (2006), “Fault-Tolerance Techniques for SRAM-Based FPGA”, Springer. April 2006, 183 p., ISBN 0-387-31068-1
- NEUBERGER, G., WIRTH, G., REIS, R., (2014) “Protecting Chips Against Hold Time Violations Due to Variability”, Springer, 107 p., 2014. ISBN 978-94-007-2426-6. DOI 10.1007/978-94-007-2427-3
- NICOLAIDIS, M. (1999), “Time redundancy based soft-error tolerance to rescue nanometer technologies”. In: IEEE VLSI TEST SYMPOSIUM, 17., 1999. Proceedings... IEEE Computer Society, 1999. p. 86-94.
- POSSER, G., FLACH, G., WILKE, G., REIS, R. (2011), “Gate Sizing Minimizing Delay and Area”, ISVLSI2011. IEEE Computer Society Annual Symposium on VLSI, Chennai, India, July 4-6, 2011. p. 315-316, ISBN 978-0-7695-4447-2. DOI 10.1109/ISVLSI.2011.92
- REIMANN, T., SZE, C., REIS, R. (2016), “Challenges of Cell Selection Algorithms in Industrial High Performance Microprocessor Designs”, Integration, Elsevier B. V., Volume 52, January 2016, Pages 347-354, ISSN: 0167-9260, doi:10.1016/j.vlsi.2015.09.001
- REIS, R., (2010) “Redução de Consumo pela Otimização de Componentes”, SEMISH 2010, Anais do 37º Seminário Integrado de Software e Hardware, Belo Horizonte, 21 a 22 de julho de 2010, p. 371-379, ISSN: 2175-2761.
- REIS, R. (2011A), “Design Automation of Transistor Networks, a New Challenge”. IEEE International Symposium on Circuits and Systems, ISCAS2011, Rio de Janeiro, Brasil, May 15-19, 2011. IEEE Press. p. 2485-2488, ISBN: 978-1-4244-9472-9. DOI 10.1109/ISCAS.2011.5938108
- REIS, R. (2011B), “Power Consumption & Reliability in NanoCMOS”, IEEE NANO, 11th International Conference on Nanotechnology, Portland, USA, August 15-19, 2011 (**invited talk**), p.711-714. ISBN 978-1-4577-1515-0, DOI:10.1109/NANO.2011.6144656
- The Connectivist (2014), <http://ow.ly/i/5vph6/original>
- The Economist (2010), 6 de setembro de 2010.
- SIA (2015), Semiconductor Industry Association, Rebooting the IT Revolution, disponível em <http://www.semiconductors.org/clientuploads/Resources/RITR%20WEB%20version%20FINAL.pdf>
- IHSMARKIT (2018), IoT Trend Watch 2018, disponível em: [https://ihsmarkit.com/forms/thankyou.html?efid=t+m2jEyFYkJOYyoP3YvuHA==&&asc\\_id=862037098&&gasc\\_label=scrXCLnM7m0Q6siGmwM](https://ihsmarkit.com/forms/thankyou.html?efid=t+m2jEyFYkJOYyoP3YvuHA==&&asc_id=862037098&&gasc_label=scrXCLnM7m0Q6siGmwM)
- Techinsights (2017), <http://techinsights.com/about-techinsights/overview/blog/apple-iphone-8-teardown/>

- VAZQUEZ, J., CHAMPAC, V., ZIESEMER, A., REIS, R., TEIXEIRA, I., SANTOS, M. e TEIXEIRA, P. (2012), “Delay Sensing for Long-Term Variations and Defects Monitoring in Safety–Critical Applications”, IN: Analog Integrated Circuits and Signal Processing, Volume 70, Number 2, 249-263, February 2012, Springer, ISSN 0925-1030, DOI: 10.1007/s10470-011-9789-0.
- VELAZCO, R , FOUILLAT, P, REIS, R. (2007), “Radiation Effects on Embedded Systems”, Springer, June 2007. ISBN 978-1-4020-5645-1
- Yakun Sophia Shao (2016), “Design and Modeling of Specialized Architectures, PhD Thesis, Harvard”, May 2016. Available at: <https://ysshao.github.io/papers/shao2016-dissertation.pdf>
- ZIESEMER, A., REIS, R. (2015), “Physical Design Automation of Transistors Network”, Microelectronics Engineering, V. 148, p. 122-128, December 2015, Elsevier B.V., ISSN: 0167-9317, doi:10.1016/j.mee.2015.10.018

# Controladores, tratamento de sinais e programação aplicados à piscicultura

Gabriel Oliveira Ferreira<sup>1</sup>, Luís Filipe Pereira Silva<sup>2</sup>

<sup>1 2</sup> Engenharia Mecatrônica – Centro Federal de Educação Tecnológica (CEFET-MG)  
Caixa Postal 400 – 91.35.503-822 – Divinópolis – MG – Brasil

{gabriel,luis}gabrielolifer95@gmail.com, luis@cefetmg.br

**Abstract.** *In this article is presented the development of closed loop control techniques that optimize the fish production in closed environment, by controlling the water temperature. It is possible to see that plenty of rudimentary techniques are still used in this area, which involves a lot of money, R\$ 2.02 billions in revenue just in 2013, according to IBGE. There is, in this project, the process automation using microcontrollers, sensors and actuators. With the system's mathematics models, that will provide enough data about the water temperature, digital controllers are calculated and programmed on the microcontroller used throughout the project, boosting the fish's growth and reproduction.*

**Resumo.** *Neste artigo é apresentado o desenvolvimento de técnicas de controle em malha fechada, visando a otimização da produção de peixes em cativeiro por meio do controle de temperatura da água onde eles estão situados. Vê-se que muitas técnicas rudimentares são aplicadas em tal meio, que circula grandes quantias de dinheiro, 2,02 bilhões apenas em 2013, de acordo com o IBGE. No projeto em questão, tem-se automação do processo por meio de microcontroladores, sensores e atuadores. Com a modelagem dos sistemas físicos que descrevem a dinâmica da temperatura da água, compensadores digitais são calculados e, então programados no microcontrolador utilizado ao longo do projeto, potencializando o crescimento e reprodução dos peixes.*

## 1. Introdução

A automação está presente em diversos segmentos, sendo possível verificar sua utilização em grande escala na agricultura. De acordo com [A. Alvarenga 2014], através de sensores, atuadores e algoritmos computacionais, consegue-se aumento na prosperidade de cultivos, além de possibilitar economia de água, visto que, no Brasil, cerca de 72% desse recurso é usado para tal finalidade [C. Cremasco 2015]. Atualmente, vê-se que vários projetos sobre tanques voltados para a piscicultura são estudados, como pode ser visto em [A. Cardoso 2016] e [M. Mallasen 2012]. Isso pode ser explicado pela necessidade de otimizar a produção de peixes, buscando seu crescimento e reprodução máximos em um tempo mínimo. Há diversos estudos acerca do controle de temperatura da água em ambientes fechados, o que pode impactar diversas áreas, como em técnicas de reversão sexual dos peixes. Para maiores detalhes, veja [A. Correia 2006].

Quando se deseja controlar um sistema, uma das formas mais eficazes é colocá-lo em malha fechada com um compensador. Tendo um controlador projetado de forma adequada, garante-se estabilidade, robustez a variação de parâmetros do modelo do sistema

e atenuação do efeito de ruídos [R. Dorf 2009]. Os controladores PID são constituídos de três ações: proporcional, integral e derivativa, sendo que as três em conjunto garantem características de regime transitório e estacionário desejadas [Ogata 2010]. Na agricultura, tal estratégia é muito utilizada para controlar a temperatura de ambientes fechados, evitando variações climáticas muito acentuadas [O. Santos 2017].

Neste artigo, propõe-se um sistema de tanques voltados para piscicultura que, a partir de controladores PID's, consiga levar a temperatura da água para 28°C, ideal para as tilápias [Abrunhosa 2011], que, de acordo com [M. Bandeira 2017], é a espécie mais produzida no país. Para tanto, trata-se, ao longo do texto, sobre a modelagem matemática dos tanques, projeto de compensadores discretos no tempo para os mesmos e sobre os melhores atuadores e sensores para a construção de um protótipo onde os estudos podem ser testados e validados.

## 2. Trabalhos Relacionados

Recentemente, verifica-se uma grande evolução no desenvolvimento de aplicativos que auxiliam no monitoramento dos ambientes aquáticos, onde técnicas de controle são aplicadas. Por meio de *softwares*, é possível identificar e analisar se as grandezas estão com grau de controle satisfatório ou se alguma ação corretiva deve ser tomada. De acordo com [G1], a tecnologia vem ganhando cada vez mais espaço entre os piscicultores, pois “em vez de percorrer os tanques com pranchetas na mão, os tratadores agora levam *tablets*” e “programas de computador e aplicativos ajudam no planejamento da criação”.

Dentre as empresas que inserem tecnologia na aquicultura, é possível destacar a *Aquiculture Production Technology Ltd.* Ela atua em 30 países de 5 continentes e realiza todas as etapas de projeto, como controle de temperatura, pH, quantidade de amônia, claridade da água, etc.

Em relação aos novos estudos sobre inserção tecnológica no meio da piscicultura, os mais relevantes estão sendo realizados na Europa e América do Norte. Este último, realizado no Canadá, planeja integrar as áreas de aquicultura, agricultura e energia renovável, sendo necessárias tecnologias vindas da Alemanha, Canadá e Israel.

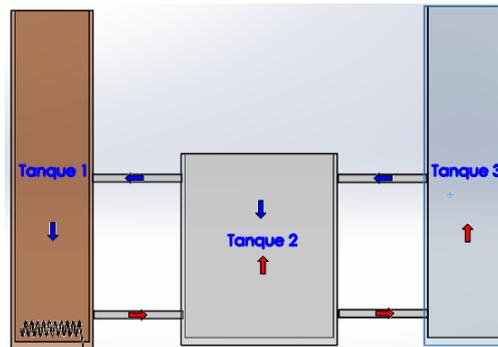
## 3. Desenvolvimento

Os peixes são animais peclotérmicos [P. Rebouças 2014], logo sua temperatura corporal varia de acordo com o ambiente em que estão submetidos, o que pode acarretar diversas consequências indesejadas em seu cultivo. De acordo com [A. Ostrensky 1998] “quando a temperatura da água varia, todo metabolismo do peixe é afetado. Em temperaturas mais altas, os peixes de clima quente comem mais, ficam mais ágeis, crescem mais; quando a temperatura cai, os peixes deixam de comer e diminuem bastante seu ritmo biológico”. Dentre as diversas variáveis que influenciam na qualidade da água e impactam no desenvolvimento dos peixes além da temperatura, é possível citar: pH, oxigênio dissolvido, amônia, transparência da água, etc.[Kubitza 2011].

O funcionamento do sistema de tanques proposto segue a seguinte metodologia: tem-se água separada em três reservatórios distintos, em que no primeiro a água é controlada a 35°C, no segundo a 28°C e no terceiro, o fluido está na temperatura ambiente. A água que possui maior quantidade de calor (setas vermelhas) é bombeada sempre na parte

inferior da planta, favorecendo as trocas de calor por convecção devido à sua densidade inferior [S. Vilar 2010], conforme Figura 1. Já as setas azuis representam a água com menor quantidade de calor, possuindo maior densidade.

Caso o tanque 2 (local onde os peixes são posicionados) necessite adquirir calor, o mesmo recebe água do primeiro reservatório; caso necessite diminuir sua temperatura, recebe água do tanque 3.



**Figura 1. metodologia de circulação da água**

Para realizar a medição de temperatura, usa-se o sensor DS18B20, que trabalha de  $-55^{\circ}\text{C}$  a  $125^{\circ}\text{C}$ , possui resolução de  $0,25^{\circ}\text{C}$  e um tempo de conversão de temperatura de 187,5 milissegundos (dados obtidos a partir do datasheet do produto).

Já para possibilitar que os tanques forneçam água um para o outro, são usadas 4 bombas do modelo Brushless DC Pump, que possuem tensão de trabalho de 12 V e corrente nominal de 0,35 A; suas vazões máximas são de 60 ml por segundo. Para acioná-las, utiliza-se o módulo de ponte H-L298N, visto que o mesmo consegue alimentá-las com valores de 0V a 12V, de acordo com tensão aplicada em uma de suas entradas.

O princípio usado para controlar a vazão de saída das bombas é o PWM, em que a entrada da ponte H recebe 0V ou 5V com determinada largura de pulso, possibilitando que em sua saída tenha o valor correspondente com a mesma largura de pulso, porém com sinais de 0V ou 12V. Variando o período em que o sinal de saída do microcontrolador está em nível lógico alto, tem-se uma faixa de tensão recebida pelas bombas (de 0V a 12 V), a partir de um sinal digital [N.Tomazio 2017].

O atuador presente no tanque 1 é uma resistência elétrica, que possui potência de 4000 W e tensão nominal de 220 V. Para seu acionamento, foi utilizado um relé de estado sólido do tipo SSR-25, que pode chavear tensões entre 24 e 380 V AC, sendo acionado apenas por 3 V DC.

### 3.1. Modelagens

Para o tanque 1, tem-se o seguinte cenário: a resistência elétrica cede determinada quantidade de calor por unidade de tempo (J/s), sendo que tal grandeza é absorvida pela água ou perdida por convecção entre as paredes do tanque e o meio, que se encontra em uma temperatura mais baixa, situação representada pela Equação 1. Destaca-se que os tanques são de vidro, material que possui baixa condutividade térmica, reduzindo as perdas de calor.

$$P_{res} = \dot{Q}_{absorvido} + \dot{Q}_{convec\cacao} \quad (1)$$

onde  $P_{res}$  representa a potência da resistência (Watts),  $\dot{Q}_{absorvido}$  o calor absorvido pela água por segundo (J/s) e  $\dot{Q}_{convec\cacao}$  o calor perdido por convecção para o meio (J/s).

Da Equação (1), pode-se chegar a Equação (2).

$$P_{res} = m_1 \cdot C \cdot \frac{\delta T}{\delta t} + h_{ar} \cdot A \cdot (T_p - T_f) \quad (2)$$

onde  $m_1$  representa a massa de água presente no tanque 1 (Kg),  $h_{ar}$  o coeficiente de convecção do ar ( $5-30 \frac{W}{m^2 \cdot K}$ ),  $A$  é a área total do tanque ( $m^2$ ),  $T_p$  a temperatura da superfície de vidro ( $^{\circ}C$  ou K),  $T_f$  a temperatura ambiente ( $^{\circ}C$  ou K) e  $C$  o calor específico da água ( $J/Kg \cdot ^{\circ}C$ );

Aplicando a Transformada de Laplace na Equação (2), tem-se a Equação (3):

$$\frac{T(s)}{P_{res}} = \frac{1}{\frac{m_1 \cdot C}{h_{ar} \cdot A} s + 1} \quad (3)$$

O processo de obtenção das equações que descrevem a dinâmica do tanque 2 se dá de forma similar à vista acima. Conforme já citado, a energia absorvida pela água nesse recipiente advém da água aquecida pela resistência elétrica, Equação (4).

$$\dot{Q}_q = \dot{Q}_2 + \dot{Q}_{convec\cacao2} \quad (4)$$

onde  $\dot{Q}_q$  representa a quantidade de calor cedida pela água quente por segundo ( $J/s$ ),  $\dot{Q}_2$  a quantidade de calor absorvida pela água do tanque 2 por segundo ( $J/s$ ) e  $\dot{Q}_{convec\cacao2}$  é a quantidade de calor perdida pelo tanque 2 por convecção para o meio ( $J/s$ ).

Da Equação (4) pode-se inferir a Equação (5):

$$\dot{Q}_q = m_2 \cdot C \cdot \frac{\delta T}{\delta t} + h_{ar} \cdot A_2 \cdot (T_{p2} - T_f) \quad (5)$$

onde  $m_2$  é a massa de água presente no tanque 2 (Kg),  $A_2$  representa a área da região de contato entre água e ar ( $m^2$ ) e  $T_{p2}$  é a temperatura da água presente no tanque 2 ( $^{\circ}C$  ou K);

Aplicando a Transformada de Laplace na Equação (5), tem-se a seguinte função de transferência:

$$\frac{T(s)}{\dot{Q}_q} = \frac{1}{\frac{m_2 \cdot C}{h_{ar} \cdot A_2} s + 1} \quad (6)$$

Conforme pode ser verificado nas Equações (3) e (6), a modelagem dos tanques está em função das variáveis que influenciam no processo. Esse procedimento possibilita modelar a planta para diversas dimensões. Como se trata de um protótipo, definiu-se

medidas que possibilitassem simular o ambiente em questão, apresentando constantes de tempo relativamente elevadas, cerca de 5.700 segundos para o tanque 1 e 42.000 para o segundo (em malha aberta).

### 3.2. Projeto dos controladores

Os compensadores calculados para os dois recipientes são projetados pelo método Lugar das Raízes. Como o tanque 1 não possui um atuador que diminui a temperatura da água, seu controlador age de forma que o sistema não apresente *overshoot* (seus polos em malha fechada não possuem componentes imaginárias). Fixando o tempo de acomodação em 100 segundos, calcula-se a função de transferência do controlador, apresentada pela Equação (7).

$$G_c(s) = \frac{312 \cdot (s + 5,3 \cdot 10^{-3})}{s} \quad (7)$$

Visando embarcar o sistema e ganhos de processamento, aplica-se técnicas de Controle Digital. Sendo assim, o primeiro passo é determinar o período de amostragem do sistema; para tal, faz-se uso do Critério de Nyquist, que afirma que a frequência de amostragem deve ser maior que, no mínimo, o dobro daquela apresentada pelo sinal que se deseja amostrar [Lathi 2011]. Por conseguinte, através do diagrama de Bode, determina-se a frequência de corte da planta em malha fechada (0,0385 rad/s) e o período de amostragem adequado para discretizar a Equação (7) no tempo: 1,7 segundos.

O método de integração numérica utilizado para a discretização do controlador é o de Tustin. Com o período de amostragem e o método de integração definidos, é possível calcular a função de transferência discreta no tempo do controlador contínuo definido acima, Equação (8).

$$G_c(z) = \frac{U(z)}{E(z)} = \frac{312,21 \cdot (z - 0,9989)}{z - 1} \quad (8)$$

Para inserir a função de transferência do compensador no microcontrolador, faz-se necessário o cálculo de sua equação a diferença, Equação (9):

$$u(k) = 312,21 \cdot e(k) - 311,866 \cdot e(k - 1) + u(k - 1) \quad (9)$$

Sendo que  $k$  representa amostras coletadas pelo microcontrolador,  $u$  o sinal de controle e  $e$  a função de erro do sistema em malha fechada.

Para o tanque 2, define-se 2 % de *overshoot* e um tempo de acomodação de 100 segundos. Dessa forma, tem-se que água está sempre bem próxima da temperatura ideal para os peixes, 28°C. A função de transferência do compensador projetado pode ser verificada na Equação (10).

$$G_c(s) = \frac{89,67s + 0,002134}{s(s + 0,08)} \quad (10)$$

Assim como feito para o controlador anterior, tem-se a representação discreta no tempo da função do controlador apresentada na Equação (10), com período de amostragem de 2s:

$$C_d(z) = \frac{U(z)}{E(z)} = \frac{83,03.z^{-2} + 0,002134.z^{-1} - 83,03}{z^{-2} - 1,852.z + 0,8519} \quad (11)$$

E, a seguir, tem-se a equação a diferença da função de transferência (11).

$$u(k) = 83,03.e(k) + 0,003952.e(k-1) - 83,03.e(k-2) + 1,852.u(k-1) - 0,8519.u(k-2) \quad (12)$$

## 4. Resultados

### 4.1. Tanque 1

A partir da planta montada, instrumentada e com sensores e atuadores calibrados, é possível aplicar várias entradas no sistema e no modelo, a fim de verificar se esse descreve a dinâmica daquele. Então, aplica-se dois degraus na planta (o primeiro logo no início da simulação e o segundo com cerca de 6200 segundos); após decorridos 185 minutos, retirou-se os degraus aplicados. O mesmo procedimento é realizado no modelo matemático, sendo possível verificar o comportamento de ambos na Figura 2. Nela, constata-se resultado satisfatório, visto que as constantes de tempo das duas curvas possuem valores muito próximos, além de tenderem para os mesmos valores finais, podendo-se dizer que o modelo foi validado.

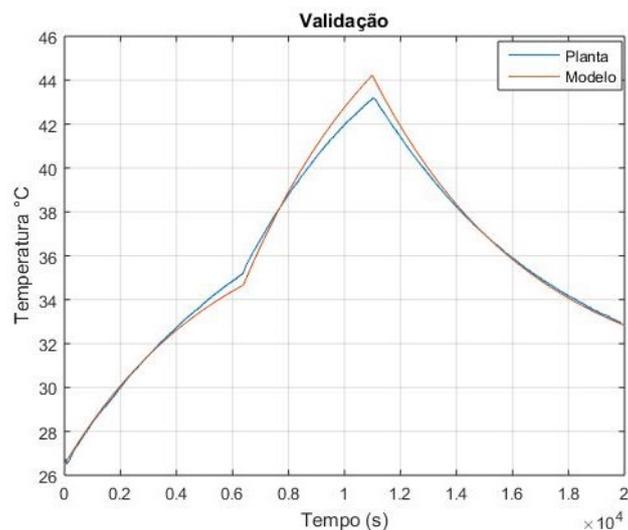
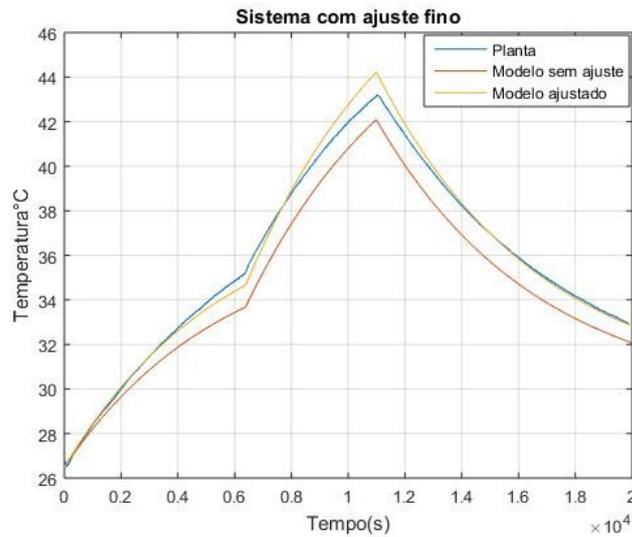


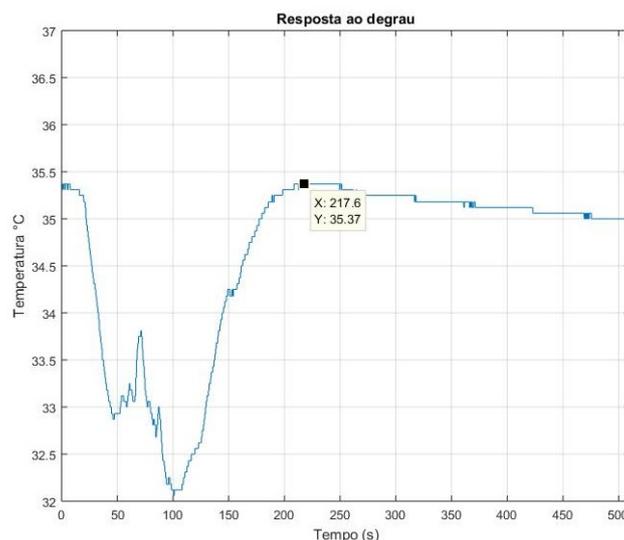
Figura 2. Validação do modelo

Entretanto, para atingir o resultado eficaz acima, é necessário realizar um ajuste fino no ganho do modelo calculado, como mostrado Figura 3. Multiplicou-se a função por 1,05, número calculado dividindo-se o maior valor da curva em vermelho pelo maior da curva em azul.



**Figura 3. Ajuste fino realizado no modelo**

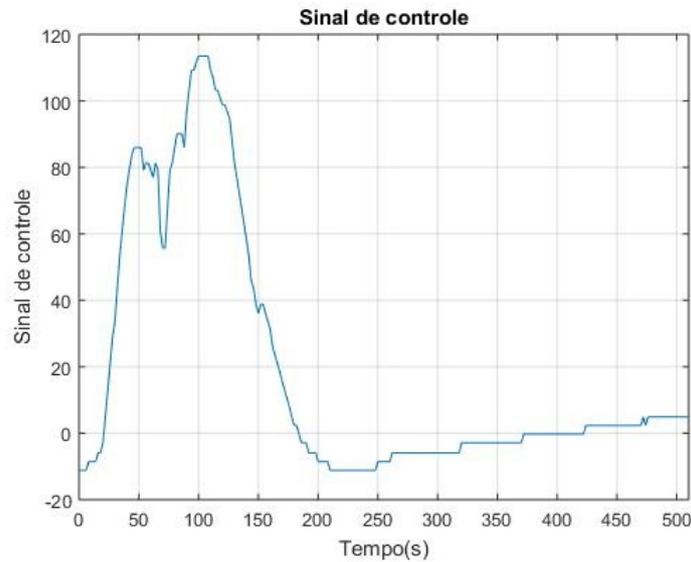
A partir do controlador discreto em forma de uma equação a diferença, obteve-se a malha fechada da planta. A partir de um degrau, obtido inserindo água em torno de 30°C no reservatório, é possível verificar a presença de 1,05 % de *overshoot* e um tempo de acomodação em torno de 90 segundos, para o critério de 2 %, considerados resultados satisfatórios, como mostrado na Figura 4. O teste consiste em inserir diversas perturbações na planta. Como pode-se verificar na imagem, no início da simulação, a água encontra-se em torno do ponto de operação (35°C), quando, de forma drástica, um líquido com temperatura mais baixa é inserida no sistema.



**Figura 4. Planta em malha fechada com Equação a diferenças**

Já na Figura 5, é apresentado o sinal de controle demandado para rejeitar as perturbações inseridas na planta. Como é possível verificar, no instante em que a temperatura da água começa a diminuir, o sinal de controle aumenta rapidamente, tornando-se menor na proporção em que o sistema aproxima-se de sua temperatura de referência, 35

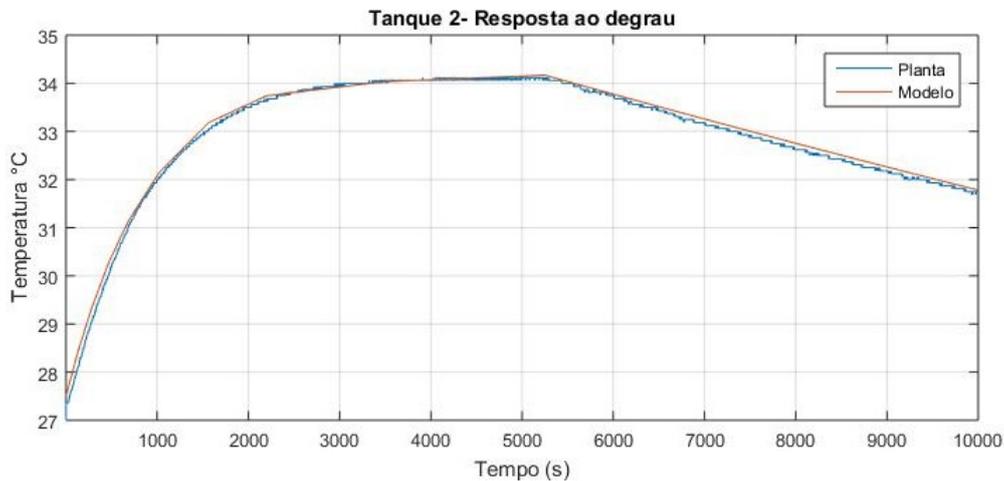
°C.



**Figura 5. Sinal de controle**

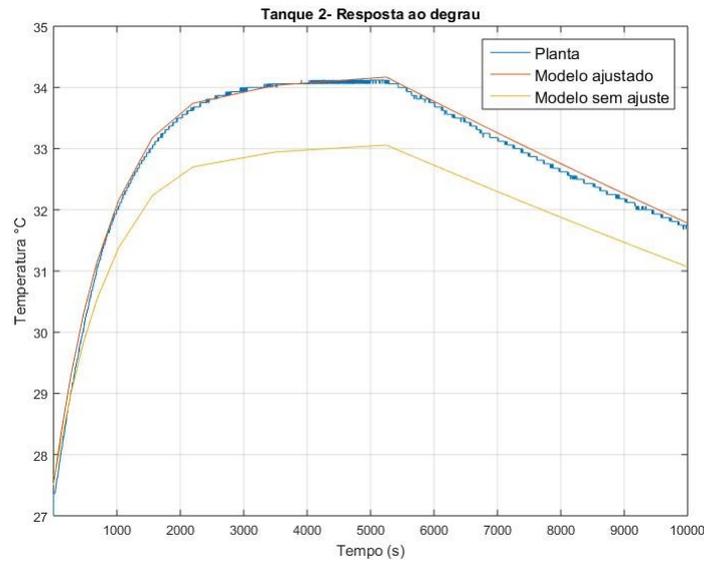
#### 4.2. Tanque 2

Diversas entradas são aplicadas no sistema com a finalidade de validar o modelo obtido anteriormente. Os mesmos degraus aplicados na planta são aplicados na função de transferência; a resposta obtida pode ser verificada na Figura 6.



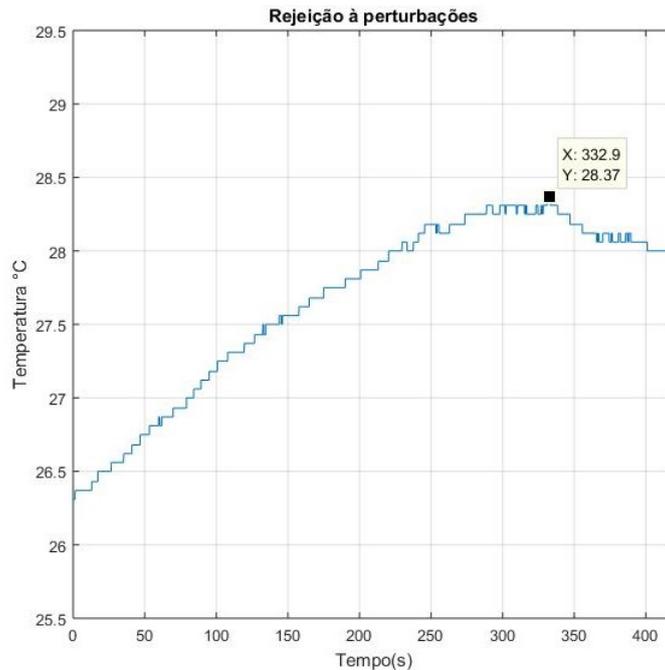
**Figura 6. Validação da modelagem- Tanque 2**

Através das curvas, é possível identificar que o modelo apresenta constante de tempo compatível com o sistema, bem como tende para valores finais muito próximos ao que ocorre com a planta. Outro fator importante a se destacar é a constante de tempo de descida, quando o degrau foi retirado; nesse momento (cerca de 5.200 segundos), percebe-se comportamento satisfatório do modelo, sendo possível constatar sua validação. Entretanto, é necessário realizar ajuste no ganho do mesmo, multiplicando-o por 1,2. Tem-se, na Figura 7, o modelo após ajuste comparado ao inicialmente calculado.



**Figura 7. Comparativo entre modelos com e sem ajuste fino**

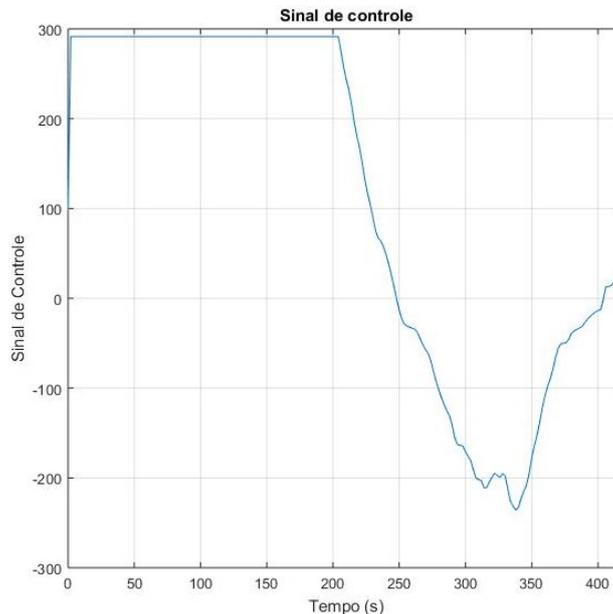
Com a validação concluída, é possível colocar a planta em malha fechada com a equação a diferença calculada. Tem-se, na Figura 8, a resposta do sistema. Nela é possível observar a presença de um *overshoot* de 1,32 %, dentro da margem calculada, acomodando-se em cerca de 150 segundos, para o critério de 2 %. O teste é realizado de acordo com a seguinte metodologia: quando o sistema estava em sua referência (28 °C), água com temperatura diferente de 28°C é inserida no mesmo.



**Figura 8. Sistema em malha fechada com Equação a diferenças**

Já na Figura 9 tem-se o sinal de controle demandado para tal. Nela é possível

verificar a ação do controlador, apresentando seu valor máximo quando a planta encontra-se distante do ponto de operação. Com a aproximação, o sinal de controle gradativamente diminui.



**Figura 9. Sinal de controle**

## 5. Conclusões

O presente artigo apresenta a definição do problema, sendo possível verificar grande investimento econômico na área da piscicultura. Nesse contexto, propôs-se o desenvolvimento de um tanque que controle a temperatura do fluido em  $28\text{ }^{\circ}\text{C}$ , ideal para as tilápias. Posteriormente, definiu-se a metodologia de funcionamento da planta: como as trocas de calor seriam efetuadas, bem como os componentes eletrônicos utilizados, como sensores de temperatura DS18B20, relé de estado sólido, Arduino, resistência elétrica, ponte H e as bombas de água. Após tal etapa, os tanques foram modelados e tais equações foram validadas, o que permitiu o projeto dos compensadores para os dois recipientes que teriam sua temperatura controlada. Visando embarcar o sistema e ganhos com processamento, houve a discretização no tempo dos controladores segundo a aproximação de Tustin. Por fim, os compensadores foram testados diretamente na planta construída, sendo possível observar resultados satisfatórios em relação ao controle de temperatura inicialmente proposto.

A primeira sugestão de trabalhos futuros é substituição do atuador elétrico. Mesmo que a resistência consiga fornecer a potência demandada pelo sistema, há a ideia de sua troca por energia solar, via painéis solares. Dessa maneira, o custo para manter a planta em funcionamento seria drasticamente menor, além de torná-la sustentável.

Outra recomendação é a inserção de torres de resfriamento no sistema, objetivando diminuir a temperatura da água presente no Tanque 3. É válido lembrar que o fluido em nesse recipiente encontra-se à temperatura ambiente; caso o atuador seja integrado, seria possível implementar uma malha de controle no Tanque 3, deixando sua temperatura abaixo da ambiente e acelerando as trocas de calor entre os reservatórios.

## 6. Referências

### Referências

- A. Alvarenga, V. Ferreira, M. F. (2014). *Energia solar fotovoltaica: uma aplicação na irrigação da agricultura familiar*.
- A. Cardoso, S. El-Deir, M. C. (2016). *Bases da sustentabilidade para atividade de piscicultura no semiárido de Pernambuco*.
- A. Correia, R. Moraes, J. L. e. F. S. (2006). *Reversão Sexual em Larvas de Tilápia-do-Nilo em Diferentes Condições Ambientais*.
- A. Ostrensky, W. B. (1998). *Piscicultura: fundamentos e técnicas de manejo*.
- Abrunhosa (2011). *Piscicultura*. e-Tec Brasil.
- C. Cremasco, D. C. e. L. S. (2015). Sistema de automação de irrigação do plantio.
- G1. <http://g1.globo.com/sao-paulo/sorocaba-jundiai/nosso-campo/noticia/2015/05/piscicultores-investem-em-tecnologia-para-modernizar-producao.html> Acesso em março de 2017.
- Kubitza, F. (2011). *Tilápia: tecnologia e planejamento na produção comercial*. Acqua Supre, 2nd edition.
- Lathi, B. (2011). *Sinais e Sistemas Lineares*. ARTMED EDITORA S.A., 2nd edition.
- M. Bandeira, J. N. (2017). *Estudo prospectivo relativo à atividade da tilápia para a indústria de alimentos no período de 2006 a 2016*.
- M. Mallasen, C. Carmo, A. T. (2012). *Qualidade da água em sistema de piscicultura em tanques-rede no reservatório de Ilha Solteira-SP*.
- N. Tomazio, A. Romero, C. M. (2017). *Desenvolvimento de um obturador de feixe óptico utilizando um disco rígido de computador*.
- O. Santos, J. Junior, M. N. (2017). *Sistema de Controle de Temperatura para um Estufa com Monitoramento via Aplicativo*.
- Ogata, K. (2010). *Engenharia de Controle Moderno*. Prentice Hall, 5th edition.
- P. Rebouças, L. Lima, I. D. J. F. (2014). *Influência da oscilação térmica na água da piscicultura*.
- R. Dorf, R. B. (2009). *Sistemas de Controle Moderno*. 11th edition.
- S. Vilar, M. Tarragó, D. B. (2010). *Modelagem da transmissão de calor por convecção: uma abordagem acessível aos alunos de Física Geral*.

# EstAcqua: Proposta de solução integrada de Hardware, Software e Internet das Coisas para monitoramento ambiental

Alan Afif Helal<sup>1</sup>, Roberto Colistete Júnior<sup>2</sup>,  
Fábio da Cunha Garcia<sup>3</sup>, Gilberto Fonseca Barroso<sup>3</sup>, Rodolfo da Silva Villaca<sup>1</sup>

<sup>1</sup> Programa de Pós-Graduação em Informática (PPGI)  
Universidade Federal do Espírito Santo (UFES) - Vitória - ES - Brasil

<sup>2</sup> Departamento de Química e Física  
Universidade Federal do Espírito Santo (UFES) - Alegre - ES - Brasil

<sup>3</sup> Departamento de Oceanografia e Ecologia  
Universidade Federal do Espírito Santo (UFES) - Vitória - ES - Brasil

alan@helal.com.br, roberto.colistete@ufes.br, garciaafc2007@gmail.com  
gilberto.barroso@ufes.br, rodolfo.villaca@ufes.br

**Abstract.** *With the expansion of the Internet of Things, several solutions for monitoring are available in the market. However, most solutions use proprietary, costly software and do not offer online monitoring, which difficults access to data and prevents to take actions in a preventive way. This article presents EstAcqua, an integrated solution of low cost hardware and software that uses concepts of Internet of Things with LoRaWan, which main objective is to monitor environmental and oceanographic data from surface and submerged sensors, featuring remote access in real time and low energy consumption. Tests were performed in real environments to show the feasibility of the solution.*

**Resumo.** *Com a expansão da Internet das Coisas, diversas soluções para monitoramento estão disponíveis no mercado. Entretanto, a maioria das soluções utilizam software proprietário, de custo elevado e não oferecem monitoramento online, dificultando o acesso aos dados e impedindo que ações sejam tomadas de forma preventiva. Este artigo apresenta a EstAcqua, uma solução integrada de hardware e software de baixo custo que utiliza conceitos de Internet das Coisas com LoRaWan, cujo objetivo principal é monitorar dados ambientais e oceanográficos de sensores de superfície e submersos, podendo ser acessada remotamente em tempo real e tendo baixo consumo de energia. Foram efetuados testes em ambientes reais para mostrar que a solução é viável.*

## 1. Introdução

Segundo o relatório da *National Aeronautics and Space Administration* (NASA)<sup>1</sup> a temperatura global aumentou 1.0°C desde o ano de 1880, sendo que os últimos 18 anos mais quentes ocorreram depois do ano 2000. Além do aumento da temperatura, tem-se também o aumento do nível dos mares, a diminuição das camadas polares e o aumento da emissão de dióxido de carbono. Diante disso, monitorar o meio ambiente é de extrema importância.

---

<sup>1</sup><https://climate.nasa.gov>

Dentre os ecossistemas aquáticos os lagos têm sido considerados como efetivos sentinelas de mudanças ambientais ao integrar em seus sistemas físicos, químicos e biológicos respostas da variabilidade dos fluxos de energia e matéria, inclusive possibilitando o registro de longo prazo de mudanças climáticas [Adrian et al. 2009, Schindler 2009]. A necessidade de avaliação das tendências dos processos de estratificação e desestratificação térmica, hidrodinâmica, distribuição de nutrientes e gases dissolvidos, como oxigênio, além de produtividade primária e secundária demandam o monitoramento contínuo e de longo prazo de variáveis chave destes processos. A partir da análise de dados e a geração de informações subsidia-se sistemas de suporte à decisão (SSD) para gestão ambiental lacustre quanto aos problemas de eutrofização, assoreamento, contaminação e a consequente perda de bens e serviços ambientais proporcionados pelos ecossistemas aquáticos [Straskraba and Tundisi 2000]. Nessa linha, o Programa *Global Lake Ecological Observatory Network - GLEON* tem como foco o desenvolvimento de projetos científicos inovadores para coleta, compartilhamento e interpretação de dados em alta resolução de sensores para compreensão, predição e comunicação do papel e resposta dos lagos em um ambiente global em mudança.

Atualmente, profissionais e pesquisadores fazem monitoramento de áreas urbanas e rurais a partir da obtenção de variáveis ambientais (e.g. climáticas, limnológicas, oceanográficas), visando a criação de um banco de dados com a evolução das condições ambientais. Para isso utilizam-se estações meteorológicas e através das quais se obtém dados climáticos como temperatura do ar, precipitação da chuva, velocidade do vento, umidade e iluminância, assim como sensores hidrológicos para a obtenção de variáveis como temperatura da água, concentração de oxigênio dissolvido, pH, turbidez, entre outras.

Entretanto, os equipamentos mais comercializados para a medição dessas variáveis apresentam um grande problema: são equipamentos proprietários, de elevado custo, com código fonte fechado e sem interoperabilidade com equipamentos de outros fabricantes. Dessa forma, o usuário fica restrito à aquisição de produtos do mesmo fabricante que já utiliza. Ou seja, caso outro fabricante lance um produto de melhor qualidade, com mais funcionalidades ou de menor custo, ele não será compatível com os outros produtos já adquiridos.

Dentre os procedimentos mais utilizados, os sensores são instalados no local de medição e fazem a coleta dos dados através de um *datalog* e, após um período, normalmente de um mês, deve-se voltar até o sensor para coletar os dados registrados. Nesse ínterim, caso o sensor seja furtado e/ou danificado, perde-se todos os dados coletados. Além disso, os sistemas de monitoramento em tempo contínuo convencionais não dispõem de avisos prévios no caso de uma variável ultrapassar um valor limite, como por exemplo, se a concentração de oxigênio dissolvido for inferior a 2,0 mg/L, implica em estresse fisiológico para os peixes. Caso o local de instalação dos equipamentos seja de difícil acesso, a tarefa de instalar o equipamento e coletar os dados se torna ainda mais exaustiva.

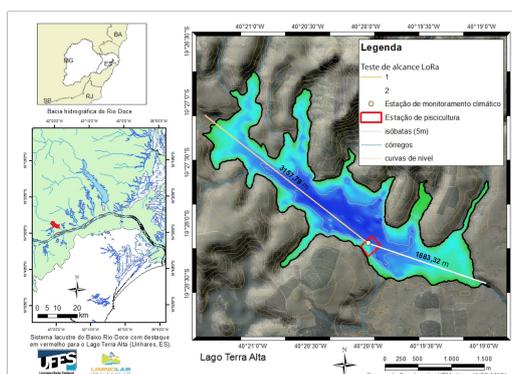
Estamos vivendo uma época de proliferação de objetos inteligentes com capacidade de sensoriamento, processamento e comunicação [Loureiro 2016]. Nos últimos anos ocorreu uma miniaturização e redução dos preços dos sensores tornando mais fácil a tarefa de monitorar. Com a facilidade de obtenção de sensores de baixo custo e con-

sumo, diversas soluções de monitoramento utilizando conceitos de Internet das Coisas (do inglês *Internet of Things (IoT)*) estão sendo desenvolvidas. Atualmente temos 11 bilhões de dispositivos IoT e, segundo a Forbes<sup>2</sup>, o ano de 2018 será de grandes avanços nessa área.

Nesse contexto, este artigo apresenta a EstAcqua, uma estação com sensores para monitoramento ambiental e oceanográfico, atualmente de superfície que coletam dados de pressão atmosférica, umidade, temperatura e iluminância, além de submersos para coletarem temperaturas em diferentes profundidades. Todos os sensores estão conectados a um microcontrolador LoPy4<sup>3</sup> e o envio dos dados é realizado usando LoRaWan<sup>4</sup>.

Essa estação, além de possuir uma arquitetura aberta de implementação, com uma solução integrada de *software e hardware* de baixo custo, tem como diferenciais: (i) possibilidade de instalação em locais remotos e sem acesso à Internet ou sinal de celular; (ii) longo alcance de transmissão (podendo chegar a poucos quilômetros); (iii) acesso aos dados pela Internet; (iv) criação de gráficos mostrando a variação dos dados, com possibilidade de criação de alarmes para notificar situações que necessitam de atenção, tornando possível tomar ações preventivas; (v) fácil instalação e utilização; e (vi) excelente autonomia de bateria e ilimitada com adição de painel solar.

Para validação do protótipo da estação ambiental, foram realizadas medições na lagoa situada dentro da Universidade Federal do Espírito Santo (UFES) e transmitidos os dados para o Departamento de Oceanografia e Ecologia, situado a 130 metros do local das medições. Também foram efetuados testes no Lago Terra Alta, no município de Linhares, no norte do estado do Espírito Santo, onde o protótipo foi colocado em uma balsa instalada no meio do lago e os dados coletados foram transmitidos para a margem do lago situada a até 3,2 km de distância, como mostra a Figura 1.



**Figura 1. Localização da EstAcqua no lago Terra Alta (Linhares, ES) e experimento de alcance de dados via LoRaWan**

O restante deste artigo está dividido da seguinte forma: Na Seção 2, serão apresentados e discutidos trabalhos relacionados. Na Seção 3, será apresentada a arquitetura, as características e os desafios encontrados na implementação da EstAcqua. Na Seção 4,

<sup>2</sup><https://www.forbes.com/sites/bernardmarr/2018/01/04/the-Internet-of-things-iot-will-be-massive-in-2018-here-are-the-4-predictions-from-ibm>

<sup>3</sup><https://pycom.io/hardware/lopy4-specs>

<sup>4</sup>Protocolo que define a arquitetura da tecnologia LoRa (<https://www.lora-alliance.org>)

será detalhada a avaliação da EstAcqua. A Seção 5 conclui o artigo e faz indicações de trabalhos futuros.

## 2. Trabalhos Relacionados

A popularização de microcontroladores de fácil programação e interface amigável proporcionou a criação de diversas soluções de *hardware* integrada com *software*, dentre elas para a área de monitoramento ambiental. Com a facilidade de integração com os microcontroladores removeu-se a barreira que outrora existia: a dificuldade eletrônica para que seja possível integrar o microcontrolador com outros dispositivos.

No trabalho de Thobias [Tose 2012] foi desenvolvido um protótipo para monitoramento de estações de esgoto com Arduino conectado a sensores de temperatura, umidade e gases, utilizando uma tecnologia de comunicação sem fio, ZigBee, para transmissão dos dados. Entretanto, essa é uma abordagem de alto custo financeiro, com baixo alcance (devido à frequência de operação), muito sensível a interferências de outros dispositivos, com baixa autonomia de bateria e dependente de um computador localizado próximo ao local de instalação do protótipo. A EstAcqua se diferencia por ter um alcance de transmissão significativamente maior, funcionar com bateria e a possibilidade de funcionamento sem a necessidade de um computador próximo.

Já o trabalho de Fabio [de Oliveira 2017] mostra a criação de um magnetômetro utilizando conceitos de Internet das Coisas com uma interface *web* para visualização dos dados *online*. O magnetômetro conta com sensores de temperatura para ajudar nas medidas realizadas e armazena em um banco de dados em um cartão micro SD. O presente trabalho se diferencia por usar LoRaWan para transmissão dos dados e ser focado em monitoramento ambiental e oceanográfico.

George Mois [Mois et al. 2017] fez um estudo comparativo de três soluções diferentes de sensores inteligentes para o monitoramento de dados ambientais utilizando transmissão sem fio *WiFi* e *Bluetooth*. Por se tratar de tecnologias de baixo alcance, o emprego dessas soluções é voltado para ambientes fechados, como escritórios. O diferencial em relação a esse trabalho é a possibilidade de uso interno ou externo com transmissão de longo alcance.

Na grande maioria dos trabalhos encontrados na literatura, as soluções são para curto alcance, dependentes de um computador próximo para se obter os dados dos sensores ou de uma fonte de energia externa para energizar o equipamento. Um exemplo é o trabalho proposto por Bharathkumar [Bharathkumar et al. 2017], em que se utiliza um microcontrolador PIC<sup>5</sup> conectado a um sensor de temperatura e umidade com a possibilidade de envio de mensagens de texto para um celular. A solução proposta neste trabalho utiliza um *hardware* mais robusto, com mais sensores e *software* aberto, o que possibilita notificações através de *e-mail*, por exemplo, de acordo com a necessidade do usuário.

Dessa forma, um diferencial da arquitetura proposta neste artigo é a sua aderência ao modelo de Internet das Coisas, onde os dados dos sensores podem ser acessados através de uma interface *web* ou de um aparelho celular, sem a necessidade de infraestrutura existente no local de instalação da EstAcqua. Além disso, caso haja alguma indisponibilidade

---

<sup>5</sup><https://www.microchip.com/design-centers/microcontrollers>

de acesso à Internet, os dados coletados são salvos em cartão micro SD, evitando a perda de dados.

### 3. Arquitetura de *Hardware e Software*

A arquitetura da EstAcqua pode ser dividida em quatro partes: um ou mais nós transmissores de dados, receptor de dados, nuvem de Internet das Coisas (*IoT Cloud*) e interação com usuário. A Figura 2 ilustra essas quatro partes.

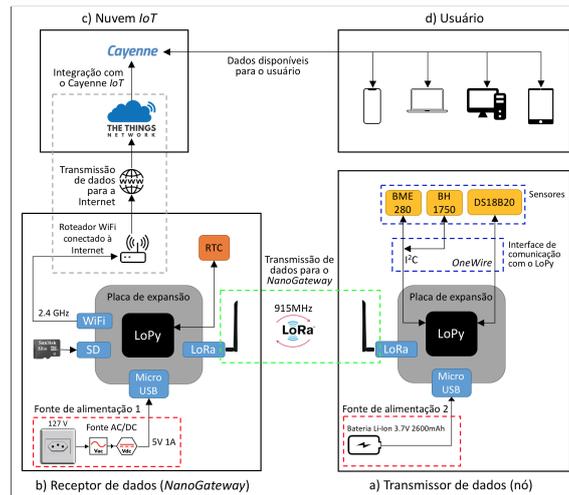


Figura 2. Arquitetura da EstAcqua

#### 3.1. Hardware

A arquitetura de *hardware* é composta principalmente pelos blocos Transmissor de dados e Receptor de dados representados na Figura 2:

- Receptor de dados (*NanoGateway*): responsável por receber os pacotes enviados pelos transmissores de dados. É alimentado por uma fonte de alimentação com saída DC de 5V e 1A e está conectado à Internet para encaminhar os dados recebidos para um servidor *online*.
- Transmissor de dados (nó): responsável pela coleta e processamento dos dados obtidos dos sensores. Possui sensores de superfície de pressão, umidade, temperatura e iluminância e sensores submersos de temperatura. É alimentado por uma bateria de 2.600 mAh com saída de 3,7 V.

Tanto o *NanoGateway* como cada nó utilizam um microcontrolador LoPy4 (ou LoPy) pois já possui integrado *WiFi*, *LoRa(Wan)* e *Bluetooth*. Além disso o LoPy4 possui um modo de economia de energia, *deep sleep*, em que um co-processador ULP (*Ultra Low Power*) é utilizado para monitorar as portas de entrada/saída do LoPy4, os canais do conversor analógico-digital e controlar a maioria dos periféricos internos com um consumo baixíssimo de energia. Adicionalmente é utilizada uma placa de expansão que possui entradas USB, cartão de memória e conector para a bateria, facilitando a interface com o LoPy4.

O nó é responsável pela coleta e processamento os dados dos sensores conectados a ele e pela transmissão via *LoRaWan* para o *NanoGateway*. Essa unidade está conectada a sensores ambientais e oceanográficos, sendo eles: (i) sensor BME280 para coletar

pressão atmosférica, umidade e temperatura; (ii) sensor BH1750 para medir iluminância; (iii) sensores de temperatura DS18B20 para coletarem a temperatura da água ao longo de diferentes profundidades.

Os sensores BME280 e BH1750 utilizam interface de comunicação  $I^2C$  e os sensores oceanográficos submersos, DS18B20, utilizam interface de comunicação *OneWire*. O protótipo do nó construído possui um BME280, um BH1750 e diversos DS18B20 para medir a temperatura em diferentes profundidades entre subsuperfície até 15 m.

O *NanoGateway* recebe os pacotes transmitidos pelos nós (transmissores de dados) e envia para um *IoT Cloud* para que os dados fiquem acessíveis de forma *online*. Como o *NanoGateway* fica ativo o tempo todo, ele deve ser ligado à energia elétrica em um local próximo a uma rede sem fio com acesso à Internet. Ainda conta com um DS3231 via  $I^2C$ , um *Real Time Clock* (RTC) com bateria externa, regulado por cristal de quartzo e com compensação de ano bissexto, para que o sistema mantenha seu horário sempre sincronizado mesmo em caso de interrupções na alimentação. O *IoT Cloud* escolhido foi a *The Things Network* (TTN)<sup>6</sup>, por se tratar de uma comunidade colaborativa com mais de 35 mil membros e quase 20 mil aplicações desenvolvidas, além de facilitar a integração dos dados recebidos com bancos de dados, HTTP e *Cayenne*.

Para diminuir as chances de perda de dados, o *NanoGateway* possui um cartão micro SD de 32GB de armazenamento onde são escritos todos os dados recebidos.

Na Figura 3 são mostradas: o nó coletando a temperatura em diferentes profundidades de uma lagoa, bem como a temperatura, umidade e pressão do ambiente da lagoa; o *NanoGateway*; o *hardware* do interior do nó; e microcontroladores LoPy(4) utilizados.

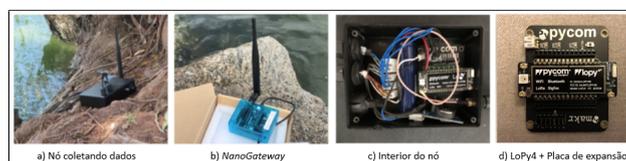


Figura 3. *Hardware da EstAcqua*

### 3.2. *Software*

Com relação ao *software* embarcado na EstAcqua, trata-se de dois códigos-fonte *MicroPython*<sup>7</sup> distintos, sendo um específico para o *NanoGateway* e outro para o nó, ambos criados pelos autores. O nó possui um código adaptativo que reconhece automaticamente quando algum sensor é conectado ou desconectado. Como cada nó foi projetado para ser instalado em um local de difícil acesso, sendo alimentado por uma bateria, foi necessário otimizar o código-fonte para que se tenha o menor consumo de energia.

Após a instalação e inicialização do nó, ele entra no modo ativo, que dura aproximadamente 2.9 segundos, onde (i) realiza as medições; (ii) compacta os dados para a criação de um pacote no formato *Cayenne LPP*<sup>8</sup>; (iii) envia o pacote para o *NanoGateway*; (iv) grava os dados coletados no cartão micro SD; (v) e entra em modo *deep sleep*, onde permanece por 10 minutos. Após esse tempo ele acorda novamente e repete o processo.

<sup>6</sup><https://www.thethingsnetwork.org>

<sup>7</sup><https://www.micropython.org>

<sup>8</sup><https://www.thethingsnetwork.org/docs/devices/arduino/api/cayennelpp.html>

Já o *NanoGateway* possui um código para receber pacotes apenas dos nós que se autenticam através de *Authentication By Personalisation (ABP)*. Após receber um pacote, os dados recebidos são gravados em um cartão micro SD e enviados para a TTN para visualização dos dados de forma *online*, tanto via *web* ou através do celular usando o aplicativo *Cayenne* conforme ilustrado na Figura 2.

## 4. Avaliação e Resultados

Para avaliar o protótipo e sua viabilidade foram realizados os seguintes testes: (i) comunicação via LoRa(Wan), para verificar como o protótipo se comporta em diferentes situações e decidir quais parâmetros utilizar na comunicação; (ii) interface de monitoramento com a nuvem, a fim de analisar como os dados enviados pelo nó são enviados para o *IoT Cloud* e são disponibilizados para o usuário; (iii) avaliação no lago Terra Alta, visando analisar o comportamento do protótipo em locais de difícil acesso e sem comunicação com a Internet; (iv) autonomia da bateria, objetivando calcular um valor teórico do tempo sem a necessidade de recorrer a uma fonte externa de energia para recarregá-la e; (iv) avaliação dos sensores utilizados, comparando-os com sensores comerciais.

### 4.1. Comunicação via LoRa(Wan)

Para comunicação via LoRa(Wan) é necessário selecionar alguns parâmetros:

- Frequência de transmissão: frequência utilizada para a comunicação entre os dispositivos. No Brasil é utilizada a banda de 915 MHz (902-907,5 MHz, 915-928 MHz), escolhemos 903,9 MHz;
- Fator de espalhamento (SF): LoRa opera com SF de 7 a 12, sendo 7 o que proporciona maior taxa de transmissão e menor alcance, e 12 a menor taxa de transmissão e maior alcance;
- Largura de banda (BW): LoRa utiliza três BW: 125kHz, 250kHz (não permitido no Brasil) e 500kHz, sendo 125kHz com menor taxa de transmissão e maior alcance e 500kHz com maior taxa de transmissão e menor alcance;
- *Code Ratio (CR)*: proporção dos dados enviados que não são redundantes. LoRa utiliza 4/5 (maior taxa de transmissão e menor alcance), 4/6, 4/7 ou 4/8 (menor taxa de transmissão e maior alcance).

O tamanho do *payload* do pacote transmitido via LoRa(Wan) depende da combinação dos parâmetros acima. Dessa forma é feito uma solução de compromisso entre distância máxima, velocidade de transmissão, taxa de perda e tamanho do pacote.

Para decidir quais parâmetros utilizar foram realizados testes na Praia de Camburi, no município de Vitória, no Estado do Espírito Santo, onde foi posicionado o nó em um píer e o *NanoGateway* em outro píer situado a 2.8 km de distância para simular os efeitos de transmissão a nível do mar, por se tratar de um cenário similar ao encontrado na lagoa de Terra Alta. Foram selecionadas 28 combinações de SF, BW e CR partindo da configuração de menor alcance e alta taxa de transmissão (SF = 7, BW = 500kHz e CR = 4/5) para a de maior alcance e baixa taxa de transmissão (SF = 12, BW = 125kHz e CR = 4/8). Para cada configuração foram enviados 100 pacotes para fazer uma estatística de perda de pacotes. Foi então selecionada a configuração SF = 8, BW = 125kHz e CR = 4/5, pois apresentou uma taxa de perda menor que 1% e um *payload* máximo de 51 bytes - representando uma taxa de perda baixíssima para uma longa distância e comportando os dados de todos os sensores em um único pacote.

## 4.2. Interface de Monitoramento via Nuvem

Depois foram realizados testes em campo na lagoa situada dentro da Universidade Federal do Espírito Santo (UFES), monitorando a temperatura da lagoa em diferentes profundidades, pressão, umidade, temperatura e iluminação do ambiente. Os dados foram enviados para o *NanoGateway* localizado no Departamento de Oceanografia, a 130m distância da lagoa e 11m de altura, estando conectado à rede sem fio da UFES. O nó foi posicionado próximo à Lagoa e bastou ligá-lo para que os dados fossem transmitidos para o *NanoGateway*, ratificando assim a sua fácil instalação e uso.

Os dados transmitidos pelo nó no teste da UFES foram visualizados através do site do *Cayenne* e com o aplicativo *Cayenne* para dispositivos móveis. A Figura 4 mostra a forma com que os dados são disponibilizados de forma *online* para o usuário. Também é possível a criação de gráficos com os valores lidos pelos sensores para acompanhar a evolução dos valores e a criação de alarmes para enviar *e-mails* caso algum dos sensores esteja com leitura acima ou abaixo do valor configurado pelo usuário. A Figura 5 mostra os gráficos de temperatura externa e submersa na lagoa da UFES, onde pode-se perceber a inércia de variação da temperatura da água da lagoa em relação à temperatura ambiente<sup>9</sup>.

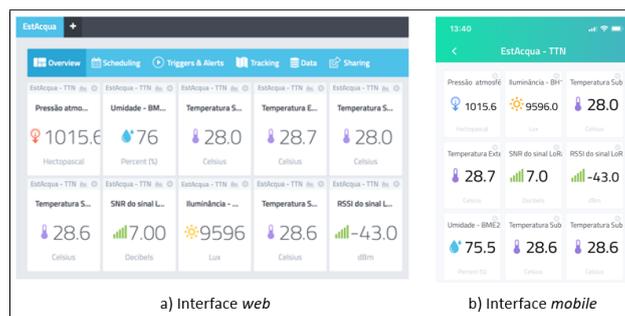


Figura 4. Interface *web* e *mobile* do Cayenne com os dados acessados *online*



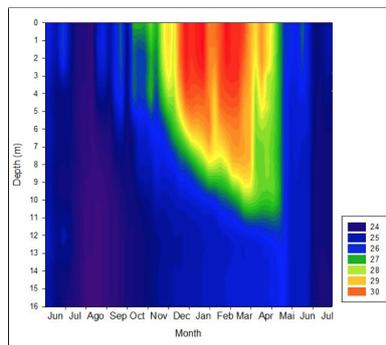
Figura 5. Gráficos de temperatura gerados pelo Cayenne

## 4.3. Avaliação no Lago Terra Alta

Outro teste foi realizado no Lago Terra Alta (área de  $3,9\text{km}^2$  e profundidade máxima de 22,1m) por se tratar de um importante ecossistema lacustre profundo sob estresse ambiental da atividade de piscicultura [Barroso et al. 2012] com produção estimada em 2017 de 550 toneladas de tilápia. Desde junho de 2014, o lago vem sendo monitorado com variáveis climáticas a cada 15 minutos e temperatura da água em oito profundidades a

<sup>9</sup>Link do *Cayenne* de acesso público para visualização dos dados coletados pela EstAcqua: <https://cayenne.mydevices.com/shared/5ac1490bd8b6585016379d30>

cada 60 minutos. O objetivo é avaliar o efeito dos fatores climáticos sobre o regime térmico do lago e propriedades hidroquímicas e hidrobiológicas. O lago Terra alta fica em uma localidade remota e sem sinal de celular ou conexão com a Internet. Na piscicultura existe uma balsa onde sensores ambientais já estão instalados. No lago Terra Alta, o monitoramento de variáveis limnológicas produz dados contínuos da estrutura térmica da coluna de água, conforme Figura 6. Essas informações são importantes para o estudo da influência de mudanças climáticas na estrutura térmica da coluna de água e seus reflexos para a ecologia desses ecossistemas. O protótipo da EstAcqua foi instalado nessa balsa e foram realizados testes movimentando o *NanoGateway* pela lagoa, chegando até sua margem localizada a 3,15km de distância.



**Figura 6. Diagrama profundidade/tempo para a variação da temperatura na coluna de água do lago Terra Alta**

O teste mostrou que em local remoto a instalação do protótipo foi rápida e fácil e mesmo sem comunicação com a internet não houve perda de dados pois os mesmos foram gravados no cartão micro SD, confirmando sua viabilidade mesmo em ambientes sem conexão com a internet ou sinal de celular.

A Figura 7 mostra a balsa instalada no lago Terra Alta e o nó instalado na balsa no lago Terra Alta.



**Figura 7. Balsa localizada no lago Terra alta e o nó na balsa coletando dados**

#### 4.4. Autonomia de Bateria

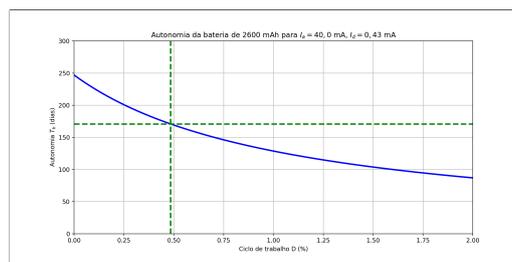
Para estimar a autonomia da bateria  $T_b$  através de cálculos teóricos são necessárias a capacidade da bateria  $C$  (em mAh), a corrente elétrica consumida no modo ativo  $I_a$  (em mA), no modo inativo (*deep sleep*)  $I_d$  (em mA) e a fração de tempo  $D$  (em %) em que o

sistema está no modo ativo (denominada *duty cycle* ou ciclo de trabalho) :

$$T_b = \frac{100 C}{24[I_a D + I_d(100 - D)]} \quad , \quad (1)$$

que mostra que se deve minimizar  $I_a$  e  $I_d$  para maximizar a autonomia da bateria  $T_b$ .

Foi utilizado o sensor de corrente contínua INA219 para medir a corrente consumida no modos ativo e multímetro no modo inativo, resultando em consumos médios  $I_a = (40,0 \pm 1,3)$  mA e  $I_d = (0,43 \pm 0,04)$  mA, respectivamente. Utilizando o tempo em que o nó EstAcqua permanece no estado ativo, 2,9s, tempo de acordar do modo inativo, carregar os módulos, configurar LoRaWan, ler sensores e enviar os dados via LoRaWan, em relação ao período do ciclo de operação de 600s, obtemos um ciclo de trabalho  $D \simeq 0,483\%$ . Empregando uma bateria com capacidade nominal de 2.600 mAh resulta em longa autonomia de bateria  $T_b \simeq (171 \pm 12)$  dias, i.e., entre 159 e 183 dias. Se adicionamos janela temporal de *downlink* (recebimento de dados do servidor) LoRaWan, são mais 2,6s totalizando 5,5s no estado ativo,  $D \simeq 0,917\%$  e autonomia de bateria mais curta,  $T_b \simeq (134 \pm 8)$  dias, entre 126 e 142 dias. Vide a Figura 8 que mostra claramente o comportamento não-linear da Equação (1) de autonomia da bateria.



**Figura 8. Autonomia da bateria de 2.600 mAh versus ciclo de trabalho para correntes de modo ativo  $I_a = 40,0$  mA e de *deep sleep*  $I_d = 0,43$  mA.**

#### 4.5. Avaliação dos Sensores usados na EstAcqua

Na Tabela 1 temos um comparativo entre os sensores conectados à EstAcqua com alguns produtos comerciais da empresa *Onset*, sendo eles: (i) *TidbiT v2 Water Temperature Data Logger*<sup>10</sup>; (ii) *HOBO U23 Pro v2 External Temperature/Relative Humidity Data Logger*<sup>11</sup>; e (iii) *HOBO Pendant Temperature/Light 64K Data Logger*<sup>12</sup>.

Como mostrado na Tabela 1, podemos verificar que os sensores utilizados na EstAcqua custam aproximadamente 1% do valor dos produtos comerciais, por isso o prejuízo em caso de furto ou dano dos sensores é extremamente baixo. Além disso, permite a aquisição de novos sensores que forem lançados, não ficando restrito a um fabricante.

Ainda apresentam uma acurácia e resolução próximas dos sensores comerciais e em alguns casos, melhor. Analisando o fundo de escala e temperatura de operação vemos que os sensores da EstAcqua são, na maioria, melhores que os comerciais. Apesar

<sup>10</sup><http://http://www.onsetcomp.com/products/data-loggers/utbi-001>

<sup>11</sup><http://http://www.onsetcomp.com/products/data-loggers/u23-002>

<sup>12</sup><http://http://www.onsetcomp.com/products/data-loggers/ua-002-64>

**Tabela 1. Comparativo com sensores comerciais**

	Luminosidade		Temperatura externa e umidade relativa		Temperatura submersa	
	BH1750 (EstAcqua)	Onset HOBO Pendant	BME280 (EstAcqua)	Onset HOBO U23 Pro	DS18B20 (EstAcqua)	Tidbit v2
<b>Acurácia</b>	1 lx	Desenvolvido para medidas relativas	Temperatura: $\pm 1^{\circ}\text{C}$ Umidade: $\pm 3\%$	Temperatura: $\pm 0,21^{\circ}\text{C}$ Umidade: $\pm 2,5\%$	$\pm 0,5^{\circ}\text{C}$	$\pm 0,021^{\circ}\text{C}$
<b>Resolução</b>	1 lx	1 lx	Temperatura: $0,01^{\circ}\text{C}$ Umidade: 0,008%	Temperatura: $0,02^{\circ}\text{C}$ Umidade: 0,05%	9 a 12 bits	0,02°C
<b>Temperatura de operação</b>	-40 a $85^{\circ}\text{C}$	-20 a $70^{\circ}\text{C}$	-40 a $85^{\circ}\text{C}$	-40 a $70^{\circ}\text{C}$	-55 a $125^{\circ}\text{C}$	-20 a $70^{\circ}\text{C}$
<b>Fundo de escala</b>	0 a 65.535 lx	0 a 320.000 lx	Temperatura: -40 a $85^{\circ}\text{C}$ Umidade: 0 a 100%	Temperatura: -40 a $70^{\circ}\text{C}$ Umidade: 0 a 100%	-55 a $125^{\circ}\text{C}$	-20 a $70^{\circ}\text{C}$
<b>Preço</b>	US 3,15	US 64,00	US 7,56	US 199,00	US 1,37	US 133,00
<b>Bateria</b>	Recarregável	Não recarregável, com duração de 1 ano	Recarregável	Não recarregável, com duração de 3 anos	Recarregável	Não recarregável, com duração de 5 anos
<b>Data Logger</b>	Sim	Sim. Sobrescreve os dados se não forem coletados em 30 dias.	Sim	Sim. Sobrescreve os dados se não forem coletados em 30 dias.	Sim	Sim. Sobrescreve os dados se não forem coletados em 45 dias.
<b>Transmissão sem fio</b>	Sim	Não	Sim	Não	Sim	Não

da acurácia e resolução serem em alguns casos, inferiores aos produtos comerciais analisados, não torna a substituição pela EstAcqua inviável, pois para medições ambientais os valores analisados com precisão de uma casa decimal são suficientes conforme, Figura 6, que mostra o gráfico de temperatura gerado pelo equipamento comercial *Sontek CastAway-CTD*<sup>13</sup>, cujo incremento de temperatura é de  $1^{\circ}\text{C}$ .

Apesar de possuir autonomia de bateria de aprox. 171 dias, é possível acoplar painel solar portátil em cada nó EstAcqua resultando em autonomia limitada somente pela vida útil de alguns anos da bateria e dos outros componentes eletrônicos.

Por fim, a EstAcqua ainda registra os dados coletados em cartão micro SD e no *IoT Cloud*, tornando possível a visualização dos dados em tempo real e, em caso de perda ou furto do equipamento, os dados coletados não são perdidos pois já se encontram na *IoT Cloud*. Vale ressaltar que nas soluções comerciais apresentadas, caso não haja uma coleta regular, os dados começam a ser sobrescritos.

## 5. Conclusão

Podemos concluir pelos resultados obtidos na avaliação dos sensores que a EstAcqua possui sensores de acurácia e resolução bem próximas de sensores comerciais e custam significativamente menos que as soluções encontradas no mercado atualmente. Além disso, a EstAcqua tem como grande vantagem a capacidade de coleta e transmissão dos dados para um *NanoGateway* situado a quilômetros de distância, podendo acessar os dados via *web* ou celular, conforme mostra seção de testes de interface de monitoramento via nuvem, cobrindo assim uma lacuna existente nas soluções encontradas atualmente, que além de não possuírem integração com outros dispositivos, são comercializados com baterias não recarregáveis e/ou substituíveis. A EstAcqua ainda conta com uma redundância de armazenamento para os dados, pois mesmo se o sensor falhar, for danificado e/ou furtado, os dados coletados já foram transferidos para a nuvem, diferente das soluções atuais onde se perderiam todos os dados coletados. Os resultados obtidos na avaliação no lago Terra Alta mostram que EstAcqua é uma solução excelente não somente para o uso acadêmico, mas também como um substituto de menor custo, confiável, com maior integração e mais funcionalidades do que a maioria das soluções encontradas no mercado.

Como trabalhos futuros, podemos citar o uso de uma caixa certificada IP67 para que se tenha maior segurança para os nós que ficarão em ambiente externo, o uso de placas

<sup>13</sup><https://www.sontek.com/productsdetail.php?CastAway-CTD-11>

solares para recarregar a bateria durante o dia fazendo com que a autonomia da bateria seja praticamente a sua vida útil, a adição de mais sensores visando monitorar mais parâmetros ambientais, o uso de *downlink* para mudar parâmetros da EstAcqua através do *IoT Cloud* e a realização de novos comparativos com os equipamentos comerciais utilizados pelo departamento de Oceanografia e Ecologia da UFES.

## Agradecimentos

Este trabalho recebeu financiamento parcial do projeto FUTEBOL - Horizon 2020 (União Europeia) sob no. 688941, assim como do MCTI por meio da RNP e do CTIC. Além disso, também gostaríamos de agradecer o financiamento parcial do CNPq e FAPES.

## Referências

- Adrian, R., O'Reilly, C. M., Zagarese, H., Baines, S. B., Hessen, D. O., Keller, W., Livingstone, D. M., Sommaruga, R., Straile, D., Donke, E. V., Weyhenmeyer, G. A., and Winder, M. (2009). Lakes as sentinels of climate change. *Limnology and Oceanography*, 54:2283–2297.
- Barroso, G. F., d. C. Garcia, F., Gonçalves, M. A., Martins, F. C. O., Venturini, J. C., d. C. Sabadini, S., d. Azevedo, A. K., d. Freitas, A. C. T., and Delazari-Barroso, A. (2012). Estudos integrados no sistema lacustre do Baixo Rio Doce (Espírito Santo). *I Seminário Nacional de Gestão Sustentável de Ecossistemas Aquáticos: Complexidade, Interatividade e Ecodesenvolvimento*.
- Bharathkumar, V., Irshad, S., Gowtham, S., and Geethamani, R. (2017). Microcontroller based digital meter with alert system using GSM. *2017 11th International Conference on Intelligent Systems and Control (ISCO)*, pages 444–448.
- de Oliveira, F. F. (2017). EstGeoMag: Integrando soluções de Hardware, Software e Internet das Coisas na medição de grandezas Geomagnéticas. *Sociedade Brasileira de Computação*, pages 2598–2609.
- Loureiro, A. A. F. (2016). Minicursos XXXIV Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos. In Allan Edgard Silva Freitas, Fabíola Gonçalves Pereira Greve, F. A. S. and Lung, L. C., editors, *Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 1–50. Sociedade Brasileira de Computação.
- Mois, G., Folea, S., and Sanislav, T. (2017). Analysis of three IoT-Based wireless sensors for environmental monitoring. *IEEE Transactions on Instrumentation and Measurement*, 66(8):2056–2064.
- Schindler, D. W. (2009). Lakes as sentinels and integrators for the effects of climate change on watersheds, airsheds and landscapes. *Limnology and Oceanography*, 54:2349–2358.
- Straskraba, M. and Tundisi, J. G. (2000). Gerenciamento da qualidade da água em reservatórios. *International Lake Environmental Committee*, page 280.
- Tose, T. (2012). Rede de Sensores sem fio Zigbee Aplicada em uma Estação de Tratamento de Esgoto. Master's thesis, Universidade Federal do Espírito Santo, Av. Fernando Ferrari, 514 - Goiabeiras, Vitória - ES, 29075-073.

# Uma Contribuição à Ciência de Contexto no Middleware EXEHDA Explorando Fog Computing

Leonardo João<sup>1</sup>, Verônica Tabim<sup>2</sup>, Anderson Cardoso<sup>2</sup>, Roger Machado<sup>1</sup>,  
João Lopes<sup>3</sup>, Gerson Cavalheiro<sup>1</sup>, Ana Marilza Pernas<sup>1</sup>, Adenauer Yamin<sup>1,2</sup>

<sup>1</sup>Universidade Federal de Pelotas (UFPel)

<sup>2</sup>Universidade Católica de Pelotas (UCPel)

<sup>3</sup>Instituto Federal Sul-rio-grandense (IFSul)

{ldrsjoao, rdsmachado, gerson.cavalheiro, marilza, adenauer}@inf.ufpel.edu.br  
{veronica.tabim, anderson}@ucpel.edu.br  
joaolopes@cavg.ifsul.edu.br

**Abstract.** *Advances in Internet of Things (IoT) have enabled interoperation between various intelligent devices, collecting and distributing contextual information, thus allowing more sophisticated models to provide context awareness. The use of middlewares is highlighted in the literature as an alternative to device management in distributed IoT infrastructure, as well as to make contextual processing more transparent to applications. Considering this scenario, the objective of this work is to present the Fog Computing proposal for the middleware EXEHDA, considering the use of computational edge devices. A case study was carried out in the area of Precision Viticulture (PV) evaluating the proposed architecture.*

**Resumo.** *Os avanços na Internet of Things (IoT) permitiram a interoperação entre diversos dispositivos inteligentes, coletando e distribuindo as informações contextuais, assim possibilitando modelos mais sofisticados para prover a ciência de contexto. O uso de middlewares é destacado na literatura como alternativa para gerenciamento de dispositivos na infraestrutura distribuída IoT, bem como para tornar o processamento contextual mais transparente para as aplicações. Considerando este cenário, o objetivo desse trabalho é apresentar a proposta de Fog Computing para o middleware EXEHDA, considerando o uso de dispositivos das bordas computacionais. Foi realizado um estudo de caso na área de Viticultura Precisão (VP) avaliando a arquitetura proposta.*

## 1. Introdução

Nos últimos anos, a rápida evolução nas áreas de dispositivos embarcados e redes de computadores, promoveu a disponibilidade de sistemas ciber-físicos com elevados níveis de conectividade. A sinergia decorrente da interoperabilidade de objetos inteligentes, formados pelos sistemas ciber-físicos, vem constituindo a *Internet of Things* (IoT) [Peralta et al. 2017].

As aplicações introduzidas pelo cenário IoT, embora onipresentes, são processadas em um ambiente computacional amplamente distribuído, e requerem comportamento autônomo, minimizando o envolvimento de seus usuários. Para atender este requisito estas aplicações necessitam ter ciência dos dados contextuais que lhe interessam e, quando

for o caso, reagirem aos mesmos. Esta classe de sistemas computacionais, reativos ao contexto, abre perspectivas ao desenvolvimento de aplicações mais ricas, elaboradas e complexas, e que exploram a natureza dinâmica das modernas infraestruturas computacionais [Botta et al. 2016].

No cenário da IoT a tecnologia de *Cloud Computing* vem oferecendo elevados níveis de disponibilidade e escalabilidade. No entanto, uma vez que a centralização é inerente à *Cloud Computing*, ela não é capaz de atender todos os requisitos do desenvolvimento de soluções na perspectiva da IoT, principalmente considerando infraestruturas distribuídas formadas por um elevado número de dispositivos embarcados [Aazam and Huh 2014].

Os dados coletados na infraestrutura computacional nem sempre precisam ser transmitidos para a nuvem. Eles podem ser processados localmente nos próprios dispositivos embarcados, por meio de políticas de filtragem e agregação, com o objetivo de economizar recursos de rede e armazenamento [Bonomi et al. 2014].

Visando melhorar a capacidade de agregação e abstração, os dispositivos embarcados podem requisitar dados de outros dispositivos em um mesmo espaço geográfico, colaborando para o processamento contextual e materializando assim as premissas de um novo paradigma da computação denominado *Fog Computing* [Privat et al. 2016].

Diferentes desafios estão presentes no provimento de suporte para as aplicações direcionadas a IoT considerando o paradigma de *Fog Computing*, dentre estes, temos o gerenciamento das informações coletadas através de dispositivos heterogêneos, e a interpretação destas informações considerando o contexto de interesse das aplicações [Bellavista et al. 2012]. As informações coletadas no sentido de promover a compreensão do contexto de interesse das aplicações, denominam-se neste trabalho de dados contextuais.

Neste sentido, este artigo tem como objetivo principal apresentar a abordagem projetada para fornecer suporte à Ciência de Contexto para o middleware EXEHDA [Lopes et al. 2014], explorando o paradigma da *Fog Computing*.

A principal contribuição desse trabalho é a concepção de uma arquitetura para o Subsistema de Reconhecimento de Contexto e Adaptação do EXEHDA, com a capacidade de lidar com a aquisição e processamento distribuído de dados contextuais na perspectiva da IoT, utilizando as bordas computacionais e assim viabilizando o emprego da abordagem de *Fog Computing*.

O texto do artigo está estruturado da seguinte forma. A seção 2 discute o escopo desse trabalho, sendo apresentado os temas relacionados a Ciência de Contexto, *Fog Computing* e *middleware* EXEHDA. Na sequência, a seção 3 descreve os trabalhos relacionados. A seção 4, apresenta a arquitetura desenvolvida. A seção 5, discute a avaliação da arquitetura, sendo apresentado os hardwares e softwares utilizados e ainda os resultados e discussões a respeito do estudo de caso. Finalmente, na seção 6 são discutidas algumas contribuições alcançadas ao final deste trabalho e os possíveis trabalhos futuros.

## 2. Escopo do Trabalho

A Ciência de Contexto refere-se a um modelo no qual o sistema computacional é capaz de verificar as características do meio no qual tem interesse e, quando necessário, reagir

as suas mudanças [Khattak et al. 2014]. No cenário da IoT, a Ciência de Contexto possui elevado significado, uma vez que existe a real necessidade do sistema tomar decisões autônomas nos mais diversos tipos de dispositivos embarcados que estão interoperando, considerando as especificações do usuário, ou aquelas inferidas pelo próprio sistema.

A *Cloud Computing* é uma das tecnologias mais promissoras para a materialização da IoT, por viabilizar sistemas escaláveis ao fornecer uma grande capacidade de armazenamento de dados e processamento [Vermesan and Friess 2014]. Apesar desses recursos, as soluções baseadas em nuvem exigem uma conexão ativa com a Internet tanto para o processamento de dados contextuais quanto para a atuação no ambiente. Essas duas operações exigem uma abordagem que garanta a confiabilidade operacional do sistema, mesmo no caso de desconexões [Stojmenovic and Wen 2014]. Deste cenário, decorre a motivação para o uso do *Fog Computing* no *middleware* EXEHDA.

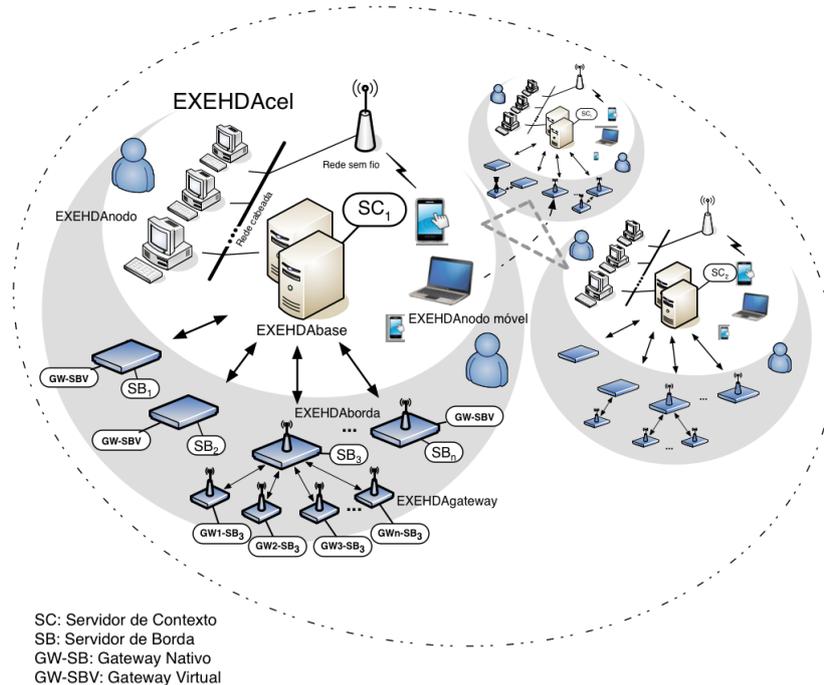
A *Fog Computing* surgiu com a intenção de abordar desafios relacionados a baixa latência, ciência de localização e confiabilidade [Bonomi 2011]. A mesma é implementada nas bordas computacionais, normalmente com dispositivos embarcados. Essa infraestrutura, feita com os dispositivos mais próximos das necessidades do usuário, é considerada como uma nuvem mais próxima do usuário, proporcionando assim baixa latência, ciência de localização e possibilidade de aprimoramento da *Quality of Service* (QoS). Deste modo, a *Fog Computing* fornece armazenamento temporário, capacidade de raciocínio, auxiliando na tomada de decisão considerando os dados de contexto coletados.

O EXEHDA consiste de um *middleware* adaptativo ao contexto baseado em serviços, que visa criar e gerenciar um ambiente ubíquo, bem como promover a execução de aplicações sobre ele. O *middleware* vem sendo utilizado pelo *Laboratory of Ubiquitous and Parallel Systems* (LUPS) em frentes de pesquisa que abordam desafios da IoT [Souza et al. 2015, Davet et al. 2015].

O ambiente fornecido pelo EXEHDA é formado por equipamentos multi-institucionais, sendo composto por dispositivos de usuário e alguns equipamentos para suporte as demandas do próprio *middleware*, para tanto, cada dispositivo é instanciado considerando seu respectivo perfil de execução no *middleware*.

Na composição do ambiente podem estar presentes sistemas embarcados, os quais também são instanciados pelo seu respectivo perfil de execução do *middleware*. Conforme pode ser observado na Figura 1, o EXEHDA possui uma organização composta por um conjunto de células de execução. Estas células, no que diz respeito ao provimento de Ciência de Contexto, são compostas por Servidores de Contexto, Servidores de Borda e Gateways. O Servidor de Borda (SB) é responsável por interagir com o ambiente através de Gateways que gerenciam sensores e atuadores. Por sua vez, o Servidor de Contexto (SC) fornece as funcionalidades para a Ciência de Contexto. Esses servidores são alocados em células no ambiente gerenciado pelo EXEHDA.

Em cada célula podem existir vários Servidores de Borda e Gateways e um equipamento central (EXEHDatabase) onde é executado o Servidor de Contexto. A organização celular do EXEHDA tem por objetivo também assegurar a autonomia das instituições envolvidas.



**Figura 1. Ambiente Ubíquo gerenciado pelo EXEHDA**

### 3. Trabalhos Relacionados

Nesta seção serão apresentados os trabalhos relacionados que foram identificados de acordo com os seguintes critérios: modernidade, desenvolvimento ativo e representatividade no cenário atual. Além dos critérios citados, levou-se em consideração requisitos relacionados ao tratamento de eventos em *Fog Computing*: distribuição; suporte a composição; escalabilidade; e gerência dinâmica.

WSO2 [Fremantle 2015] propõe uma série de soluções para a IoT, dentre elas uma arquitetura de referência com o objetivo de auxiliar desenvolvedores quanto a concepção de arquiteturas para o cenário da IoT. A arquitetura tem como objetivo fornecer um ponto de partida eficaz que contemple a maior parte dos requisitos de sistemas e projetos envolvendo IoT. No WSO2 são identificados alguns pontos necessários para soluções IoT, sendo classificados em cinco grupos: (i) conectividade e comunicação; (ii) gerenciamento de dispositivos; (iii) obtenção de dados e análise; (iv) escalabilidade; e (v) segurança. Além desses, pode ser mencionado ainda alta disponibilidade, previsão e facilidade de integração.

Xively [Xively 2018] disponibiliza um *middleware* comercial, utilizando uma abordagem baseada em nuvem para tratar e armazenar os dados providos pelos dispositivos. O sistema é baseado no padrão arquitetural REST, disponibilizando os sensores e atuadores como recursos Web e interfaces padronizadas para a troca de dados através de uma estratégia de sensoriamento como serviço [Zaslavsky et al. 2013].

LinkSmart [LinkSmart 2018], anteriormente chamado Hydra, é uma plataforma de *middleware* baseada em *Service-Oriented Architecture* (SOA), desenvolvida na linguagem Java, que oferece suporte ao desenvolvimento de aplicações com base em

informações fornecidas por dispositivos físicos heterogêneos, disponibilizando interfaces de serviços Web para controle destes dispositivos.

Carriots [Carriots 2018] propõe uma plataforma para aplicações em IoT que utiliza serviços de nuvem para gerenciar dados providos por qualquer tipo de dispositivo, além de conectar dispositivos e outros sistemas, o que faz se alinhar ao conceito de *Plataformas as a Service*(PaaS) da computação em nuvem.

A sistematização das funcionalidades e dos perfis operacionais destes trabalhos relacionados, tem sido centrais nos esforços de pesquisa referentes as novas funcionalidades do *middleware* EXEHDA.

#### 4. Arquitetura Desenvolvida

A proposta de *Fog Computing* para o *middleware* EXEHDA herda as características de Ciência de Contexto, empregando uma estratégia colaborativa entre a aplicação e o ambiente de execução, através da qual é oportuno ao programador individualizar políticas para gerenciar o comportamento de cada um dos componentes que constituem o software da aplicação. Na Figura 2 é apresentada a arquitetura desenvolvida para o Servidor de Borda do *middleware* EXEHDA, sendo mostrados os módulos que a compõem.

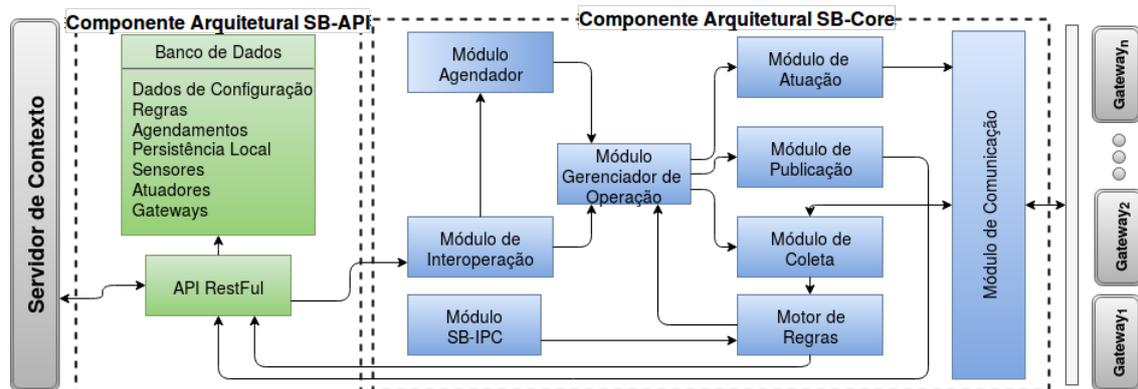


Figura 2. Módulos do Servidor de Borda.

##### 4.1. Componente Arquitetural SB-API

A SB-API, implementada sobre um web-server, é responsável pelas requisições provenientes de clientes ativos no momento, criando novos eventos para as mesmas. Os dados são recebidos via HTTP por requisição REST pela SB-API, e enviados tanto para o banco de dados, como para o Módulo de Interoperação em formato JSON. Através de um servidor *RestFul* utilizando o *framework Django*<sup>1</sup>, as requisições são processadas nos padrões REST para o acesso às informações e aos serviços do Servidor de Borda.

Na Tabela 1 são apresentados os possíveis URI's (Uniform Resource Identifiers) de acesso à SB-API. Esses recursos podem ser acessados pelos seguintes endereços: *groups, users, manufacturers, gateways, actuators, baseParameters, contextServers, sensorsTypes, sensors, persistances, rules, schedules e topics*.

<sup>1</sup><https://www.djangoproject.com/>

**Tabela 1. Tabela URI do SBWebService**

Verbo	URI	Descrição
GET	IP/	Lista todos os tipos de recursos
POST	IP/Recurso	Inserir um recurso
PUT	IP/Recurso/ID	Atualiza informações do recurso
GET	IP/Recurso/ID	Informações do recurso
DELETE	IP/Recurso/ID	Deleta o recurso

## 4.2. Componente Arquitetural SB-Core

O SB-Core é responsável pela atuação e processamento dos dados cadastrados na SB-API, bem como pelo acionamento de regras sobre os eventos a serem tratados.

As mensagens transferidas entre cada um dos módulos estão formatadas em JSON, dessa forma ocorre a padronização na passagem dos argumentos necessários para atuação de cada etapa do Servidor de Borda. Quando a SB-API recebe dados do Servidor de Contexto, a mesma salva as informações no Banco de Dados, comunicando o SB-Core sobre uma possível inserção de um novo sensor ou de um agendamento. Os agendamentos são registrados para sensores previamente cadastrados. Na Tabela 2 podem ser visualizadas as URI's utilizadas.

**Tabela 2. Tabela URI do SBCore**

Verbo	URI	Descrição
POST	IP/sigSensor_add	Notifica o core sobre um novo sensor
POST	IP/sigSensor_delete	Notifica o core sobre a remoção de sensor
POST	IP/sigScheduler_add	Notifica o core sobre um novo agendamento
POST	IP/sigScheduler_delete	Notifica o core sobre a remoção de agendamento

Os módulos que constituem o componente arquitetural do SB-Core estão descritos a seguir.

### Módulo Agendador

Gerencia os eventos periódicos cadastrados no banco de dados do SB-API, entre eles a leitura de dados dos sensores e controle dos atuadores. Por sua vez, os eventos aperiódicos produzidos por outros Servidores de Borda são recebidos através do Módulo de Interoperação. No controle das tarefas utilizou-se a biblioteca implementada em Python, *Advanced Python Scheduler*(APScheduler) [APScheduler 2018].

O *APScheduler* permite o cadastro de uma ação, considerando que a tal seja executada periodicamente ou uma única vez, permitindo a inserção e gerência de tarefas já cadastradas.

A biblioteca *APScheduler* possui três modos de gerência, entre eles: (i) **Cron-style scheduling**: é o modo mais completo, possui todos requisitos do *CRON* e funcionalidades de adicionar horário de início e de fim nas atuações de tarefas; (ii) **Interval-based execution**: executa as tarefas com intervalos regulares, com a opção de adicionar horário de início e término; e (iii) **One-off delayed execution**: executa uma única tarefa, determinada por data e horário específicos.

### **Módulo Gerenciador de Operações**

Administra o fluxo de dados do agendador com os demais módulos, verificando o tipo de evento a ser realizado, entre eles: atuação, coleta e publicação. Após a verificação, transmite os dados necessários para processamento nos módulos seguintes.

### **Módulo de Atuação**

Realiza a requisição de atuação através do Módulo de Comunicação, transmitindo uma mensagem JSON com os parâmetros necessários para identificar um determinado atuador conectado nos Gateways ativos.

### **Módulo de Coleta**

Requisição de coleta ao Módulo de Comunicação, enviando uma mensagem no formato JSON com os parâmetros necessários para a ação de coleta. Após o recebimento dos dados, os mesmos são repassados ao Motor de Regras para o seu processamento dos dados contextuais.

### **Módulo de Publicação**

Publica o dado contextual do ambiente no Servidor de Contexto e realiza o armazenamento temporário localmente. Entretanto, caso a publicação não seja efetivada por motivos de comunicação, os dados são armazenados localmente, e posteriormente quando a conexão for reestabelecida, os dados contextuais são transmitidos.

### **Motor de Regras**

Processa os dados contextuais relacionando as informações com as regras cadastradas pelo usuário, tendo potencial de combinar o dado contextual de um sensor com outro e até mesmo com outro ambiente em monitoramento, ou mesmo uma requisição de atuação sob o ambiente. O Motor de Regras é implementado em Python, de código aberto e sendo possível alterá-lo para uso em fins específicos.

### **Módulo de Comunicação**

Realiza as requisições de atuação e coleta do Servidor de Borda aos Gateways, disponibilizando uma única interface de comunicação com diversos protocolos existentes. Combinando o *UUID* do sensor ou atuador com o IP de acesso a este Gateway. Pode-se observar na Tabela 3, o formato das URI's utilizadas no acesso.

### **Módulo de Interoperação**

Emprega um Servidor HTTP, recebendo notificações compostas de novos sensores e agendamentos cadastrados no Servidor de Contexto, repassando as informações ao Módulo Agendador em tempo real. Essas URI's de acesso, podem ser visualizadas na Tabela 2.

### **Módulo SB-IPC**

Utiliza o protocolo de comunicação *Message Queue Telemetry Transport* (MQTT) para troca de dados. Este protocolo segue o modelo cliente/servidor, onde os dispositivos sensorizados são os clientes que se conectam a um servidor chamado Broker, usando TCP/IP. Os clientes podem subscrever em diversos tópicos, e são capazes de receber as mensagens

de diversos outros clientes que publicam neste tópico. Dessa forma, este módulo recebe dados de outros Servidores de Borda que são de seu interesse. Entre os dados recebidos, temos o dado contextual coletado e a regra relacionada a este dado. Os dados recebidos por este módulo são transmitidos ao Motor de Regras.

**Tabela 3. Tabela URI do Gateway**

Verbo	URI	Descrição
GET	IP/sensor?uuid=parametro	Coleta de dados do sensor físico
POST	IP/atuador?uuid=parametro	Ativa/desativa o atuador

## 5. Prototipação e Avaliação

A *Fog Computing* é implementada nas bordas computacionais do EXEHDA, transferindo parte do processamento para os sistemas embarcados localizados no ambiente do usuário final, sendo assim considerada uma nuvem computacional mais próxima da ocorrência dos eventos de interesse. Uma discussão detalhada da arquitetura do Servidor de Borda do EXEHDA pode ser encontrada em [Souza 2017].

A viticultura é uma frente de exploração agrícola que possui grande potencial econômico e social em diversas regiões do Brasil, e em particular no Rio Grande do Sul. A Viticultura de Precisão (VP) pode ser entendida como a gestão da variabilidade temporal e espacial das áreas cultivadas com o objetivo de melhorar o rendimento econômico da atividade agrícola [Braga and Pinto 2009].

Nesse sentido, uma das questões fundamentais na produção de vinhos de alta qualidade é o momento certo de irrigar. Para determinar o momento correto de irrigar é necessário avaliar as variáveis físicas do ambiente. No cenário em estudo, as variáveis contextuais consideradas são as seguintes: tensão de água no solo, temperatura e umidade do ar. Os comandos de atuação disparados através do processamento de regras, são os seguintes: alertas visuais e sonoros; envio de mensagens (SMS/e-mail); e atuação de transdutores elétricos para os acionamentos dos sistemas de irrigação.

Visando uma qualificação da informação e validação de consistência, foi considerado o uso de diversos sensores distribuídos ao longo das zonas de manejo. Cada zona de manejo é equipada com um Servidor de Borda capaz de gerenciar os Gateways e sensores atribuídos a estes, para que o controle de irrigação não seja inviabilizado por eventuais quedas de conexão de rede, ocasionando perda de contato com o Servidor de Contexto.

Através desse cenário pretende-se avaliar a capacidade de operação em *Fog Computing*. Atualmente, grande parte das áreas rurais dependem de conexões móveis através de rede de celular para conexão à Internet, muitas vezes sujeitas a conexões instáveis, baixa largura de banda e volume de dados mensais limitados através de franquias. Esses aspectos apontam para a necessidade de uso moderado do tráfego de dados através da Internet e o uso de estratégias que garantam a operação em momentos em que esse acesso não é possível.

## 5.1. Hardware e Software Utilizados

O Servidor de Borda foi concebido para ser disponibilizado nas instalações físicas através de um modelo Raspberry PI <sup>2</sup> B +, usando o sistema operacional Raspbian. Os Gateways são dispositivos de baixo poder computacional, utilizados como forma de comunicação entre os Sensores e Servidores de Borda. Visando o baixo consumo energético e o emprego de uma plataforma de software disseminada, para prototipação dos Gateways utilizou-se o processador ESP8266-12 [Kurniawan 2016], um dispositivo com suporte a comunicação WI-FI e programável através do framework de desenvolvimento da plataforma Arduino<sup>3</sup>.

Para atender as demandas de sensoriamento utilizou-se a tecnologia 1-Wire. Esta tecnologia apresenta a transmissão de dados através de um único barramento, no qual todos os dispositivos são endereçáveis, apresentando robustez e flexibilidade no desenvolvimento de redes sensores cabeados.

O ambiente computacional concebido para avaliação deste estudo de caso é baseado no *Common Open Research Emulator* (CORE) [Ahrenholz et al. 2008]. Este framework *open-source* desenvolvido pela *Boeing Research and Development Division* (BR&T)<sup>4</sup> visa a emulação de ambientes computacionais, permitindo assim testes largamente distribuídos sem a necessidade de implantações de custosos hardwares reais.

Os cenários providos pelo CORE são emulados dinamicamente na medida em que a execução se desenvolve, possibilitando conexões de rede entre ambientes reais e emulados, permitindo a criação de diversos hosts virtuais baseados em Linux. Tanto o Servidor de Contexto como os Servidores de Borda foram emulados no CORE.

O hardware utilizado nos testes com o CORE é dotado de um processador core i5 5200U de 2.2 GHz, 8 GB de RAM DDR3L e HD 1TB 5400 RPM, com distribuição Linux (Ubuntu 16.04), por sua vez os códigos pertinentes aos Servidores de Borda, Gateways e Sensores são executados em ambiente de emulação.

## 5.2. Resultados e Discussões

A avaliação da proposta de *Fog Computing* para o *middleware* EXEHDA, considerou as duas situações a seguir:

- **Operação sem FOG:** a publicação dos dados contextuais dos sensores é transmitida ao Servidor de Contexto no momento da coleta, recebendo toda comunicação sobre estado crítico de uma zona de manejo e disparando atuação remota. Nesse caso não há armazenamento de eventos e dados históricos sobre a irrigação, pois nesse sentido não há suporte a registro de eventos originados pelo Servidor de Contexto.
- **Operação com FOG:** realiza uma operação de filtragem e agregação de dados contextuais, publicando a média dos valores coletados, em períodos de 1 hora. Além de qualificar o controle do ambiente, as operações de publicação dos eventos e média da tensão do solo no Servidor de Contexto possibilitam preservar o histórico e o registro de que um evento ocorreu e que foi necessária uma atuação sob o ambiente.

<sup>2</sup><https://www.raspberrypi.org>

<sup>3</sup><https://www.arduino.cc/en/Reference/>

<sup>4</sup><http://www.boeing.com.au/products-services/research-technology.page>

Foram realizadas duas avaliações: (i) aquisições regulares; e (ii) leituras em intervalos reduzidos cuja descrição está a seguir.

Na primeira avaliação realizada, **aquisições regulares**, considerou-se a aquisição de dados contextuais da tensão do solo em intervalos de 5 minutos. A Tabela 4 apresenta os resultados obtidos com e sem a utilização de Fog em relação ao período de acúmulo de dados no Servidor de Contexto. Os resultados são categorizados em quatro grupos: hora; dia; semana; mês.

**Tabela 4. Quantidade de dados acumulados ao longo do período**

Período de envio	Sem Fog	Com Fog
1 Hora	0,044 MBytes	0,001 MBytes
1 Dia	1,066 MBytes	0,02 MBytes
7 Dias	7,462 MBytes	0,14 MBytes
30 Dias	31,968 MBytes	0,566 MBytes

Conforme pode ser visualizado na Tabela 4, com o emprego de *Fog Computing* foi obtido uma economia de aproximadamente 98% no fluxo de dados transmitidos. Esta economia é alcançada pela característica de o Servidor de Borda não enviar os dados coletados a todo momento ao Servidor de Contexto. Assim, o Servidor de Borda se torna responsável por controlar a atuação no ambiente em questão.

Na segunda avaliação realizada, **leituras em intervalos reduzidos**, foi realizada uma variação da frequência de aquisição de dados. Esta avaliação está relacionada a cenários onde é necessário preservar um rigoroso controle sobre o ambiente. Na Tabela 5 é apresentada uma comparação ao utilizar uma estratégia de *Fog Computing* aplicada à necessidade de verificação frequente às variáveis contextuais. Esta comparação é realizada com base na quantidade de dados enviada para o Servidor de Contexto, o cenário utiliza dados de coleta de um intervalo de 30 dias.

**Tabela 5. Quantidade de dados contextuais transmitidos em diferentes Intervalos**

Intervalo de coleta	Sem Fog	Com Fog
1 Minuto	159 MBytes	0,556 MBytes
5 Minutos	31,968 MBytes	0,556 MBytes
10 Minutos	15,984 MBytes	0,556 MBytes

Com o uso do *Fog Computing*, o Servidor de Borda calcula o valor médio dos dados coletados e publica esse valor no servidor de contexto a cada 1 hora, enviando uma quantidade menor de dados contextuais para o Servidor de Contexto, resultando em menor utilização da rede. Enquanto no ambiente sem *Fog Computing*, as publicações de dados contextuais são realizadas no momento da coleta e todos os dados são enviados.

## 6. Considerações Finais

A medida que a *Internet of Things* está crescendo, dispositivos embarcados, com recursos de sensoriamento, processamento, análise e comunicação, estão permitindo que objetos sejam monitorados e controlados remotamente através da infraestrutura de rede existente.

Considerando que a área de *Fog Computing* é uma área emergente no cenário internacional, se fez necessária uma busca criteriosa de trabalhos relacionados, tendo sido selecionados os mais relevantes. Empregando como referência as características dos trabalhos relacionados, foram concebidos os mecanismos empregados na arquitetura proposta, a qual atribui os conceitos de *Fog Computing* na coleta e processamento de dados contextuais. Sua operação acontece de maneira distribuída, empregando as bordas computacionais, bem como considera o emprego de regras no momento da especificação para atender as demandas de processamento contextual das diferentes aplicações.

As avaliações realizadas com o estudo de caso exploraram as funcionalidades em relação a gerência dinâmica para aquisição de dados contextuais e seu processamento distribuído. Os resultados obtidos se mostraram oportunos na redução de volume de dados transmitidos ao Servidor de Contexto, promovendo a Ciência de Contexto e, empregando as bordas computacionais de maneira distribuída.

Dentre os aspectos levantados para a continuidade do trabalho destaca-se a implementação da proposta *Fog Computing* para o EXEHDA na EMBRAPA Clima Temperado.

## Agradecimentos

O presente trabalho foi realizado com apoio da CAPES (Programa Nacional de Cooperação Acadêmica - Procad) e da FAPERGS (Programa Pesquisador Gaúcho - PqG).

## Referências

- Aazam, M. and Huh, E.-N. (2014). Fog computing and smart gateway based communication for cloud of things. In *Future Internet of Things and Cloud (FiCloud), 2014 International Conference on*, pages 464–470. IEEE.
- Ahrenholz, J., Danilov, C., Henderson, T. R., and Kim, J. H. (2008). Core: A real-time network emulator. In *MILCOM 2008-2008 IEEE Military Communications Conference*.
- APScheduler (2018). Disponível em: <https://apscheduler.readthedocs.io/en/latest>. Acesso em fevereiro de 2018.
- Bellavista, P., Corradi, A., Fanelli, M., and Foschini, L. (2012). A survey of context data distribution for mobile ubiquitous systems. *ACM Computing Surveys (CSUR)*, 44(4):24.
- Bonomi, F. (2011). Connected vehicles, the internet of things, and fog computing. In *The Eighth ACM International Workshop on Vehicular Inter-Networking (VANET), Las Vegas, USA*, pages 13–15.
- Bonomi, F., Milito, R., Natarajan, P., and Zhu, J. (2014). Fog computing: A platform for internet of things and analytics. In *Big Data and Internet of Things: A Roadmap for Smart Environments*, pages 169–186. Springer.
- Botta, A., de Donato, W., Persico, V., and Pescapé, A. (2016). Integration of cloud computing and internet of things: a survey. *Future Generation Computer Systems*, 56:684–700.

- Braga, R. and Pinto, P. (2009). Alterações climáticas e agricultura. *Inovação e Tecnologia na Formação Agrícola*, 12(2):34–56.
- Carriots (2018). Carriots iot application platform. Disponível em: <https://www.carriots.com/>. Acesso em julho de 2018.
- Davet, P., Kaiser Filho, H., João, L., Xavier, L., and Carvalho, T. (2015). Consciência de contexto na iot: uma arquitetura distribuída e escalável. *Brazilian Symposium on Computing Systems Engineering (SBESC)*.
- Fremantle, P. (2015). A reference architecture for the internet of things. *WSO2 White Paper*.
- Khattak, A. M., Akbar, N., Aazam, M., Ali, T., Khan, A. M., Jeon, S., Hwang, M., and Lee, S. (2014). Context representation and fusion: Advancements and opportunities. *Sensors*, 14(6):9628–9668.
- Kurniawan, A. (2016). *Sparkfun ESP8266 Thing Development Workshop*. PE PRESS, Canada. An optional note.
- LinkSmart (2018). Middleware for networked embedded systems. Disponível em: <https://docs.linksmart.eu/>. Acesso em julho de 2018.
- Lopes, J. L., de Souza, R. S., Geyer, C., da Costa, C., Barbosa, J., Pernas, A. M., and Yamin, A. (2014). A middleware architecture for dynamic adaptation in ubiquitous computing. *J. UCS*, 20(9):1327–1351.
- Peralta, G., Iglesias-Urkia, M., Barcelo, M., Gomez, R., Moran, A., and Bilbao, J. (2017). Fog computing based efficient iot scheme for the industry 4.0. In *Electronics, Control, Measurement, Signals and their Application to Mechatronics (ECMSM), 2017 IEEE International Workshop of*, pages 1–6. IEEE.
- Privat, G., Lemke, L., Borscia, P., and Capdevielle, M. (2016). Edge-of-cloud fast-data consolidation for the internet of things. *Proceedings of the 9th ACM Conference on Recommender Systems*.
- Souza, R., Lopes, J., Geyer, C., Garcia, C., Davet, P., and Yamin, A. (2015). Context awareness in ubicomp: An iot oriented distributed architecture. In *Electronics, Circuits, and Systems (ICECS), 2015 IEEE International Conference on*, pages 535–538. IEEE.
- Souza, R. S. (2017). *Um middleware para Internet das Coisas com suporte ao processamento distribuído do contexto*. Tese de doutorado em ciência da computação, Universidade Federal do Rio Grande do Sul - UFRGS, Brasil, Porto Alegre.
- Stojmenovic, I. and Wen, S. (2014). The fog computing paradigm: Scenarios and security issues. In *Computer Science and Information Systems (FedCSIS), 2014 Federated Conference on*, pages 1–8. IEEE.
- Vermesan, O. and Friess, P. (2014). *Internet of Things-From research and innovation to Market Deployment*. River Publishers.
- Xively (2018). Xively. Disponível em: <http://www.xively.com>. Acessado em janeiro de 2018.
- Zaslavsky, A., Perera, C., and Georgakopoulos, D. (2013). Sensing as a service and big data. *arXiv preprint arXiv:1301.0159*.

# SoyRetrieval - Técnicas de Aprendizado e Recuperação de Imagens para Análise do Vigor de Sementes de Soja

Rafael S. Bressan<sup>1</sup>, Marcelo de Souza Junior<sup>1</sup>, Douglas F. Pereira<sup>1</sup>,  
Pedro H. Bugatti<sup>1</sup>, Priscila T. M. Saito<sup>1,2</sup>

<sup>1</sup>Departamento de Computação Universidade Tecnológica Federal do Paraná  
(UTFPR) – Cornélio Procópio – PR – Brasil

<sup>2</sup>Instituto de Computação Universidade de Campinas  
(UNICAMP) – Campinas, SP – Brasil

{rafaelbressan, marcelojunior.2015, douglaspereira}@alunos.utfpr.edu.br  
{pbugatti, psaito}@utfpr.edu.br

**Abstract.** *The production and selection of high quality seeds are fundamental factors for the success of the soybean crop. To evaluate such quality the seed industry in Brazil has been adopting the so-called tetrazolium test. However, a problem that can be observed in this testing process and analysis of seeds is the time and effort required by the specialist, making the process extremely laborious. Therefore, this work aims at developing and making available to the specialists content-based image retrieval and classification tools. The results of the experiments show that the proposed approach presents significant gains compared to state-of-the-art techniques.*

**Resumo.** *A produção e seleção de sementes de alta qualidade são fatores primordiais para o sucesso da cultura da soja. O teste de tetrazólio tem se destacado e sido adotado pela indústria de sementes no Brasil. No entanto, uma problemática que pode ser observada nos processos de testes e análises das sementes é o tempo e esforço do especialista, tornando o processo extremamente laborioso. Portanto, o objetivo desse trabalho é desenvolver e disponibilizar para os especialistas ferramentas de classificação e de recuperação de imagens baseada em conteúdo. Os resultados dos experimentos mostram que a abordagem proposta apresenta ganhos significativos em comparação a técnicas amplamente utilizadas na literatura.*

## Introdução

A produção e seleção de sementes de alta qualidade são fatores primordiais para o sucesso da cultura da soja. Dessa forma, o processo de análise da qualidade das sementes torna-se essencial. Tal processo deve ser confiável e ágil, de forma a fornecer resultados precisos e de maneira rápida. A demora para obtenção de resultados em alguns testes de avaliação tradicional pode impactar negativamente a tomada de decisões relacionada aos processos de colheita, processamento, armazenagem e comercialização, resultando em prejuízos aos produtores de sementes [França-Neto et al. 2007].

O teste de tetrazólio tem se destacado e tem sido adotado pela indústria de sementes no Brasil, dada à sua rapidez, precisão, bem como pelas inúmeras informações

fornecidas. O teste possibilita avaliar a viabilidade e o vigor dos lotes de sementes, além de fornecer as causas da redução de qualidade, tais como: danos mecânicos, por umidade ou por percevejo. No entanto, uma problemática que pode ser observada nos processos de teste e análise das sementes é o tempo e esforço do especialista, pois a quantidade de lotes para análise pode chegar a milhares de sementes, tornando o processo extremamente laborioso.

Portanto, o objetivo desse trabalho é desenvolver e disponibilizar para os especialistas ferramentas de recuperação de imagens baseada em conteúdo e de classificação, de forma a auxiliá-los no processo de análise do vigor de sementes de soja, e que consequentemente possibilitem aumento na produtividade e na sustentabilidade da cultura da soja.

Para tanto, o presente trabalho propõe uma nova abordagem explorando estratégias de aprendizado ativo de forma a selecionar imagens mais relevantes para ambos os processos de aprendizado do classificador e do sistema de recuperação de imagens. Além disso, uma nova estratégia de aprendizado ativo específica para o problema é apresentada. Para validar a abordagem e estratégia propostas foram realizados experimentos utilizando diferentes subconjuntos de imagens de sementes de soja reais obtidas por meio do teste de tetrazólio, bem como técnicas de aprendizado do estado da arte. Para a descrição das imagens foram considerados diferentes extratores, bem como obtidos os melhores descritores, pares de extratores de características e funções de distância para cada um dos conjuntos avaliados.

## **Fundamentações**

A utilização de sementes de qualidade é um fator primordial para o sucesso da cultura da soja. No entanto, para que o sucesso seja alcançado, o controle de qualidade deve ser rápido e preciso, disponibilizando resultados plausíveis, de forma clara e objetiva [França-Neto et al. 1998]. A demora na obtenção de resultados interfere diretamente no processo de tomada de decisões na indústria de sementes, resultando em sérios prejuízos aos produtores de sementes, dificultando a tomada de decisão sobre a lavoura, a colheita e a armazenagem das sementes.

Devido à sua agilidade, o teste de tetrazólio se destacou na indústria de sementes, por trazer um maior número de informações sobre as mesmas, fornecendo resultados precisos sobre o vigor dos lotes de sementes, detectando as causas responsáveis pela redução da qualidade das sementes. A qualidade das sementes pode variar em função de alguns fatores, como o ataque de percevejos, danos mecânicos e deterioração por umidade. Dessa maneira, as sementes devem ser manuseadas de forma cuidadosa em todas as etapas da colheita, visando sua qualidade [Moreano 2012]. Apesar do teste de tetrazólio ser simples e não utilizar equipamentos e reagentes caros, [França-Neto et al. 1998] destaca que para a execução do mesmo é necessário que o analista de sementes seja bem treinado nas técnicas do teste, possuindo conhecimento das estruturas anatômicas da semente. Dessa forma, o conhecimento para realização do mesmo não é trivial.

Nesse sentido, técnicas de recuperação de imagem baseada em conteúdo (*Content-based Image Retrieval* - CBIR) podem ser interessantes, dado que possibilitam a recuperação de imagens com base na similaridade entre uma determinada imagem de consulta e um conjunto de dados. Para calcular essa similaridade, carac-

terísticas de baixo nível baseadas em cor, textura e/ou forma são extraídas das imagens [Malode and Gumaste 2015]. Quando o processo CBIR retorna as imagens similares, de acordo com uma determinada imagem de consulta, o processo pode ser alimentado com o grau de relevância de cada imagem retornada. Assim, essas informações são agregadas com às características da imagem e a função de distância para realizar uma nova consulta mais próxima da intenção do usuário. Esse processo de realimentação de relevância (*Relevance Feedback* - RF) pode ser realizado até que o usuário esteja satisfeito com as imagens retornadas.

De maneira geral, as técnicas de RF permitem realizar o refinamento de uma dada consulta por similaridade baseado na intenção do usuário. No entanto, apesar da existência de diversas técnicas de RF na literatura, a maioria dessas solicita do especialista a anotação das imagens visando apenas a relevância e irrelevância, relegando assim o conceito de diversidade. Tal fato, não contribui de maneira satisfatória para o aprendizado de um classificador ao utilizar tal conjunto de imagens baseado na experiência do especialista. Isso ocorre pois, com o refinamento da consulta ao longo das iterações, mais imagens relevantes são retornadas, e em muitos casos apenas imagens relevantes começam a ser retornadas. Em um primeiro instante, pode parecer que tal fato é extremamente satisfatório. No entanto, ao retornar apenas imagens relevantes em relação a uma dada consulta isso caracteriza-se como uma ênfase exacerbada a uma classe de imagens específica.

Caso um classificador seja treinado com tais imagens, o mesmo será enviesado a classificar corretamente apenas imagens pertencentes a tal classe, ou até mesmo, gerar um modelo extremamente superajustado que consiga apenas classificar corretamente as imagens pertencentes ao próprio conjunto de treinamento sem possibilidades de generalização. Portanto, para que um processo de aprendizado do classificador seja realizado de maneira condizente por meio de tais informações obtidas pelo processo de anotação do usuário, é necessário construir um conjunto de treinamento composto de imagens que possuam um balanceamento entre similaridade e incerteza com uma dada imagem de consulta. Isso permite que o processo não fique preso em soluções locais e restrito às mesmas.

Nesse contexto, estratégias de aprendizado ativo (*Active Learning* - AL) [Settles 2009] podem ser incorporadas ao processo de CBIR. Tais estratégias consistem em selecionar as amostras mais informativas para o treinamento do classificador, o qual participa do seu processo de aprendizado, auxiliando ativamente na seleção das amostras. Um oráculo (por exemplo, especialista) é considerado para confirmar/corrigir os rótulos das amostras.

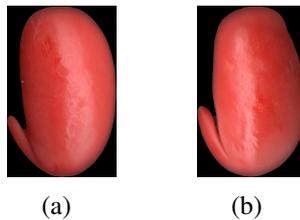
A heurística usada no processo de aprendizado ativo é baseada em como localizar as amostras mais informativas para treinamento do classificador. Para realizar essa tarefa alguns trabalhos propõem diferentes estratégias, dentre elas a seleção das amostras mais próximas à fronteira de decisão de um classificador [Alajlan et al. 2014, Tong and Chang 2001]. O objetivo consiste em selecionar as amostras mais diversas e incertas, próximas à fronteira de decisão do classificador, como sendo as amostras mais informativas, de forma a proporcionar um maior benefício ao modelo de aprendizado.

## Abordagem Proposta

A abordagem proposta agrega o paradigma de aprendizado ativo ao processo de CBIR. Para tanto, uma nova estratégia de aprendizado ativo é proposta e incorporada ao processo CBIR juntamente com RF. Considerando o processo de realimentação de relevância tradicional, na primeira iteração, o usuário realiza o processo de anotação (indicando as imagens relevantes e irrelevantes, de acordo com uma dada imagem de consulta). Em seguida, a partir da segunda iteração, as imagens recuperadas devem ser aquelas que mais contribuirão para o processo de aprendizado do classificador, o qual será treinado em um processo de aprendizado ativo.

Neste cenário, as imagens mais informativas a serem selecionadas são aquelas que apresentam o melhor balanceamento não somente entre a similaridade com a imagem de consulta, mas também certo grau de incerteza. O critério de seleção adotado deve permitir selecionar imagens de classes distintas, bem como que sejam difíceis de diferenciar quando comparada a semântica da imagem da consulta e a semântica da imagem recuperada (por exemplo, imagens na fronteira de duas classes diferentes/sobrepostas).

A Figura 1 apresenta um exemplo de duas amostras informativas de classes distintas, uma amostra sem dano e uma amostra com dano por percevejo, respectivamente. De acordo com o critério adotado de seleção, tais amostras podem ser selecionadas e apresentadas ao usuário, diferentemente do processo CBIR tradicional, que apresentaria apenas imagens mais próximas ao centro de consulta. A estratégia proposta possibilita equilibrar o processo de aprendizado com as imagens mais informativas (similares e incertas) que melhor contribuem para obter um classificador robusto mais rapidamente, e consequentemente, melhorar a qualidade das imagens retornadas, mais similares em relação à imagem de consulta.



**Figura 1. Exemplos de amostras informativas de duas classes diferentes (a) sem dano e (b) com dano por percevejo nível 3.**

As principais etapas da abordagem proposta são apresentadas na Figura 2. As linhas tracejadas representam o ciclo do processo de aprendizado incremental. O Algoritmo 1 descreve detalhes da abordagem proposta.

Na etapa 1, dada uma imagem de consulta  $q$ , o processo de recuperação é iniciado. Inicialmente, considerando  $q$  e um conjunto de dados de imagem  $\mathcal{I}$ , é realizada a seleção do melhor descritor (melhor par extrator de característica e função de distância). Como este processo é fundamental para o processo de recuperação, diferentes extratores de características  $F_i$  e funções de distância  $D_j$  foram avaliados. Em seguida, as características de baixo nível são extraídas de  $\mathcal{I}$  (Linha 1), utilizando o melhor extrator de características (BestFD.FeatureExtractor) e gerando o conjunto de aprendizado  $\mathcal{Z}_2$  (Linha 2). Também são extraídas características de  $q$ , utilizando o mesmo extrator.

Na etapa 2, o conjunto de aprendizado  $\mathcal{Z}_2$  é particionado em  $k$  grupos utilizando

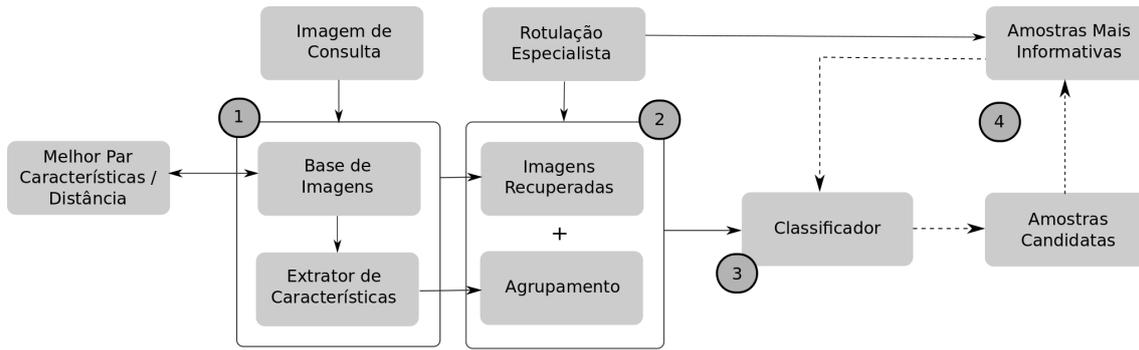


Figura 2. Pipeline da abordagem proposta.

**Algoritmo 1:** Abordagem proposta**Entrada** : imagem de consulta  $q$ **Saida** : instância final do modelo de aprendizado  $\mathcal{M}^\Omega$  e uma lista  $\mathcal{L}_R^\Omega$  ordenada por relevância em relação à  $q$ , sendo  $\mathcal{L}_R \subset I$ **Auxiliares:** conjunto de imagens  $I$ , conjuntos de extratores de características  $F_i$  e de funções de distância  $D_j$ , conjunto de aprendizado  $\mathcal{Z}_2$ , número de clusters  $k$ , conjunto de centroides/medóides  $\mathcal{C}$ , lista ordenada  $\mathcal{L}_S$  das imagens mais próximas a  $q$ , número de amostras  $ns$  desejadas, conjunto de treinamento temporário  $\mathcal{Z}'_1$ , conjunto de treinamento  $\mathcal{Z}_1$ , instância do modelo de aprendizado  $M$ , número de amostras a serem selecionadas  $nu$ .

- 1  $BestFD \leftarrow \text{MelhorDescritor}(I, F_i, D_j)$ ;
- 2  $\mathcal{Z}_2 \leftarrow \text{extraicaoCarateristicas}(BestFD.FeatureExtractor)$ ;
- 3  $\mathcal{C} \leftarrow \text{localizacaoCentroides}(\mathcal{Z}_2, k)$ ;
- 4  $\mathcal{L}_S \leftarrow \text{ordenacaoSimilaridade}(q, \mathcal{Z}_2, BestFD.Distance)$ ;
- 5  $\mathcal{Z}'_1 \leftarrow \mathcal{C} \cup \mathcal{L}_{S_i} \in \mathcal{Z}_2, i = 1, 2, \dots, ns$ ;
- 6  $\mathcal{Z}_1 \leftarrow \text{anotacao}(\mathcal{Z}'_1)$ ;
- 7  $M \leftarrow \text{treinamento}(\mathcal{Z}_1)$ ;
- 8 **repeat**
- 9      $\mathcal{Z}'_1 \leftarrow \text{selecao}(q, nu, BestFD.Distance, \mathcal{Z}_2 \setminus \mathcal{Z}_1, M)$ ;
- 10     $\mathcal{Z}_1 \leftarrow \mathcal{Z}_1 \cup \text{anotacao}(\mathcal{Z}'_1)$ ;
- 11     $M \leftarrow \text{reTreinamento}(\mathcal{Z}_1, M)$ ;
- 12 **until** *satisfeito*;
- 13  $\mathcal{M}^\Omega \leftarrow M$ ;
- 14  $\mathcal{L}_R^\Omega \leftarrow \text{ordenar}(\mathcal{Z}, \mathcal{M}^\Omega), \mathcal{L}_R^\Omega \subset I$ ;

um algoritmo de agrupamento (Linha 3). De acordo com a estratégia de agrupamento aplicada nesta tarefa, o centro de cada grupo pode ser um medóide, sendo assim não é necessário obter a imagem mais próxima do centroide, mas a própria imagem, gerando o conjunto de centróides/medóides  $\mathcal{C}$ . Além das imagens de  $\mathcal{C}$ , as imagens mais similares em relação à  $q$  são selecionadas. Para tanto,  $ns$  imagens desejadas são obtidas de  $\mathcal{L}_S$ , ordenadas por uma ordem crescente de distância em relação à  $q$  (Linhas 4 e 5). Essas imagens são apresentadas ao usuário para anotação (Linha 6). Sendo assim, o conjunto de treinamento  $\mathcal{Z}_1$  é composto pelas imagens mais próximas de cada centróide  $C$  e as  $\mathcal{L}_{S_i}$ ,

$i = 1, \dots, ns$  imagens mais próximas à  $q$ . As imagens anotadas constituem o conjunto de treinamento inicial  $\mathcal{Z}_1$ , o qual é utilizado no processo de treinamento (Linha 7), gerando a primeira instância do modelo de aprendizado  $\mathcal{M}$  (Etapa 3).

Finalmente, na etapa 4, o atual modelo de aprendizado  $\mathcal{M}$  participa ativamente do processo de seleção das imagens mais informativas a serem utilizadas em seu próprio treinamento, a fim de melhorar o resultado da consulta, retornando imagens mais similares. Para tanto, os critérios de seleção propostos são baseados na incerteza e similaridade em relação à imagem de consulta  $q$ . Assim, o conjunto temporário de treinamento  $\mathcal{Z}'_1$  recebe as  $nu$  imagens mais informativas em relação à  $q$ , de acordo com o modelo de aprendizado atual  $\mathcal{M}$ , as amostras restantes em  $\mathcal{Z}_2$  ( $\mathcal{Z}_2 \cap \mathcal{Z}_1 = \emptyset$  ou em uma notação simplificada  $\mathcal{Z}_2 \setminus \mathcal{Z}_1$ ), assim como a imagem de consulta  $q$  e a melhor função de distância  $BestFD.Distance$  (Linha 9). O conjunto de imagens selecionado  $\mathcal{Z}'_1$  é exibido para o usuário. A partir da primeira iteração, esse conjunto já é rotulado previamente pela instância atual do modelo. Assim, o usuário precisa apenas corrigir os rótulos de imagens classificadas incorretamente. As imagens confirmadas e corrigidas pelo usuário são adicionadas ao conjunto de treinamento  $\mathcal{Z}_1$ . O treinamento é realizado novamente e uma nova instância do modelo  $\mathcal{M}$  é gerada. As etapas 3 e 4 (Linhas 8 – 12) são repetidas até que o usuário esteja satisfeito com o processo de aprendizado.

O Algoritmo 2 descreve a estratégia de seleção proposta. Inicialmente, as Linhas 1-3 referem-se apenas a um controle para verificar se existem  $nu$  amostras desejadas para serem selecionadas no conjunto de aprendizado  $\mathcal{Z}_2 \setminus \mathcal{Z}_1$ , dado que trata-se de um processo iterativo, no qual um conjunto de imagens é selecionado a cada iteração. Em seguida, 4 conjuntos ou listas para controle e armazenamento de amostras são criados (Linha 4). As amostras do conjunto  $\mathcal{Z}_2 \setminus \mathcal{Z}_1$  são classificadas como relevantes ou irrelevantes a partir do modelo de aprendizado  $\mathcal{M}$  (Linha 5). Sendo assim, a lista  $\mathcal{L}_P$  recebe as amostras classificadas como relevantes a partir de  $\mathcal{Z}_2 \setminus \mathcal{Z}_1$  e  $\mathcal{L}_N$  recebe as classificadas como irrelevantes (Linhas 6-7). Em seguida, localiza-se o centro de massa de  $\mathcal{L}_P$ , armazenando-o em  $\mathcal{C}_P$  (Linha 8). O centro de massa pode ser calculado simplesmente pela média das características das amostras existentes na lista. As imagens em  $\mathcal{L}_P$  são ordenadas em relação à distância do centro de massa  $\mathcal{C}_P$ , sendo priorizadas as imagens de maior distância, ou seja, das mais distantes para mais próximas de  $\mathcal{C}_P$  (Linha 9). As imagens em  $\mathcal{L}_N$  também são ordenadas em relação à distância do centro de massa  $\mathcal{C}_P$ . No entanto, nesse caso as amostras são organizadas de forma inversa, sendo das mais próximas para mais distantes de  $\mathcal{C}_P$  (Linha 10). As amostras de  $\mathcal{L}_P$  e  $\mathcal{L}_N$  são concatenadas formando a lista de candidatas  $\mathcal{L}_C$ .

Finalmente, a estratégia de seleção retorna as  $nu$  primeiras amostras mais informativas de  $\mathcal{L}_{C_i}$ ,  $i = 1, \dots, nu$  (Algoritmo 1, Linha 9). Tais amostras são apresentadas para a anotação (como relevante ou irrelevante) pelo usuário. Após a anotação, tais amostras são incorporadas ao conjunto de treinamento  $\mathcal{Z}_1$  (Linha 10). Em seguida, o modelo  $\mathcal{M}$  é treinado novamente e uma nova instância é gerada (Linha 11). O usuário pode continuar o processo até que esteja satisfeito com os resultados retornados. Uma vez satisfeito, pode-se obter um modelo final de aprendizado  $\mathcal{M}^\Omega$  (Linha 13) e uma lista final  $\mathcal{L}_R^\Omega$  (Linha 14) ordenada por relevância (da mais similar para a menos similar) em relação a amostra de consulta  $q$ .

**Algoritmo 2:** Estratégia de seleção das imagens mais informativas

---

**Entrada** : imagem de consulta  $q$ , número de amostras a serem selecionadas  $nu$ , melhor função de distância  $BestFD.Distance$ , conjunto de aprendizado  $\mathcal{Z}_2 \setminus \mathcal{Z}_1$  e instância do modelo de aprendizado  $\mathcal{M}$

**Saida** : lista de amostras selecionadas  $\mathcal{L}_{\mathcal{R}}$ .

**Auxiliares:** lista de imagens candidatas  $\mathcal{L}_{\mathcal{C}}$ , lista de imagens relevantes  $\mathcal{L}_{\mathcal{P}}$ , lista de imagens irrelevantes  $\mathcal{L}_{\mathcal{N}}$  e centro de massa das amostras relevantes  $\mathcal{C}_{\mathcal{P}}$ .

```

1 if tamanho( $\mathcal{Z}_2 \setminus \mathcal{Z}_1$ ) <  $nu$  then
2   |  $nu \leftarrow$  tamanho( $\mathcal{Z}_2 \setminus \mathcal{Z}_1$ );
3 end
4  $\mathcal{L}_{\mathcal{P}}, \mathcal{L}_{\mathcal{N}}, \mathcal{C}_{\mathcal{P}}, \mathcal{L}_{\mathcal{C}} \leftarrow \emptyset$ ;
5 classificacaoImagens( $\mathcal{Z}_2 \setminus \mathcal{Z}_1, \mathcal{M}$ );
6  $\mathcal{L}_{\mathcal{P}} \leftarrow$  amostrasRelevantes( $\mathcal{Z}_2 \setminus \mathcal{Z}_1$ );
7  $\mathcal{L}_{\mathcal{N}} \leftarrow$  amostrasIrrelevantes( $\mathcal{Z}_2 \setminus \mathcal{Z}_1$ );
8  $\mathcal{C}_{\mathcal{P}} \leftarrow$  localizacaoCentroMassa( $\mathcal{L}_{\mathcal{P}}$ );
9 ordenacaoDecrescente( $\mathcal{L}_{\mathcal{P}}, BestFD.Distance, \mathcal{C}_{\mathcal{P}}$ );
10 ordenacaoCrescente( $\mathcal{L}_{\mathcal{N}}, BestFD.Distance, \mathcal{C}_{\mathcal{P}}$ );
11  $\mathcal{L}_{\mathcal{C}} \leftarrow$  concatenacao( $\mathcal{L}_{\mathcal{P}}, \mathcal{L}_{\mathcal{N}}$ );
12 while  $i \leq nu$  do
13   |  $\mathcal{L}_{\mathcal{R}} \leftarrow \mathcal{L}_{\mathcal{C}_i} \cup \mathcal{Z}_2 \setminus \mathcal{Z}_1$ ;
14 end

```

---

## Experimentos

A presente seção descreve os experimentos realizados para validação, abrangendo a descrição dos conjuntos de dados utilizados, os cenários de análise, bem como os resultados obtidos por meio de comparações com técnicas do estado da arte na área.

### Conjuntos de Dados

Para os experimentos foram considerados 4 conjuntos de imagens reais de sementes de soja. A Tabela 1 apresenta a descrição de cada um deles, incluindo a quantidade de imagens pertencentes a cada conjunto, quantidade de classes, e intervalo de variação de quantidade de imagens por classe. Nota-se os desafios e desbalanceamentos característicos de problemas e dados reais. O conjunto  $I_1$  foi obtido a partir de [Santanna et al. 2014]. Já os conjuntos  $I_2$ ,  $I_3$  e  $I_4$  foram criados por meio de captura in-loco em um laboratório de análise de sementes, pertencente a uma unidade de beneficiamento de sementes.

**Tabela 1. Descrição de cada conjunto de dados público usado nos experimentos**

Nome	Imagens	Classes	Imagens/classes
$I_1$	576	12	15-74
$I_2$	350	7	5-103
$I_3$	691	7	6-199
$I_4$	1333	10	7-529

## Cenários

Com o intuito de analisar e validar a abordagem proposta, a qual foi nomeada como AL-NEW, foram realizados testes comparativos utilizando 3 diferentes abordagens do estado da arte amplamente utilizadas na literatura: movimentação de centro de consulta (*Query Point Movement Strategy* - QPM) [Liu et al. 2009], expansão de consulta (*Query Expansion* - QEX) [Porkaew and Chakrabarti 1999], e aprendizado ativo baseado em SVMs (SVM-AL) [Tong and Chang 2001]. Além disso, como comparativo basal para todas as abordagens elencadas, foram também explicitados os resultados obtidos por meio do processo CBIR tradicional. Para facilitar a leitura e interpretação dos resultados, as abordagens da literatura citadas foram nomeadas, respectivamente, para: QPM, QEX, SVM-AL e CBIR-T.

A partir dos conjuntos de imagens descritos na Seção 4.1 foram extraídas características de cor e textura. Os métodos utilizados para extração de tais características são detalhados na Tabela 2 e nomeados como  $F_i$ , onde  $0 < i < 5$ . Cada tipo de característica extraída foi também comparado com diferentes funções de distância, obtendo o melhor descritor (par extrator de características/função de distância) em cada conjunto de imagens, para realizar as consultas por similaridade. Para tais comparações, foram utilizadas 7 diferentes funções de distância, tais como:  $L_1$ ,  $L_2$ ,  $L_\infty$ ,  $X_2$ , *Canberra*, *Jeffrey Divergence* e *dLog*. A Tabela 3 apresenta a melhor função de distância para cada extrator de característica  $F_i$  e conjunto de dados. Além disso, é possível observar o melhor descritor para cada conjunto (por meio dos extratores destacados em negrito).

**Tabela 2. Propriedades de cada extrator de características.**

Extratores	Categoria	#Caraterísticas
$F_1$ - BIC [Stehling et al. 2002]	Cor	128
$F_2$ - GCH [Stricker and Orengo 1995]	Cor	255
$F_3$ - LBP [Guo et al. 2010]	Textura	256
$F_4$ - LCH [Smith and Chang 1996]	Cor	135

**Tabela 3. Melhores descritores para cada conjunto de imagens  $I$ .**

	$F_1$	$F_2$	$F_3$	$F_4$
$I_1$	<b>Jeffrey</b>	$X_2$	dLog	$X_2$
$I_2$	dLog	$L_\infty$	<b>dLog</b>	Canberra
$I_3$	dLog	$L_\infty$	dLog	Canberra
$I_4$	<b>Canberra</b>	Jeffrey	$L_2$	Canberra

Para o processo de aprendizado do modelo  $\mathcal{M}$ , foi utilizado o classificador baseado em  $k$ -vizinhos mais próximos ( $k$ -NN). Em relação ao processo de agrupamento foi utilizada a técnica  $k$ -means. Vale ressaltar que a abordagem proposta pode ser instanciada considerando qualquer classificador supervisionado ou técnica de agrupamento. Com relação à quantidade de amostras selecionadas  $nu$ , para a primeira iteração, o valor de  $k$  definido para o agrupamento consiste em  $1/3$  de  $nu$ , já para as amostras mais próximas da imagem de consulta, o valor definido foi de  $2/3$  de  $nu$ , formando assim, a primeira instancia do classificador.

Para a comparação da abordagem proposta com os outros métodos do estado da arte foram gerados gráficos de Precisão e Revocação (P&R). A precisão de uma con-

sulta pode ser entendida como a fração de imagens relevantes recuperadas, já a revocação é a proporção de imagens relevantes que foram recuperadas por meio da mesma, considerando todas as imagens relevantes no conjunto de dados. Dessa forma, a precisão atinge 100% quando cada imagem recuperada é relevante para a consulta, e a revocação atinge 100% quando todas as imagens relevantes do conjunto de dados foram retornadas [Baeza-Yates and Ribeiro-Neto 2011]. Como regra geral, quanto mais próxima a curva de P&R do topo do gráfico, melhor é a abordagem.

Para construir os gráficos P&R foram realizadas diversas consultas por similaridade utilizando o operador baseado em  $k$ -vizinhos mais próximos. Vale ressaltar que todas as imagens de cada um dos conjuntos foram utilizadas como imagens de consulta. A quantidade de imagens retornadas pelas consultas por similaridade foi definida como 30, ou seja,  $nu = 30$ . Tal valor foi especificado para estar em concordância com a prática de análise diária realizada no processo de análise de sementes. Com o intuito de resumir os resultados obtidos, foram gerados gráficos de P&R por meio do conceito de *Mean Average Precision* (MAP), conforme definido em [Baeza-Yates and Ribeiro-Neto 2011]. Além disso, podem ocorrer casos nos quais uma dada classe de imagens não possua 30 amostras. Dessa forma, em tal ocorrência, o valor  $nu$  é definido de acordo com o número de amostras dessa classe.

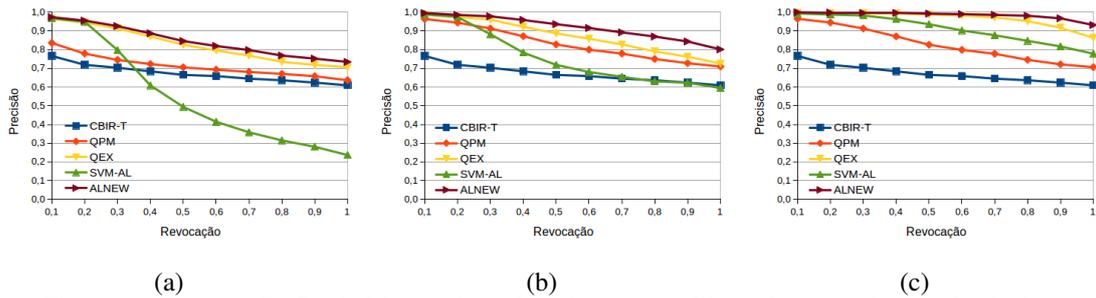
## Resultados

As Figuras 3 a 6 ilustram os resultados obtidos pela abordagem proposta ALNEW em comparação com as abordagens tradicionais CBIR-T, QPM, QEX e SVM-AL, na primeira, quarta e oitava iterações de realimentação, utilizando os conjuntos de imagens  $I_1$  a  $I_4$  (ver Seção 4.1), respectivamente. Em tais gráficos de P&R, a precisão obtida pela abordagem CBIR tradicional foi ilustrada como comparativo base em todos os gráficos, uma vez que não passa pelo refinamento da consulta inicial.

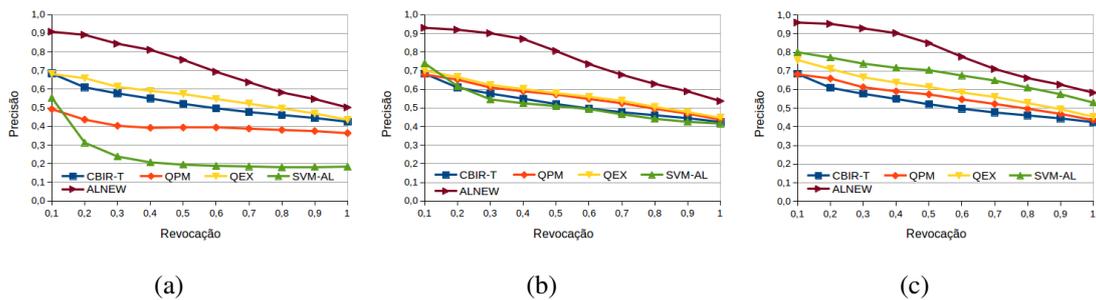
Analisando o conjunto  $I_1$  (Figura 3) pode-se observar que a abordagem ALNEW apresenta as melhores precisões em todas as iterações, quando comparada com as outras abordagens em análise. ALNEW foi até 2,1 vezes melhor que SVM-AL, bem como obteve ganhos de precisão de até 34,66% e 19,68%, considerando, respectivamente, a primeira, quarta e oitava iterações. Em relação à abordagem QEX, ALNEW apresentou ganhos de até 3,99%, 10,34% e 7,87% para as mesmas iterações. Ao comparar ALNEW com a abordagem QPM, novamente foram obtidos ganhos consideráveis de até 15,38%, 12,89% e 31,90% na precisão das consultas.

Comportamento semelhante foi observado ao analisar os resultados obtidos pela abordagem proposta ALNEW, quando aplicada ao conjunto de imagens  $I_2$  (Figura 4). ALNEW apresentou maiores valores de precisão em comparação às demais abordagens. ALNEW obteve uma precisão de 76%, 81% e 85% para a primeira, quarta e oitava iterações, respectivamente. Considerando um nível de revocação de 50%, ALNEW apresenta um ganho mínimo de precisão de 20% e um ganho máximo de até 2,89 vezes em relação às demais técnicas.

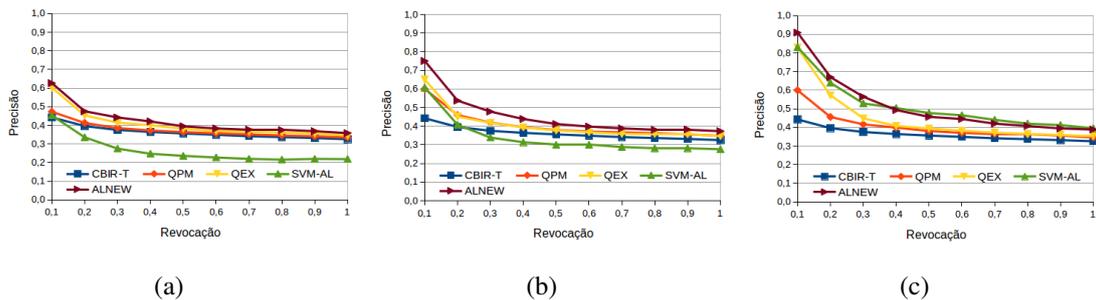
Para o conjunto  $I_3$  (Figura 5), nota-se novamente que ALNEW obteve um ganho de precisão considerável. Por exemplo, para um nível de revocação de 10% nas sucessivas iterações (Figuras 5(a)-(c)), a abordagem proposta atingiu ganhos de no mínimo 3,98% e no máximo 105,22%. Vale enfatizar que níveis de revocação mais baixos são de maior



**Figura 3. Curvas P&R obtidas pelas abordagens, utilizando o conjunto de dados  $I_1$ , considerando: (a) primeira, (b) quarta e (c) oitava iteração.**



**Figura 4. Curvas P&R obtidas pelas abordagens, utilizando o conjunto de dados  $I_2$ , considerando: (a) primeira, (b) quarta e (c) oitava iteração.**



**Figura 5. Curvas P&R obtidas pelas abordagens, utilizando o conjunto de dados  $I_3$ , considerando: (a) primeira, (b) quarta e (c) oitava iteração.**

importância, uma vez que aproximam-se mais de análises cotidianas realizadas.

Por fim, para o conjunto  $I_4$  (Figura 6), a abordagem ALNEW novamente apresentou ganhos consideráveis de precisão em comparação com as outras abordagens. Por exemplo, considerando um nível de revocação de 10%, a mesma foi 5,09 vezes melhor que a abordagem SVM-AL na primeira iteração. Além disso, para o mesmo nível de revocação, considerando a quarta e a oitava iterações, ALNEW apresentou ganhos de precisão de 63% e 22% em relação à SVM-AL. Em relação a QPM obteve um ganho de até 21%, considerando a primeira iteração. Já ao comparar com a QEX, o ganho na precisão foi de até 2% na oitava iteração.

A partir dos resultados obtidos, pode-se concluir que a abordagem proposta apresentou consideráveis ganhos de precisão em relação às consultas por similaridade em conjuntos provenientes de imagens de soja submetidas ao teste de tetrazólio. Além disso, a abordagem ALNEW também apresenta um grau menor de saturação no decorrer das subsequentes iterações de realimentação em todos os conjuntos de imagens analisados. Com o intuito de resumir os resultados, na Tabela 4 são apresentadas as precisões médias

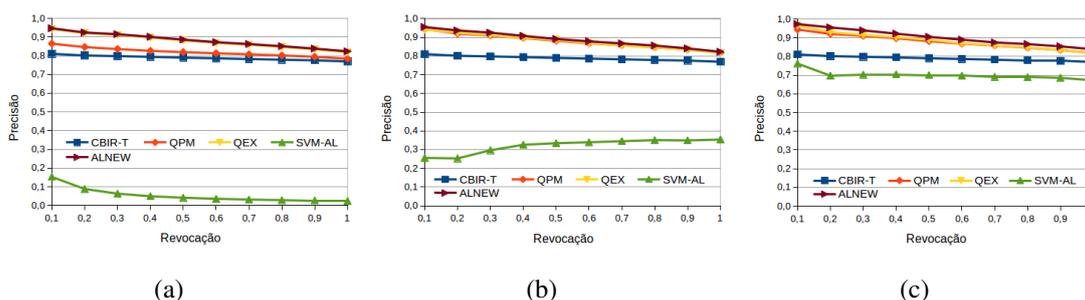


Figura 6. Curvas P&R obtidas pelas abordagens, utilizando o conjunto de imagens  $I_4$ , considerando: (a) primeira, (b) quarta e (c) oitava iteração.

Tabela 4. Precisões médias gerais obtidas por cada abordagem e conjunto de imagens, considerando todas as iterações de realimentação.

Base	QPM	QEX	SVM-AL	ALNEW
$I_1$	80,9	88,8	76,4	<b>92,3</b>
$I_2$	53,1	57,7	51,8	<b>76,1</b>
$I_3$	40,1	41,8	37,4	<b>46,5</b>
$I_4$	86,7	87,6	60,2	<b>89,0</b>

gerais obtidas por cada abordagem e conjunto de dados utilizados no presente trabalho, considerando todas as iterações de realimentação (i.e. da 1<sup>a</sup> até a 8<sup>a</sup> iteração). Para a obtenção de tal precisão média geral foi calculada a integral das curvas de P&R para cada abordagem em cada iteração e realizada a média de tais integrais, como definido em [Baeza-Yates and Ribeiro-Neto 2011]. Ao analisar os resultados sumarizados na Tabela 4, nota-se claramente que a abordagem ALNEW atingiu os melhores níveis de precisão no decorrer das iterações, mantendo maior consistência e robustez.

## Conclusão

No presente trabalho é apresentada uma nova abordagem de aprendizado e recuperação de imagens, incluindo uma nova estratégia de aprendizado ativo capaz de ser integrada de maneira trivial ao processo CBIR, de forma a tratar problemas intrínsecos ao mesmo, bem como prover maior eficácia ao processo.

Por meio dos experimentos, foi possível constatar que a abordagem proposta provê melhorias consideráveis em relação à precisão de consultas por similaridade no domínio de análise de sementes. Dessa forma, os resultados demonstram que a abordagem é altamente viável de aplicação no contexto de análise do vigor de sementes de soja. Tal contribuição pode gerar impacto considerável e melhorias na produtividade de tal cultivar e sustentabilidade como um todo, ao prover um processo mais robusto, com maior rapidez e eficácia.

Em trabalhos futuros pretende-se realizar a avaliação de diferentes classificadores supervisionados e técnicas de agrupamentos gerando diferentes instâncias da abordagem proposta. Além disso, vislumbra-se também a proposta de outras estratégias de aprendizado ativo para a seleção de amostras informativas, conseqüentemente, levando à melhoria da precisão de consultas por similaridade.

## Agradecimentos

O presente trabalho recebeu apoios oriundos do CNPq: grants #472625/2014-4, #431668/2016-7, #422811/2016-5; CAPES; Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná; SETI; Belagrícola; e UTFPR.

## Referências

- Alajlan, N., Pasolli, E., Melgani, F., and Franzoso, A. (2014). Large-scale image classification using active learning. *IEEE GRSL*, 11(1):259–263.
- Baeza-Yates, R. and Ribeiro-Neto, B. (2011). *Modern Information Retrieval: The Concepts and Technology Behind Search*. Addison-Wesley Publ. Comp., 2nd ed.
- França-Neto, J. B., Krzyzanowski, F. C., and da Costa, N. P. (1998). *O Teste de Tetrazólio em Sementes de Soja*. Embrapa - Centro Nacional de Pesquisa de Soja, Londrina.
- França-Neto, J. B., Krzyzanowski, F. C., Henning, A. A., de Pádua, G. P., et al. (2007). Tecnologia da produção de semente de soja de alta qualidade. *Embrapa Soja-Artigo em periódico indexado (ALICE)*.
- Guo, Z., Zhang, L., and Zhang, D. (2010). Rotation invariant texture classification using LBP variance (LBPV) with global matching. *PR*, 43(3):706–719.
- Liu, D., Hua, K. A., Vu, K., and Yu, N. (2009). Fast query point movement techniques for large cbir systems. *IEEE TKDE*, 21(5):729–743.
- Malode, P. and Gumaste, S. V. (2015). A review paper on content based image retrieval. *Intl. Research Journal of Engineering and Technology*, 20:883–885.
- Moreano, T. B. (2012). *Evolução das Qualidades Física e Fisiológica da Semente de Soja no Beneficiamento*. Dissertação de mestrado, UEM, Maringá.
- Porkaew, K. and Chakrabarti, K. (1999). Query refinement for multimedia similarity retrieval in mars. In *ACM Intl. Conference on Multimedia*, pages 235–238.
- Santanna, M. G. F., Saito, P. T. M., and Bugatti, P. H. (2014). Content-based image retrieval towards the automatic characterization of soybean seed vigor. In *ACM Symposium on Applied Computing*, pages 964–969.
- Settles, B. (2009). Active learning literature survey. Computer Sciences Technical Report 1648, University of Wisconsin–Madison.
- Smith, J. R. and Chang, S.-F. (1996). Local color and texture extraction and spatial query. In *Intl. Conference on Image Processing*, volume 3, pages 1011–1014.
- Stehling, R. O., Nascimento, M. A., and Falcão, A. X. (2002). A compact and efficient image retrieval approach based on border/interior pixel classification. In *Intl. Conference on Information and Knowledge Management*, pages 102–109.
- Stricker, M. A. and Orengo, M. (1995). Similarity of color images. In *Storage and Retrieval for Image and Video Databases III*, volume 2420, pages 381–393. International Society for Optics and Photonics.
- Tong, S. and Chang, E. (2001). Support vector machine active learning for image retrieval. In *ACM International Conference on Multimedia*, pages 107–118.

# Extração de dados de fontes textuais: uma abordagem para enriquecimento de dados abertos interligados

Karen Torres Teixeira, Maria Luiza Machado Campos, João C. P. da Silva

<sup>1</sup>Programa de Pós-Graduação em Informática  
Universidade Federal do Rio de Janeiro (UFRJ)  
Rio de Janeiro – RJ – Brasil

karentteixeira@gmail.com; mluiza@ppgi.ufrj.br; jcps@dcc.ufrj.br

**Abstract.** *In the Web of Data, data items are interconnected and associated with descriptive annotations, taking advantage of a representation in the form of triples. In this context, documents and other textual sources can be annotated to be incorporated into this universe as resources or serving as sources for extracting new triples. The purpose of this article is to present an approach for data extraction and triple generation from texts with specific styles, aiming at their association and connection to existing databases. The approach was applied and evaluated in the context of a portal with information on the consumption of pesticides in Brazil.*

**Resumo.** *Na Web de Dados, itens de dados são interconectados e associados a anotações descritivas na forma de vocabulários, tirando vantagem de uma representação em triplas. Neste contexto, documentos e outras fontes textuais podem ser anotados para serem incorporados a este universo como recursos ou servindo também de base para extração de novas triplas. O objetivo deste artigo é apresentar uma abordagem para extração de dados e geração de triplas a partir de textos com estilos específicos visando o enriquecimento de dados abertos interligados, através de sua associação e ligação a bases existentes. A abordagem foi aplicada e avaliada no contexto de um portal com informações sobre o consumo de agrotóxicos no Brasil.*

## 1. Introdução

A importância de obter informações e gerar conhecimento é uma das principais motivações para uso de tecnologia computacional no mundo atual. A informação é gerada a partir da disponibilização, organização e exploração de dados, cujo volume cresceu enormemente com o surgimento da *web*, onde uma grande quantidade de dados é publicada na forma de dados abertos.

Nos últimos anos, para permitir que esses dados possam ser explorados de forma conjunta e processados por agentes de software com maior agilidade, surge a assim chamada Web de Dados. Nesta, ao invés de associações entre páginas e documentos, itens de dados são interligados, tirando vantagem de uma representação em triplas, onde os dados são interconectados e associados a anotações descritivas na forma de vocabulários ou ontologias.

Uma consequência importante da interligação de dados seguindo os padrões propostos pela Web Semântica<sup>1</sup> (chamados de dados abertos interligados ou Linked Open

<sup>1</sup><http://www.w3c.br/Padroes/WebSemantica>

Data – LOD, em inglês) é a possibilidade de geração de novos conhecimentos a partir da exploração das ligações entre diferentes recursos na *web*.

É neste contexto, que o Observatório de Atenção Permanente ao Uso de Agrotóxicos <sup>2</sup> foi criado, visando disponibilizar informações referentes ao uso de agrotóxicos em um portal de dados abertos. Este portal foi desenvolvido utilizando a plataforma CKAN, que é um gerenciador de conteúdo (dados). O CKAN é muito utilizado por governos, organizações e instituições que coletam muitos dados, por facilitar a realização de tarefas como gerenciamento e publicação de dados, busca facetada para navegação e visualização dos dados. Apesar dos dados estarem publicados no portal, eles ainda não se encontram totalmente triplificados (tarefa em andamento), o que não permite sua ligação com outras bases de dados. Para evidenciar um dos benefícios do uso de LOD neste contexto, considere um conjunto de dados que trata de agrotóxicos permitidos e proibidos, e outro que compreende agrotóxicos utilizados em uma determinada produção agrícola. Se esses dados são publicados como LOD, é possível descobrir que um agrotóxico usado intensivamente na produção de tomate é o mesmo agrotóxico descrito no outro dataset e que consta como proibido. A interligação desses itens de dados permitirá não só sua recuperação conjunta, mas também expandirá as possibilidades de descoberta de novos conhecimentos a partir dessas fontes de dados.

Embora exista amplo uso de LOD sobre dados estruturados, como CSV, XML, HTML, o mesmo não vale para dados não estruturados como imagens, vídeos e textos. Isto porque tratar dados não estruturados é uma tarefa árdua. Considerando a enorme quantidade de informações relevantes em formato textual, é muito importante a sua transformação para o formato estruturado ou semiestruturado. A extração de informação de um texto pode gerar um enriquecimento de informação muito maior.

O Processamento de Linguagem Natural (PLN) é uma área da Computação que estuda técnicas e mecanismos que possibilitam ao computador manipular e interpretar os dados não estruturados. Entre as tarefas estudadas em PLN estão o reconhecimento de entidades nomeadas e a extração de relações entre as entidades [Nadkarni et al. 2011]. Essas tarefas auxiliam o computador na identificação de lugares, pessoas, organizações e outras formas de entidades e na relação entre elas. Assim, as informações que antes não possuíam formato estruturado, agora possuem uma representação dos dados que permite sua melhor manipulação e interoperabilidade pelo computador.

Para extrair informações de textos, diversos métodos já foram propostos, podendo ser baseados em (i) regras, (ii) aprendizado supervisionado, (iii) aprendizado semi-supervisionado e (iv) aprendizado não supervisionado [de Abreu et al. 2013].

Esses métodos podem ser utilizados tanto em domínio específico, a exemplo de textos com estilos semelhantes em um determinado domínio, quanto em domínio aberto, onde independem do estilo e domínio do texto e da quantidade de relações existentes. Neste último, não é necessária a análise prévia do texto, sendo utilizadas técnicas referentes à estrutura da linguagem e não referente a um domínio restrito para que ocorra a extração.

É neste contexto de extração de informação, PLN e Web Semântica que este trabalho se insere. O objetivo deste artigo é apresentar uma abordagem para extração de

<sup>2</sup>[http://dados.contraosagrototoxicos.org/pt\\_PT/](http://dados.contraosagrototoxicos.org/pt_PT/)

dados e geração de triplas a partir de textos com estilos específicos, visando o enriquecimento de dados abertos interligados, através de sua associação e ligação a bases existentes. O trabalho foi desenvolvido tendo como alvo os datasets do portal do Observatório e interligando-o, como exemplo, ao Agrovoc [Caracciolo et al. 2013], Bioportal [Noy et al. 2009] e DBpedia [Lehmann et al. 2015].

Este artigo está organizado da seguinte maneira: a seção 2 revisa e classifica trabalhos relacionados a técnicas para extração de informações a partir de textos. A seção 3 descreve a abordagem proposta. Na seção 4 são detalhados os experimentos e os primeiros resultados, finalizando com a seção 5 que apresenta algumas conclusões e os próximos passos.

## 2. Trabalhos relacionados

Buscando verificar o estado da arte de técnicas e mecanismos para extração de dados a partir de fontes textuais, foi realizado um levantamento de trabalhos nesta área. Esta seção apresenta uma visão geral desse levantamento e uma caracterização dos métodos revisados.

### 2.1. Método baseado em regras

Esta foi uma das primeiras abordagens propostas para sistemas de extração. Nela é necessário que um humano escreva e desenvolva regras ou expressões regulares para que a informação desejada seja extraída.

Os primeiros trabalhos que utilizaram esta abordagem focaram em domínios específicos. Como exemplo, nos trabalhos de [Grishman et al. 1991] e [Lehnert et al. 1991] as regras foram definidas a partir do domínio e estilo dos textos, sendo seu objetivo extrair informações de textos sobre ações de terrorismo para completar templates com essas informações sobre o tipo do evento, data, localização, vítimas e alvos físicos. Em caso de nova informação, uma nova regra deve ser definida. Esses sistemas não são escaláveis para outros domínios sem precisar de alteração, pois utilizam regras e templates específicos.

A vantagem desta abordagem para domínios específicos é que a semelhança dos estilos de textos facilita a definição das regras. A desvantagem deste método é que, como as regras são pré-definidas, se um novo tipo de relação tiver que ser extraído, então é preciso adicionar uma nova regra ao conjunto existente.

A extração em domínios abertos (Open Information Extraction - OIE) [Etzioni et al. 2008] como a *web* é mais complexa devido à grande quantidade de entidades e relações. Um sistema baseado em OIE deve operar em duas fases. Primeiro, deve aprender um modelo geral de como os relacionamentos e entidades são representados e expressados em uma determinada linguagem. Segundo, deve utilizar esse modelo como base para o extrator de relação independente de domínio, em que a entrada é um corpus de documentos e a saída são triplas extraídas.

Para aprender o modelo geral de como as relações são expressas em uma determinada linguagem, diferentes recursos podem ser utilizados, como por exemplo análise morfológica, sintática e semântica. Podemos citar como exemplos deste tipo de sistema: Graphia [Carvalho et al. 2013], LODifier

[Augenstein et al. 2012], ReVerb [Fader et al. 2011], DepOE [Gamallo et al. 2012] e ClausIE [Del Corro and Gemulla 2013]. Uma característica comum a tais sistemas é que os mecanismos de PLN usados na análise das sentenças têm um impacto forte na qualidade das extrações obtidas.

## 2.2. Método baseado em aprendizado supervisionado

Esta abordagem surgiu com o objetivo de que o computador pudesse aprender/definir as regras de extração, ao invés de um humano ter que fazê-lo. Esse processo de aprendizado é feito com um conjunto de textos anotados por especialistas de domínio que servem como um conjunto de treinamento para que a máquina possa aprender as regras desejadas. Esta abordagem pode ser aplicada para domínios específicos (como em [Lange et al. 2010] e [Joshi et al. 2013]) ou para domínios abertos (como em [Byrne and Klein 2010] e [de Souza and Claro 2014]).

## 2.3. Método baseado em aprendizado semi-supervisionado

Esta abordagem tenta contornar o problema dos métodos supervisionados, de necessitar de uma base anotada, utilizando apenas um pequeno conjunto de dados anotados e outro conjunto não-anotado. Exemplos de sistemas que usam essa abordagem são o DIPRE [Brin 1999] e o Snowball [Agichtein and Gravano 2000], ambos aplicados a domínios específicos.

## 2.4. Método baseado em aprendizado não-supervisionado

Nesta abordagem, o objetivo é extrair informação sem a necessidade de se usar uma base previamente anotada. Isso pode ser feito através de um conjunto de relações genéricas para descobrir/aprender novas relações, atributos e instâncias, ou através da utilização de uma base de conhecimento para o domínio, onde as relações existentes em tais bases possam ser exportadas para outras bases que se refiram ao mesmo domínio da base original.

No sistema Espresso [Pantel and Pennacchiotti 2006], este método foi utilizado. O sistema começa com um conjunto de instâncias e tenta encontrar no texto trechos semelhantes ao conjunto inicial. Neste caso, a extração ocorreu em domínio específico e as relações semânticas extraídas foram referentes a *isa*, *part-of*, *succession*, *reaction*, e *production*. Outros trabalhos que utilizaram a abordagem não-supervisionada para domínios abertos foram o KnowitAll, [Etzioni et al. 2005], TextRunner [Yates et al. 2007].

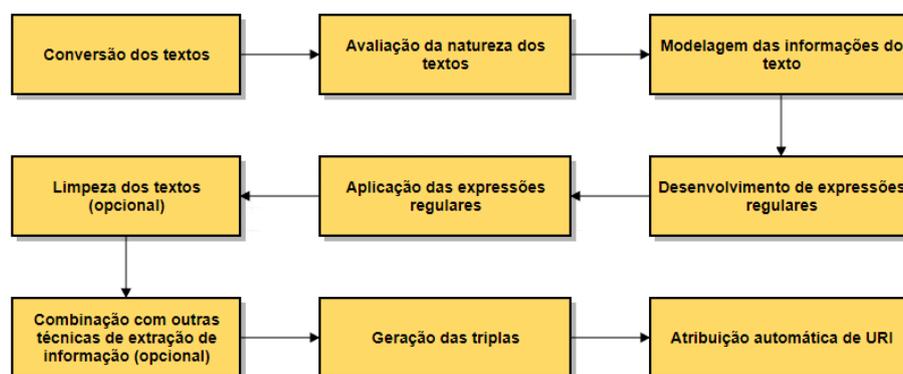
Esta abordagem apesar de não necessitar de dados anotados e nem regras escritas por humanos, possui mais chances de extrair relações indesejáveis e incoerentes, pois a base utilizada pode não possuir um conjunto inicial confiável de treinamento.

## 3. Abordagem proposta

Muitos dos trabalhos apresentados na seção anterior já evidenciaram os benefícios da extração de informações a partir de texto. A escolha do método de extração adequado depende de diversos fatores como, por exemplo, o estilo e a estrutura do texto, o número de relações que se deseja extrair, a existência ou não de anotações no texto, se a informação se refere a um domínio específico ou é independente de domínio, entre outros.

Neste trabalho, os tipos de textos trabalhados se referem a um domínio específico (agrotóxicos). As características (estilo) encontradas nos textos foram: (i) tratavam-se de

textos técnicos; (ii) os textos apresentavam seções padronizadas, bem delimitadas, e com separação por tópicos/assuntos bem definidos; (iii) as sentenças não apresentavam com frequência uma estrutura do tipo sujeito/verbo/objeto, não tendo assim relações interessantes que pudessem ser extraídas; (iv) não possuíam anotações nem bases de conhecimento associadas. O processo geral de nossa abordagem pode ser ilustrado pela Figura 1.



**Figura 1. Abordagem geral de extração**

O processo inicia com a conversão de qualquer formato de texto para o formato de texto simples (arquivos txt), visando facilitar o tratamento posterior. Em seguida, é feita uma avaliação da natureza do texto, verificando-se a ocorrência ou não de alguma estrutura ou padrão na representação de seu conteúdo. Esta avaliação permite que seja feita uma modelagem das informações contidas no texto, cujo objetivo é identificar o que há de interesse a ser extraído.

Em seguida, um conjunto de expressões regulares (ou outro método que se mostre mais adequado para a tarefa de extração) é definido e aplicado aos textos de interesse. Cabe notar que, em textos que são semi-estruturados, como por exemplo onde há a ocorrência de um padrão do tipo chave-valor, as expressões regulares podem ser definidas facilmente, apenas alterando-se o valor de interesse no padrão básico. As expressões regulares permitem que as informações extraídas já estejam no formato de triplas, ou quando isso não for diretamente possível, permitem selecionar as sentenças consideradas relevantes e que devem ser consideradas para passar por um processo de extração de informação.

Neste último caso, o conjunto de sentenças obtidas pelas expressões regulares necessita sofrer uma limpeza, com o objetivo de remover frases com sentido negativo e algumas stopwords. A partir deste conjunto de sentenças, é necessário combinar outras técnicas de extração de informação para a geração de triplas. Neste caso é gerada uma matriz TF-IDF que relaciona termos com documentos e indica a importância de um termo de um documento em relação a um conjunto de documentos. A matriz TF-IDF gerada é usada para gerar um conjunto de triplas, que relaciona um termo com os documentos nos quais tal termo é mais relevante.

Por fim, é feita a atribuição automática de URIs aos termos das triplas geradas, permitindo que os mesmos possam ser relacionados a outras bases e vocabulários existentes. Na próxima seção, mostraremos como esta abordagem foi aplicada em nosso

domínio específico, e apresentaremos então os experimentos e resultados obtidos.

#### 4. Experimentos e Resultados

O domínio de agrotóxicos foi escolhido para aplicar a abordagem proposta na seção anterior. O objetivo é enriquecer semanticamente o portal do Observatório de Atenção Permanente ao Uso de Agrotóxicos, que reúne diversas fontes de dados disponibilizadas por diferentes instituições. O portal possui a vantagem de centralizar em um único ambiente virtual, de fácil usabilidade, as informações sobre agrotóxicos e seu consumo no Brasil.

Para alcançar este objetivo, estudamos os conjuntos de dados, tipos de documentos e material disponibilizados na *web* relacionados ao uso de agrotóxico no Brasil. Duas fontes de dados não estruturados chamaram atenção quanto à riqueza do seu conteúdo: bulas encontradas no portal de agrotóxicos do Paraná<sup>3</sup> e monografias disponibilizadas no portal da ANVISA<sup>4</sup> sobre este tema. Para cada uma dessas fontes descreve-se a seguir a aplicação da abordagem tal qual apresentada na seção 3.

##### 4.1. Aplicação da abordagem nas monografias

As monografias foram convertidas de textos em PDF para TXT e a conversão foi feita utilizando a biblioteca em Python chamada PyPDF2<sup>5</sup>. Apesar das monografias estarem em formato textual, possuíam estilo semelhante e eram semi-estruturadas quanto ao seu conteúdo. Além disso, a parte essencial de informação de cada monografia era representada por uma estrutura "chave:valor", onde a chave era representada por propriedades referentes ao agrotóxico e o valor referente ao valor da propriedade.

As monografias continham as seguintes informações referentes ao agrotóxico: Ingrediente ativo ou nome comum; Sinonímia; Número CAS, que é o registro único de uma substância no banco de dados Chemical Abstract Service - CAS<sup>6</sup>; Nome Químico; Fórmula Bruta e Estrutural; Grupo Químico; Classe; Classificação Toxicológica; Uso Agrícola, que contém informações da modalidade de emprego daquele agrotóxico em diferentes culturas; e Ingestão Diária Aceitável.

A partir dessa avaliação da natureza dos textos, a modelagem das monografias foi realizada e é mostrada na Figura 2. Exemplos de leitura desta modelagem pode ser feita da seguinte maneira, um agrotóxico pode possuir 1 ou mais classes, e uma classe possuir 1 ou mais agrotóxicos, assim como um agrotóxico só pode possuir um Número CAS e um número CAS só pode estar associado a 1 agrotóxico.

Como as informações eram disponibilizadas da mesma forma e o domínio a ser aplicado era específico, então o uso de expressões regulares para extrair informações foi utilizado. Expressões regulares foram desenvolvidas para extrair e triplificar as informações modeladas, onde o *sujeito* era sempre o valor da propriedade *ingrediente ativo* e os *predicados* e *objetos* eram as *chaves* e *valores*, respectivamente. Em seguida, as expressões regulares foram aplicadas nas monografias e o resultado obtido foi um conjunto de triplas. Todas as triplas de cada monografia foram inseridas em um único arquivo

<sup>3</sup><http://celepar07web.pr.gov.br/agrotoxicos/bulas.asp>

<sup>4</sup><http://portal.anvisa.gov.br/registros-e-autorizacoes/agrotoxicos/produtos/monografia-de-agrotoxicos/>

<sup>5</sup><https://pypi.python.org/pypi/PyPDF2>

<sup>6</sup><https://www.cas.org/>



## 4.2. Aplicação da abordagem nas bulas

As bulas também foram convertidas de PDF para TXT utilizando a mesma biblioteca citada acima. Apesar das bulas estarem em formato textual, possuíam um padrão na disponibilização de seu conteúdo, com seções bem definidas e delimitadas.

Uma bula contém as seguintes informações referentes a um agrotóxico: Classe; Composição; Tipo de Formulação; Classificação Toxicológica; Classificação do Potencial de Periculosidade; Primeiros Socorros; Número, Época e Intervalo de Aplicação; Dados Relativos à Proteção da Saúde Humana; Dados Relativos ao Meio Ambiente; Fabricante do Produto; Titular de Registro; Instrução de Uso (normalmente em tabela); Modo de Aplicação (Terrestre e Aérea); Procedimentos de Lavagem, Armazenamento, Transporte e Destinação de Embalagens Vazias e Restos de Produtos Impróprios para Utilização ou em Desuso.

A partir da avaliação da natureza do texto da bula, foi realizada uma modelagem. Nesta, foram desconsideradas informações que não tinham relação com o domínio do uso do agrotóxico e riscos a saúde. O resultado da modelagem das bulas é mostrado na Figura 4. Note que as duas fontes de dados (monografia e bula) puderam ser relacionadas através das informações relativas a Classe, Composição e Grupo Químico. Exemplos de interpretação desta modelagem pode ser feita da seguinte maneira: uma bula pode ou não ter efeitos colaterais, mas um efeito colateral pode estar associado a uma ou mais bulas, assim como uma bula possui apenas uma composição e uma composição só pode estar associada a uma bula.

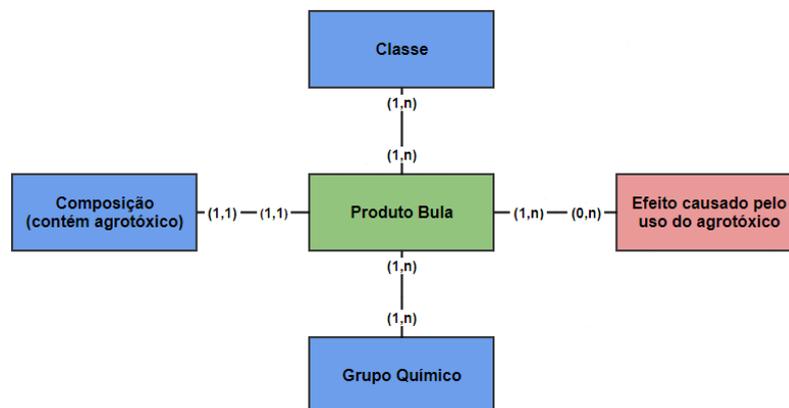


Figura 4. Modelagem de informações das bulas

Por conta da disposição das informações quase sempre ocorrer da mesma forma, expressões regulares foram desenvolvidas e aplicadas para selecionar apenas as seções modeladas como de interesse, pois a utilização apenas de expressões regulares não se mostrou suficiente para uma extração de qualidade. Por exemplo, determinar quais agrotóxicos (bulas) poderiam causar determinado efeito colateral. Isso ocorria porque parte da informação que estava descrita nas bulas era de texto não estruturado. Para extrair este tipo de informação, era interessante combinar outra técnica de extração de informação, como por exemplo uma matriz TF-IDF, onde o conjunto de termos de todas as bulas eram relacionados às bulas.

Antes de combinar esta técnica, para melhorar ainda mais o processo de extração

foi realizado um processamento para limpeza e preparação do texto. Como em alguns textos existiam frases com sentido negativo, ao se trabalhar com termos e não com a análise da frase completa, poderiam ocorrer casos de falsos positivos. Por exemplo: em uma bula com a frase "não há evidências de câncer", ao realizar a verificação dos termos, essa bula seria retornada para o termo "câncer", quando, na verdade, não deveria ser retornada. Desta forma, foram retiradas frases com sentido negativo. Um outro ponto tratado foi unificar termos em expressões com sentido próprio, como por exemplo "aumento de pressão", além de remover stopwords.

Com os textos processados, o próximo passo foi gerar uma matriz TF-IDF, cujo objetivo era extrair a relação de termos e documentos, onde o conjunto de termos de todas as bulas eram relacionados às bulas. Assim, identificando um sintoma dentro da lista de termos (por exemplo, vômito), foi possível relacionar este sintoma a todos os agrotóxicos (através de sua respectiva bula) que o causam. Com isso, um conjunto de triplas da forma (agrotóxico, provoca, sintoma) pode ser extraída.

Por último, foi realizada a atribuição automática de URIs para os termos da matriz TF-IDF. Por faltarem vocabulários e datasets em português sobre doenças e efeitos na saúde, os termos da matriz foram traduzidos para inglês e a partir dos termos em inglês foi realizada uma busca automática dos termos no dataset do BioPortal [Noy et al. 2009]. Caso o termo fosse encontrado, então a relação de igualdade era mapeada, e, em caso contrário, vocabulários próprios eram definidos.

Foram utilizadas 1234 bulas, separadas pelas categorias: *fungicida*, *herbicida*, *inseticida* e outros. O processo da bula foi executado nas quatro categorias. A Tabela 1 apresenta os resultados do processo.

**Tabela 1. Resultados das bulas**

Categoria	Documentos	Termos	Termos encontrados	Triplas
Inseticida	436	4186	369	2309
Herbicida	426	3539	261	1656
Fungicida	298	3093	235	1197
Outros	74	1173	61	140

Na categoria de inseticida, 436 documentos foram processados e 4186 termos foram gerados. O BioPortal foi utilizado por disponibilizar diversos vocabulários. Como nosso objetivo era apenas obter termos relacionados a sintomas e efeitos, restringimos a busca (via API) utilizando apenas a ontologia MEDDRA <sup>7</sup>. Além disso, utilizamos um POS Tagger do pacote NLTK <sup>8</sup> de modo a restringir nossa busca a termos que fossem substantivos. Após fazer as restrições, 369 termos foram encontrados e anotados, gerando 2309 triplas que associavam os sintomas às bulas. O mesmo processo foi realizado nas outras três categorias (ver Tabela 1).

Alguns exemplos de triplas geradas estão representadas no grafo da Figura 5.

<sup>7</sup><https://bioportal.bioontology.org/ontologies/MEDDRA>

<sup>8</sup><https://www.nltk.org/>

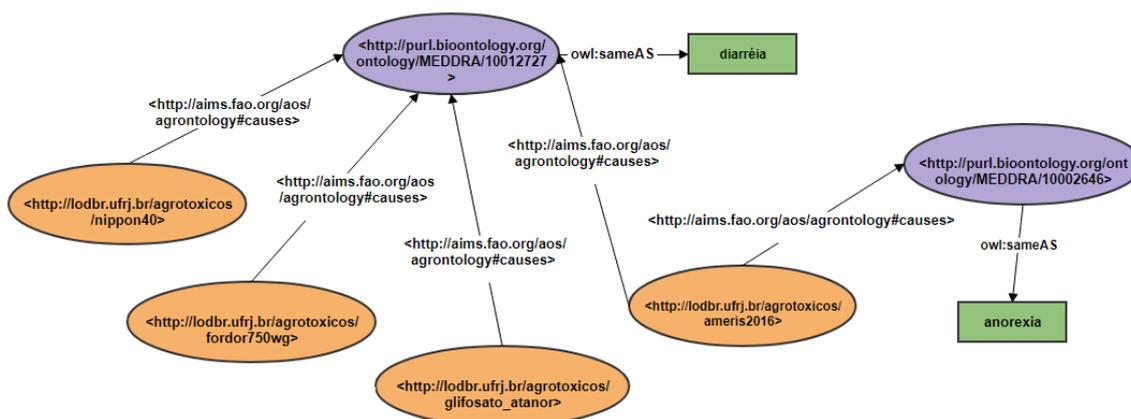


Figura 5. Exemplo de triplas geradas das bulas

### 4.3. Incorporação das triplas no portal

As triplas extraídas dos documentos estão sendo inseridas no portal do Observatório, para gerar o enriquecimento do mesmo e de outras bases que o mesmo referencia. No portal, outros dados estruturados, como CSV e XLSX, estão sendo triplificados, como por exemplo, um dataset que relaciona o agrotóxico e países onde o mesmo está proibido. Esses dados triplificados podem ser associados às triplas extraídas das monografias e bulas sendo, conseqüentemente, enriquecidos.

Além das informações dos sintomas extraídas das bulas, termos referentes à composição química, grupo químico e classe estão sendo associados com outros vocabulários e ontologias do BioPortal. Ao realizar esta associação o enriquecimento entre fontes de dados, monografias e bulas, também ocorrerá. Assim, por exemplo, a bula associada ao *glifosato atanor*, apresentada na Figura 5, possui em sua composição o glifosato. Este é o ingrediente ativo de um agrotóxico descrito em uma monografia, representado pela Figura 3, sendo possível verificar que o produto glifosato usado como dessecante nas culturas de aveia preta, azevém e soja pode ter como sintoma a diarréia.

## 5. Conclusão

Este trabalho apresentou uma abordagem para extração de dados e geração de triplas a partir de textos com características específicas. Com a ligação e associação das triplas com bases existentes e vocabulários externos, o portal do Observatório, que já vem tendo boa parte de seus datasets triplificados, passa a ter esses dados enriquecidos.

Apesar da abordagem ter sido experimentada em domínio específico, a ideia geral da mesma pode ser aplicada em outros domínios que possuam estrutura/estilo de texto semelhante. A vantagem de usar essa abordagem é que a extração ocorre da forma desejada, não necessita de um corpus anotado, nem de bases de conhecimentos. A desvantagem é que para qualquer nova regra, a mesma deve ser adicionada na etapa de desenvolvimento das expressões regulares.

Este trabalho também abre novas possibilidades de trabalhos futuros, como por exemplo o enriquecimento de descritores de dados, e não só dados. Em diversos portais são utilizados conjuntos de tags para classificar e agrupar diferentes datasets que possuem algum conceito em comum. O problema é que as tags normalmente são atribuídas

por gestores de datasets de forma livre, estando sujeitas à ambiguidade e subjetividade. Técnicas já foram desenvolvidas para limpar, conciliar e enriquecer tags de portais de dados abertos de governo, como por exemplo em [Tygel et al. 2016], porém uma forma que parece interessante é tentar enriquecer semanticamente tags a partir dos dados e de extrações de fontes diversas.

## Referências

- Agichtein, E. and Gravano, L. (2000). Snowball: Extracting Relations from Large Plain-Text Collections. In *Proc. of the Fifth ACM Conf. on Digital Libraries, DL '00*, pages 85–94, New York, NY, USA. ACM.
- Augenstein, I., Padó, S., and Rudolph, S. (2012). LODifier: Generating Linked Data from Unstructured Text. In *Proc. of the 9th Inter. Conf. on The Semantic Web: Research and Applications, ESWC'12*, pages 210–224, Berlin, Heidelberg. Springer-Verlag.
- Brin, S. (1999). Extracting Patterns and Relations from the World Wide Web. In *Selected Papers from the Int. Workshop on The World Wide Web and Databases, WebDB '98*, pages 172–183, London, UK, UK. Springer-Verlag.
- Byrne, K. and Klein, E. (2010). Automatic Extraction of Archaeological Events from Text. In *Proc. of the 37th Int. Conf. Computer App. and Quantitative Methods in Archaeology*, pages 48–56, Williamsburg, Virginia, USA.
- Caracciolo, C., Stellato, A., Morshed, A., Johannsen, G., Rajbhandari, S., Jaques, Y., and Keizer, J. (2013). The AGROVOC Linked Dataset. volume 4, pages 341–348, Amsterdam, The Netherlands, The Netherlands. IOS Press.
- Carvalho, D. S., Freitas, A., and da Silva, J. C. P. (2013). Graphia: Extracting Contextual Relation Graphs from Text. In *The Semantic Web: ESWC 2013 Satellite Events - ESWC 2013 Satellite Events, Montpellier, France, May 26-30, 2013, Revised Selected Papers*, pages 236–241. Springer.
- de Abreu, S. C., Bonamigo, T. L., and Vieira, R. (2013). A review on Relation Extraction with an eye on Portuguese. *Journal of the Brazilian Computer Society*, 19(4):553–571.
- de Souza, E. N. P. and Claro, D. B. (2014). Extração de Relações utilizando Features Diferenciadas para Português. *Linguamática*, 6:57–65.
- Del Corro, L. and Gemulla, R. (2013). ClausIE: Clause-Based Open Information Extraction. In *Pro. of the 22nd Int. Conf. on World Wide Web, WWW '13*, pages 355–366, New York, NY, USA. ACM.
- Etzioni, O., Banko, M., Soderland, S., and Weld, D. S. (2008). Open Information Extraction from the Web. *Commun. ACM*, 51(12):68–74.
- Etzioni, O., Cafarella, M., Downey, D., Popescu, A.-M., Shaked, T., Soderland, S., Weld, D. S., and Yates, A. (2005). Unsupervised Named-Entity Extraction from the Web: An Experimental Study. *Artif. Intell.*, 165(1):91–134.
- Fader, A., Soderland, S., and Etzioni, O. (2011). Identifying Relations for Open Information Extraction. In *Proc. of the Conf. on Empirical Methods in Natural Language Processing, EMNLP '11*, pages 1535–1545, Stroudsburg, PA, USA. Ass. for Comp. Linguistics.

- Gamallo, P., Garcia, M., and Fernández-Lanza, S. (2012). Dependency-Based Open Information Extraction. In *Proc. of the Joint Workshop on Unsupervised and Semi-Supervised Learning in NLP, ROBUS-UNSUP '12*, pages 10–18. Ass. for Comp. Linguistics.
- Grishman, R., Sterling, J., and Macleod, C. (1991). Description of the Proteus System as used for MUC-3. In *Proc. of the Third Message Understanding Conference, San Diego, CA, May 1991*, pages 183–190. Morgan Kaufmann.
- Joshi, A., Lal, R., Finin, T., and Joshi, A. (2013). Extracting Cybersecurity Related Linked Data from Text. In *Proc. of the 7th IEEE Int. Conf. on Semantic Computing*, pages 252–259. IEEE Computer Society Press.
- Lange, D., Böhm, C., and Naumann, F. (2010). Extracting Structured Information from Wikipedia Articles to Populate Infoboxes. In *Proc. of the 19th ACM Int. Conf. on Inf. and Knowledge Management, CIKM '10*, pages 1661–1664, New York, USA. ACM.
- Lehmann, J., Isele, R., Jakob, M., Jentzsch, A., Kontokostas, D., Mendes, P. N., Hellmann, S., Morsey, M., van Kleef, P., Auer, S., and Bizer, C. (2015). DBpedia - A Large-scale, Multilingual Knowledge Base Extracted from Wikipedia. *Semantic Web Journal*, 6(2):167–195.
- Lehnert, W., Williams, R., Cardie, C., Riloff, E., and Fisher, D. (1991). The CIRCUS System as Used in MUC-3. Technical report, Amherst, MA, USA.
- Nadkarni, P. M., Ohno-Machado, L., and Chapman, W. W. (2011). Natural language processing: an introduction. *Journal of the American Med. Inf. Ass.*, 18(5):544–551.
- Noy, N. F., Shah, N. H., Whetzel, P. L., Dai, B., Dorf, M., Griffith, N., Jonquet, C., Rubin, D. L., Storey, M.-A. D., Chute, C. G., and Musen, M. A. (2009). BioPortal: ontologies and integrated data resources at the click of a mouse. *Nucleic Acids Research*, 37(Web-Server-Issue):170–173.
- Pantel, P. and Pennacchiotti, M. (2006). Espresso: Leveraging Generic Patterns for Automatically Harvesting Semantic Relations. *ACL-44*, pages 113–120, Stroudsburg, PA, USA. Ass. for Comp. Linguistics.
- Tygel, A., Auer, S., Debattista, J., Orlandi, F., and Campos, M. L. M. (2016). Towards Cleaning-Up Open Data Portals: A Metadata Reconciliation Approach. In *Tenth IEEE Int. Conf. on Semantic Comp., ICSC 2016, Laguna Hills, CA, USA, 2016*, pages 71–78.
- Yates, A., Cafarella, M., Banko, M., Etzioni, O., Broadhead, M., and Soderland, S. (2007). Textrunner: Open information extraction on the web. In *Proc. of Human Language Technologies: The Annual Conf. of the North American Chapter of the Association for Computational Linguistics: Demonstrations, NAACL-Demonstrations '07*, pages 25–26, Stroudsburg, PA, USA. Ass. for Comp. Linguistics.

# Sustentabilidade de Foto-memórias na Era Digital: Desafios e Oportunidades para a Computação

Paulo L. S. Brizolara<sup>1</sup>, Leonardo Cunha de Miranda<sup>1</sup>

<sup>1</sup>Departamento de Informática e Matemática Aplicada  
Universidade Federal do Rio Grande do Norte (UFRN)  
59078-970 – Natal, RN – Brasil

pbrz@protonmail.com, leonardo@dimap.ufrn.br

**Resumo.** *A cultura tem sido, recentemente, reconhecida como um novo pilar para alcançar a sustentabilidade. A construção da cultura se dá através das gerações, como uma herança. Registros de memórias autobiográficas, como fotografias, são elementos importantes para transmitir essa herança. Preservá-los, no entanto, pode apresentar uma gama de desafios. Neste trabalho abordamos a questão do uso de fotografias como registros de memórias (foto-memórias), no contexto da sustentabilidade cultural. Apresentamos um conjunto de desafios relacionados ao tema, identificados a partir de uma revisão da literatura, e, associado a eles, descrevemos oportunidades de pesquisa para diferentes áreas da Computação.*

**Abstract.** *The culture has been, recently, recognized as a new pillar to achieve sustainability. Culture is built through generations, as an heritage. Autobiographical memories records, such as photographs, are important elements to pass down this heritage. Preserving these records, however, can present a range of challenges. In this work we address the issue of the use of photographs as records of memories (photo-memories), in the context of cultural sustainability. We present a set of challenges related to the theme, identified from a literature review, and, associated to them, we describe research opportunities for different areas of Computing.*

## 1. Introdução

A construção de uma sociedade sustentável envolve uma gama variada de aspectos. Embora alguns defendam uma visão de sustentabilidade associada, estritamente, a questão ecológica [Pargman e Raghavan 2014], uma visão comumente aceita é a de que para alcançar a sustentabilidade é preciso equalizar diferentes aspectos, os chamados pilares da sustentabilidade: ambiental, econômico e social. Um outro aspecto que tem sido visto com igual importância, como um quarto pilar da sustentabilidade, é a questão cultural [Loach et al. 2016].

A sustentabilidade cultural, e mesmo a cultura, são vistas sob diferentes perspectivas na literatura. Uma dessas perspectivas [Soini e Birkeland 2014] enxerga que a cultura é formada por bens imateriais e materiais (capital cultural) que evoluem e são passados entre gerações (herança cultural). A sustentabilidade cultural sobre essa perspectiva está, portanto, relacionada com a preservação dessa herança. Esta é composta não apenas por aquilo que é reconhecido e valorizado pela humanidade (e.g., monumentos e locais históricos), mas é construída a partir dos indivíduos (e.g., suas memórias e propriedades), para sua comunidade, região e, por fim, todo o globo

[LeBlanc 1993]. Assim, as memórias autobiográficas e os meios através dos quais elas podem ser registradas são, portanto, relevantes para a herança cultural, tanto por elas serem moldadas pela cultura em que se inserem [Wang e Brockemeir 2002], quanto pelo papel na formação de nossa memória cultural e senso de identidade e, assim, potencializar a transmissão da cultura para futuras gerações [Giaccard et al. 2012].

A fotografia pessoal tem sido tradicionalmente percebida como um meio para o registro de memórias autobiográficas, sejam individuais ou coletivas [Sarvas e Frohlich 2011]. Muito embora, junto a ascensão da fotografia digital, tenham ocorrido uma série de transformações nos papéis atribuídos à fotografia pessoal (e.g., o crescimento no uso de fotos para comunicação e representação da própria identidade [Van House 2011]), o registro de memórias através delas continua sendo uma função importante [Van Djick 2008]. No entanto, como observam Whittaker et al. (2010), preservar fotografias a longo prazo, especialmente em formato digital, ainda é uma atividade complexa. Arquivos pessoais de fotos digitais são considerados mais frágeis e mais difíceis de organizar, segundo Van House (2011). Marshall (2008a), por sua vez, observa que a perda ocasional de arquivos pessoais é tida como algo inevitável, e até uma forma de controlar o excesso de arquivos.

Neste trabalho abordamos essa problemática, i.e. a preservação e uso a longo prazo de fotografias digitais para registrar memórias na “era digital”, dentro do contexto da sustentabilidade cultural. Nesse sentido, adotamos como objetivo levantar as barreiras e questões iniciais relacionadas ao tema. Para tanto, realizamos uma revisão de literatura com uma abordagem exploratória, a partir da qual identificamos desafios e oportunidades de pesquisa que precisam ser abordados pela Computação, para que fotografias digitais possam ser preservadas e utilizadas a longo prazo, isto é, por dezenas de anos e, até mesmo, através de gerações.

Este artigo está organizado da seguinte maneira: a Seção II apresenta o conceito de foto-memórias; as Seções III e IV descrevem, respectivamente, os desafios e as oportunidades para a Computação no contexto desse tema; a Seção V discute os resultados deste trabalho; e a Seção VI conclui o artigo.

## 2. Foto-memórias

Fotografias pessoais podem ser utilizadas com diferentes propósitos. Em Van Djick (2008), três principais papéis são descritos: o de meio de comunicação, forma de representar (e construir) a própria identidade, e o de instrumento para recordar memórias autobiográficas. Esses diferentes usos se relacionam, por exemplo, aos significados e ao valor (de curto ou longo prazo) atribuídos às fotografias. Em Kindberg et al. (2005), por exemplo, a maior parte das fotos que os participantes desejavam manter por um longo prazo estavam entre aquelas com funções afetivas, em especial funções ligadas à memória (e.g., reflexão e recordação). Também em Ceroni et al. (2015), a capacidade de evocar memórias é tida como principal critério para preservar fotos, além de outros similares, como a possibilidade de representar um evento ou a presença de alguém (ou algo) importante na foto.

Para designar essas fotografias (pessoais) utilizadas para registrar e recordar memórias a longo prazo, nós adotamos o termo “foto-memórias”. Vale salientar, entretanto, que memórias não podem ser “armazenadas”. Invés disso, essas fotografias atuam como “gatilhos” (*memory cues*) [Broekhuijsen et al. 2017b], i.e. elas podem

auxiliar a relembrar de certas memórias, mas isso depende das associações construídas pelo observador. Apesar disso, utilizamos a noção de “registros de memórias”, para nos referir, de forma mais simples, aos artefatos criados ou utilizados com a intenção de recordar determinadas memórias.

O conceito de foto-memórias facilita a distinção entre essas fotos e outras utilizadas com propósitos distintos, em especial, aquelas com caráter efêmero, i.e. que tem valor apenas a curto prazo, como as fotos com fins utilitários, observadas por Kindberg et al. (2005). As formas de utilizar uma determinada fotografia, no entanto, não são imutáveis, nem mutuamente excludentes. Com o tempo, por exemplo, o valor dado a uma fotografia (ou memória) pode se modificar [Mols et al. 2014]. Por sua vez, fotos podem também assumir, em maior ou menor grau, diferentes papéis. Assim, além de representar nossas memórias e nos auxiliar a lembrá-las [Broekhuijsen et al. 2017b], foto-memórias podem também servir de base para compartilhar histórias e experiências [Van House 2009], bem como construir percepções de identidade ou de pertencimento a uma família [Van House 2011] ou outro grupo social. Preservar as foto-memórias pode ser, por isso, também uma forma de construir nossa herança cultural [Giaccardi et al. 2012], por exemplo, ao observar os recortes que fazemos do mundo hoje, gerações futuras podem compreender e se apropriar do seu passado.

Entretanto, arquivos de fotografias digitais são hoje voláteis e tendem a sair do controle, em termos de tamanho e organização, como observa Van House (2011). Isto é, o modo com que utilizamos e gerenciamos foto-memórias digitais torna improvável mantê-las a longo prazo. Isto é, o uso de foto-memórias digitais não é sustentável. Para garantir essa sustentabilidade de foto-memórias por longos períodos de tempo, diferentes áreas da Computação precisam lidar com uma gama variada de desafios.

### **3. Desafios**

Os desafios descritos a seguir representam barreiras que precisam ser abordadas por pesquisadores (e desenvolvedores) de Computação, de modo a construir soluções para que foto-memórias possam ser preservadas e utilizadas a longo prazo. Os desafios estão agrupados de acordo com as “necessidades”, identificadas a partir da literatura, que os motivam, i.e. aquilo que leva os indivíduos a utilizarem as foto-memórias.

#### **3.1. Necessidade #1 - Registrar memórias**

Pessoas capturam foto-memórias como forma de persistir para o futuro a representação de uma memória, pessoa ou objeto querido [Kindberg et al. 2005; Goh et al. 2009], i.e. um memento. Mais do que aquilo que é comunicado diretamente através das imagens, foto-memórias evocam consigo um conjunto de histórias e significados que podem não ser compreensíveis sem uma conexão pessoal com o que é retratado na foto e o seu contexto [Sarvas e Frolich 2011]. Segundo Olsson et al. (2008), as fotografias, sem as histórias relacionadas a elas, não constituem “memórias”, mas apenas documentos históricos. Portanto, registrar memórias através de fotografias, demanda também formas de representar e capturar as histórias e informações de contexto relacionadas a ela.

##### **3.1.1. Desafio #1.1 - Registrar e representar fotografias e memórias**

A representação das memórias associadas a fotografias pode ser feita, por exemplo, através de narrativas orais (*storytelling*), quando presencialmente [Van House 2009] ou de anotações em fotografias impressas [Van House 2011]. No formato digital, existem

maiores possibilidades, mas também faltam padrões para representar memórias, em termos de armazenamento e de visualizações. Além disso, registrar memórias para grandes coleções de fotos, e.g. através de *tags* e anotações, pode demandar esforço. Soluções precisam considerar quais informações irão utilizar para representar memórias e buscar reduzir o esforço para registrá-las.

### **3.1.2. Desafio #1.2 - Capturar memórias não antecipadas**

Registrar um determinado momento, durante seu acontecimento, pressupõe uma percepção de que ele “vale ser registrado”. No entanto, a percepção do valor de um momento ou memória pode mudar com o tempo [Olsson et al. 2008]. Assim, há uma dificuldade em registrar experiências que passamos a valorizar posteriormente (memórias não antecipadas) [Mols et al. 2014], como as experiências do cotidiano.

Soluções computacionais podem ajudar a tratar essa dificuldade. Por exemplo, através da criação de novos métodos de captura, ou auxiliar a reutilizar fotografias para atribuir novos significados, e.g. enfatizar aspectos retratados no plano de fundo ou relacionados ao contexto da foto, ou ainda ajudar usuários a identificar momentos relevantes a capturar, e.g. destacando contrastes com o passado [Mols et al. 2014].

## **3.2. Necessidade #2 - Preservar memórias a longo prazo**

Fotografias podem auxiliar a preservar para o futuro lembranças consideradas valiosas. Em Kindberg et al. (2005), participantes desejam manter algumas dessas fotos por longo prazo, em especial aquelas relacionadas a funções afetivas e à memória. É o significado dos eventos e pessoas nessas fotos, segundo Vyas et al. (2013), que as tornam “importantes o suficiente” para serem preservadas a longo prazo. Há também o desejo de passar essas fotos para futuras gerações, expresso por idosos [Olsson et al. 2008], pais com crianças pequenas [Whittaker et al. 2010] e mesmo entre jovens [Wolters et al. 2015]. Entretanto, preservar fotos em formato digital a longo prazo apresenta novas dificuldades para usuários e desafios para a Computação.

### **3.2.1. Desafio #2.1 - Armazenamento disperso de foto-memórias**

Coleções pessoais de fotos, e de outros “pertences digitais”, são frequentemente armazenadas através de uma gama de dispositivos, mídias de armazenamento e serviços online [Marshall et al. 2006] desconexos. Essa dispersão de dados dificulta o gerenciamento e localização de fotos [Whittaker et al. 2010], e cria duplicações e inconsistências dentro das coleções. Aliado a isso, a dificuldade de controlar e observar esses dados pode levar à perda de arquivos ou do acesso a eles [Marshall 2008a].

Tratar esse armazenamento disperso de dados envolve integrar bases de dados independentes, que podem não estar acessíveis continuamente. Invés de uma base centralizada, entretanto, Marshall (2008b) sugere criar “catálogos” que permitam uma visão unificada sobre os dados que são armazenadas de forma descentralizada.

### **3.2.2. Desafio #2.2 - Preservar foto-memórias seletivamente**

Não são todas as fotografias que desejamos preservar para o futuro. Entretanto, como observam Drazin e Frohlich (2007), até fotos (impressas) que não tem um valor ou função definidos não costumam ser descartadas. Mesmo fotos indesejadas deixam de ser removidas, por motivos como a “falta de tempo” [Kindberg et al. 2005]. Com pertences digitais essa problemática se agrava devido a taxa com que são acumulados [Marshall et al. 2006]. Mais do que o espaço de armazenamento, esse acúmulo demanda maior

atenção e esforço humanos [Marshall et al. 2006], e dificulta a localização e organização de fotos [Whittaker et al. 2010].

Para tratar esse problema, Niederée et al. (2015) propõem uma abordagem de “esquecimento gerenciado”, i.e. decidir de forma consciente o que deve ser excluído ou preservado, invés de “causas aleatórias”, como falhas em disco ou obsolescência tecnológica. Para tornar isso viável, soluções precisam auxiliar usuários a preservar o que é importante e eliminar o que é desnecessário.

### **3.2.3. Desafio #2.3 - Inferência (semi)automática do valor de foto-memórias**

Determinar o valor dado a cada fotografia é importante para identificar quais devem ou não ser preservadas (Desafio #2.2), e pode auxiliar na organização e localização delas [Whittaker et al. 2010]. Entretanto, avaliar grandes coleções de arquivos demanda esforço, e por isso exigiria o auxílio de soluções automatizadas [Marshall 2008b].

Para tanto, Niederée et al. (2015) propõem a avaliação de informações armazenadas para determinar o seu valor a curto e a longo prazo, considerando fatores como origem, tipo da informação e uso que se faz dela. No entanto, como observa Ceroni et al. (2015), os critérios utilizados por pessoas para determinar o valor de uma fotografia tendem a ser subjetivos, o que dificulta uma avaliação automatizada. Usuários devem ter, portanto, a decisão final e a possibilidade de expressar explicitamente o que desejam preservar ou excluir [Marshall 2008b].

### **3.2.4. Desafio #2.4 - Bases de foto-memórias evolutivas**

Preservar foto-memórias demanda também considerar as mudanças de tecnologias e requisitos que podem ocorrer a longo prazo. Isto é, em escalas longas de tempo (e.g., décadas), a definição de quais dados devem ser preservados, bem como os formatos e aplicações utilizadas para isso podem mudar [Niederée et al. 2015]. Contudo, os dados criados ou armazenados, e o esforço associado com isso, não devem ser perdidos.

Para lidar com essa questão, aplicações devem ser projetadas para a mudança, e mesmo os modelos de desenvolvimento adotados devem permitir que elas continuem evoluindo. Por sua vez, ações precisam ser conduzidas ao longo do tempo para garantir que informações armazenadas continuem válidas, e.g. verificar a integridade de dados, e mover o conteúdo para novas mídias e formatos [Marshall 2008b].

### **3.2.5. Desafio #2.5 - Organização de coleções de foto-memórias**

A organização de coleções de fotos é um aspecto importante para permitir a localização, e, portanto, o uso, de fotografias a longo prazo [Whittaker et al. 2010]. Sequência e posicionamento, por exemplo, são utilizados em álbuns de fotos impressas para restringir (e associar) significados [Van House 2011]. Entretanto, organizar fotos consome tempo e é, frequentemente, negligenciado [Whittaker et al. 2010].

Automação de tarefas pode auxiliar a reduzir o esforço humano na manutenção de foto-memórias, e de outros objetos digitais, mas o papel dos usuários é central em determinar o que é importante preservar [Marshall 2008b], bem como em associar significados às fotografias e coleções. Broekhuijsen et al. (2017b) observam ainda que usuários podem não aceitar bem a automação (total) da curadoria de fotos, pois eles querem se manter no controle. Os autores sugerem que a curadoria pode ser auxiliada por soluções semi-automáticas, e propõem que atividades manuais de curadoria sejam integradas a outras consideradas mais agradáveis, como a navegação através das fotos.

### 3.3. Necessidade #3 - Relembrar memórias

Relembrar memórias, individuais ou coletivas, é um dos motivos importantes para registrar e compartilhar fotografias [Kindberg et al. 2005; Goh et al. 2009; Olsson et al. 2008], e pode ser considerado o propósito de capturar e preservar foto-memórias. Mols et al. (2014) apontam que tanto os fatos (objetivos) quanto a “experiência” (percepção subjetiva) desejam ser lembrados, e Vyas et al. (2013) descrevem o uso das fotografias de eventos como memórias de celebrações e conquistas importantes. Entretanto, utilizar fotografias para lembrar requer ter acesso às fotos desejadas, o que pode ser difícil em coleções antigas e de grande porte.

#### 3.3.1. Desafio #3.1 - Localizar foto-memórias de longo prazo

Buscas por fotos (digitais) se diferenciam da simples navegação ou visualização das coleções, pois são orientadas por um objetivo [Broekhuijsen et al. 2017b]. Essas buscas podem ser por algo vago, i.e. “bom o suficiente” [Frohlich et al. 2013], ou mais específico, como uma foto particular, fotos de um evento ou com outra propriedade comum (e.g., uma pessoa) [Rodden e Wood 2003]. Conduzir essas buscas, entretanto, é geralmente uma tarefa cansativa, segundo Broekhuijsen et al. (2017b), que pode ser dificultada por fatores como o excesso de fotos, dispersão dos arquivos (Desafio #2.1) e falta de organização [Whittaker et al. 2010].

Facilitar a localização de fotos passa por prover formas de navegação ou de consulta mais eficientes. Isso depende da organização das fotos (Desafio #2.5), mas também da forma com que são apresentadas e dos dados associados a elas (Desafio #1.1). Outras soluções podem envolver a análise do conteúdo da imagem para extrair informações para buscas, como pessoas ou ambiente da foto (e.g., [Gu et al. 2013]).

#### 3.3.2. Desafio #3.2 - Redescobrir foto-memórias esquecidas

Localizar fotos requer ao menos “fragmentos de memórias” que permitam conduzir uma busca. Entretanto, com o tempo, é possível esquecer até da existência de certos arquivos ou de coleções inteiras [Marshall 2008a]. Contraditoriamente, a redescoberta de fotos esquecidas pode ser uma experiência prazerosa [Frohlich et al. 2013]. Com objetos físicos, a forma com que são armazenados torna provável um reencontro futuro, segundo Marshall (2008a). Esses encontros “acidentais” seriam, inclusive, uma das razões mais prováveis para explorar arquivos de fotos impressas [Frohlich et al. 2013]. Artefatos digitais, entretanto, podem ser mais facilmente perdidos [Van House 2011], e portanto, soluções precisam ser projetadas para facilitar esse reencontro.

Marshall (2008b) propõe para isso criar mecanismos que facilitem a localização de arquivos “valiosos”, e meios que potencializem reencontrar itens esquecidos ou perdidos. Visualizar ou manipular coleções de fotografias pode, por exemplo, motivar a redescoberta de fotos esquecidas [Frohlich et al. 2013]. Porém, é preciso controlar esses reencontros para que não ocorram em circunstâncias indesejadas [Marshall 2008b].

### 3.4. Necessidade #4 - Compartilhar e construir memórias colaborativamente

A maior parte das memórias são criadas, definidas, armazenadas e lembradas em um contexto social, segundo Olsson et al. (2008). Há, portanto, uma necessidade de utilizar foto-memórias em grupo, i.e. colaborativamente. É comum, por exemplo, que fotos de um evento sejam capturadas coletivamente e distribuídas entre grupos de pessoas relacionadas [Vyas et al. 2013]. Narrativas de memórias a partir de fotografias podem

também ser construídas e compartilhadas em grupo, como descrevem Sarvas e Frohlich (2011). Entretanto, para realizar práticas colaborativas como essas através de fotos digitais podem surgir entraves, que demandam (novas) soluções computacionais.

#### **3.4.1. Desafio #4.1 - Coleções de foto-memórias colaborativas**

A ausência de ferramentas adequadas, dificulta o gerenciamento de foto-memórias coletivas, i.e. que são do interesse de um grupo de pessoas. Broekhuijsen et al. (2017b), por exemplo, observam a dificuldade na divisão de responsabilidades sobre coleções de fotos de interesse comum (e.g., de uma família) ou de dependentes (e.g., crianças). Em eventos, a integração das fotos capturadas por diferentes participantes e o repasse a todos os interessados também demanda esforço [Vyas et al. 2013]. Com suporte adequado, entretanto, o gerenciamento colaborativo de foto-memórias pode permitir não só lidar com estas questões, como dividir, entre um grupo, o esforço para curadoria [Marshall 2008b] e composição (captura e coleta) de coleções de foto-memórias.

Dar suporte a coleções compartilhadas de foto-memórias requer lidar com algumas questões. Fotos de origens diferentes, por exemplo, precisam ser integradas em uma coleção única, o que demanda lidar com possíveis duplicatas [Marshall 2008a], e identificar relações entre as fotos (e.g., fotos de um mesmo evento [Figueirêdo et al. 2012]). Além disso, divergências entre usuários devem ser tratadas, e.g. conflitos sobre a propriedade das fotos (Desafio #5.2), e descrições de memórias discordantes, ou até incompatíveis. Olsson et al. (2008) apontam, quanto a isso, a necessidade de versões alternativas de memórias (e.g., uma pessoal e uma outra coletiva).

#### **3.4.2. Desafio #4.2 - Compartilhamento presencial de foto-memórias**

O compartilhamento de foto-memórias permite tanto comunicar quanto rememorar experiências, seja de forma remota ou presencial. Esta última tem um papel importante como prática social, segundo Van House (2009), e seria até mais pervasiva [Sarvas e Frohlich 2011]. Broekhuijsen et al. (2017a) identifica, entretanto, fatores que dificultam o compartilhamento presencial de fotos digitais, tais como, dificuldades para visualização (e.g., tamanho de tela), falta de organização nas coleções (Desafio #2.5), e dificuldade de ocultar da audiência conteúdos privados.

Abordagens para melhorar o compartilhamento presencial incluem: facilitar acesso ao conteúdo, prover dispositivos adaptados ao propósito, simplificar a visualização, combinação e sequência de conteúdo para auxiliar nas narrativas de memórias [Van House 2009], bem como permitir adaptação das fotos à audiência, além da interação e conteúdo multi-usuário [Broekhuijsen et al. 2017a].

#### **3.5. Necessidade #5 - Controlar o uso e acesso a foto-memórias**

A fotografia pessoal tem se tornado menos privada, segundo Van House (2011). Enquanto o uso de fotos impressas pode ser controlado apenas restringindo o acesso físico a elas, o uso de meios digitais, especialmente sites de compartilhamento, redes sociais e outras ferramentas online, torna esse controle mais difícil [Besmer e Lipford 2010]. Preocupações quanto à privacidade, entretanto, podem variar com indivíduos [Ahern et al. 2007]. Em Miller e Edwards (2007), por exemplo, são observados dois perfis distintos de usuários quanto a práticas de compartilhamento, um compartilha mais fotos pessoais e entre conhecidos, o outro mais fotos artísticas públicas. Olsson et al. (2008) também observam diferentes atitudes de compartilhamento, associadas às motivações para salvar memórias. Essas diferentes necessidades de privacidade, e os

conflitos que podem surgir a partir delas, levantam desafios que precisam ser considerados, para possibilitar o uso (social) de foto-memórias.

### **3.5.1. Desafio #5.1 – Controlar o acesso a foto-memórias**

Usuários desejam controlar quem tem acesso às suas memórias [Olsson et al. 2008]. Isso pode envolver restringir o acesso de grupos ou indivíduos específicos [Besmer e Lipford, 2010]. Nem sempre, entretanto, ferramentas proveem o nível de controle adequado. Van House (2011) relata que usuários do Flickr entrevistados desejavam controles mais detalhados sobre suas fotos. Usuários podem também se ver forçados a abrir mão da privacidade em nome da conveniência de acesso [Ahern et al. 2007].

Balancar essa granularidade dos controle de privacidade e conveniência de acesso, considerando diferentes perfis de usuários, é um desafio. É importante também considerar a complexidade para gerenciar esses controles. Caso contrário, usuários podem adotar estratégias para reduzir a complexidade que prejudiquem a própria privacidade [Ahern et al. 2007]. Miller e Edwards (2007) propõem o uso de ferramentas de compartilhamento direcionadas (similar ao e-mail), pois destinatários são determinados explicitamente, aumentando controle por parte dos usuários.

### **3.5.2. Desafio #5.2 – Controlar o uso da própria imagem**

Outro problema observado na literatura está no controle da própria imagem em fotografias de terceiros. Pessoas se preocupam em ter sua imagem capturada sem o seu conhecimento ou consentimento, e querem ter o direito de negar a captura ou solicitar a remoção de sua imagem [Olsson et al. 2008]. Além disso, há preocupações quanto ao compartilhamento da própria imagem por terceiros para além do seu controle [Besmer e Lipford 2010], e com os danos que podem ser causados por isso, a curto ou longo prazo.

Há, entretanto, uma tensão quanto à propriedade e direitos sobre a fotografia [Besmer e Lipford 2010], i.e. o direito de quem possui uma foto de utilizá-la pode conflitar com o direito a privacidade de quem é retratado. Soluções precisam considerar esse conflito, equilibrando o direito a privacidade, sem restringir a liberdade do outro.

## **4. Oportunidades**

Os desafios levantados representam também oportunidades de pesquisa, i.e. questões e problemas (em aberto), para subáreas diversas da Computação. Algumas dessas áreas estão mais diretamente relacionados a temática, i.e. sustentabilidade de foto-memórias. Estudos relacionados às áreas de Interação Humano-Computador (IHC) e Computação Ubíqua, por exemplo, tem examinado questões quanto ao uso e projeto de soluções para a fotografia digital (e.g., [Kindberg et al. 2005; Olsson et al. 2008; Whittaker et al. 2010]). Outras áreas podem ter uma relação menor com o tema, mas prover fundações para a solução de diferentes desafios. A Engenharia de Software, por exemplo, pode examinar questões relacionadas ao desenvolvimento de soluções e tecnologias de software “duradouras”, como a manutenibilidade e adaptabilidade dessas soluções.

Existem oportunidades relacionadas aos desafios em si, em parte descritas junto a eles. Explicitamos a seguir, entretanto, algumas delas, na forma de tópicos que podem ser tratados por cada subárea. As subáreas foram listadas a partir das comissões especiais da SBC<sup>1</sup>, então podem diferir de outras classificações. Subáreas com as quais

---

1 [www.sbc.org.br/403-comissoes-especiais](http://www.sbc.org.br/403-comissoes-especiais).

não pudemos identificar uma relação foram omitidas. Destacamos ainda que, naturalmente, essa listagem é incompleta, tendo em vista que uma abordagem mais detalhada exigiria *expertises* em todas essas áreas.

**Tabela 1. Oportunidades de pesquisa por subárea da Computação**

Subáreas	Desafios relacionados	Oportunidades
Sistemas Distribuídos	2.1, 4.1 e 4.2	<ul style="list-style-type: none"> <li>Investigar o armazenamento, acesso e indexação de arquivos dispersos através de dispositivos, serviços e mídias independentes</li> <li>Prover a integração entre bases de foto-memórias e dispositivos para uso colaborativo</li> </ul>
Segurança da Informação e de Sistemas Computacionais	2.1, 2.4 e 5.1	<ul style="list-style-type: none"> <li>Prover segurança (e.g., confidencialidade e autenticação) para bases de foto-memórias em dispositivos heterogêneos e ao longo do tempo</li> </ul>
Engenharia de Sistemas Computacionais	3 e 4.2	<ul style="list-style-type: none"> <li>Construção de dispositivos para localizar, visualizar, exibir, e interagir com foto-memórias (individual ou socialmente)</li> </ul>
Engenharia de Software	2.4	<ul style="list-style-type: none"> <li>Investigar o projeto de tecnologias e soluções de software capazes de evoluir a longo prazo</li> </ul>
Linguagens de Programação	2.4	<ul style="list-style-type: none"> <li>Tratar a adaptação de bases de código, a longo prazo, para acompanhar a evolução das linguagens</li> </ul>
Interação Humano-Computador	1.2, 2.5, 3.1, 3.2 e 5.2	<ul style="list-style-type: none"> <li>Simplificar a curadoria e registro de memórias</li> <li>Facilitar a localização e redescoberta de foto-memórias</li> </ul>
Processamento de Imagens	2.2, 2.3 e 3.1	<ul style="list-style-type: none"> <li>Analisar o conteúdo de imagens para permitir “avaliá-las” e localizá-las</li> </ul>
Inteligência Artificial e Inteligência Computacional	2.2, 2.4, 2.5 e 3.1	<ul style="list-style-type: none"> <li>Auxiliar a automação de tarefas, como a avaliação, seleção e organização de foto-memórias</li> </ul>
Processamento de Linguagem Natural	1.1, 2.3 e 3.1	<ul style="list-style-type: none"> <li>Auxiliar na análise de informações relacionadas a fotos (e.g., anotações) para facilitar o registro de memórias, organização e busca de fotos</li> </ul>
Sistemas Colaborativos	4.1 e 4.2	<ul style="list-style-type: none"> <li>Investigar a construção e organização de coleções de foto-memórias colaborativas</li> </ul>
Sistemas Multimídia	1.1	<ul style="list-style-type: none"> <li>Auxiliar na representação de memórias associadas a fotografias através de diferentes mídias</li> </ul>
Sistemas Web	2.1 e 4.1	<ul style="list-style-type: none"> <li>Construção de soluções para uso distribuído de foto-memórias</li> </ul>
Computação Gráfica e Realidade Virtual	3	<ul style="list-style-type: none"> <li>Construção de visualizações para apresentar foto-memórias e permitir interagir com elas</li> </ul>
Sistemas de Informação	1.1, 2.1, 2.4 e 2.5	<ul style="list-style-type: none"> <li>Tratar gerenciamento de memórias, sob a ótica de sistemas de informação</li> </ul>
Bancos de Dados	1.1, 2.1 e 2.4	<ul style="list-style-type: none"> <li>Pesquisar o armazenamento e representação de dados para foto-memórias</li> <li>Lidar com dados distribuídos (e.g., relações e consistência entre eles), considerando sua evolução ao longo do tempo (e.g., formatos e esquemas de dados)</li> </ul>

## 5. Discussão

Os desafios descritos na Seção 3 foram agrupados sob a perspectiva das necessidades (e dificuldades) relativas ao uso de foto-memórias digitais. A partir desses desafios e necessidades, entretanto, emergem outras dimensões relacionadas a sustentabilidade de (foto-)memórias digitais que não se enquadram na organização adotada.

Uma dessas dimensões diz respeito ao meio utilizado para representar memórias. Neste trabalho, o foco foi no uso de fotografias. Entretanto, como observam Petrelli e Whittaker (2010), outras mídias podem ser empregadas com o mesmo propósito, como vídeos, comunicações armazenadas (e.g., e-mails e mensagens de texto), e criações digitais (e.g., *slideshows*, desenhos e histórias). Para cada uma delas, entendemos que também se aplicam as mesmas necessidades identificadas. Isto é, independente da mídia, há ainda as Necessidades #1, #2 e #3 de registrar, preservar e recuperar memórias, e utilizá-las socialmente (Necessidades #4 e #5). Os desafios, por sua vez, embora focados nas fotografias, também se relacionam a problemáticas mais genéricas, como a representação de memórias em formato digital (e.g., Desafios #2.1, #2.4 e #5.1). De acordo com a mídia, entretanto, certos desafios podem se modificar ou tornar-se mais ou menos evidentes (e.g., Desafios #1.1 e #5.2), e outros podem vir a ser observados, como a localização (e o “recorte”) de representações de memórias em gravações de áudio ou vídeo.

Outra dimensão que influencia grande parte dos desafios, se não todos, abrange os dispositivos utilizados. De acordo com o contexto, atividade realizada e aplicações disponíveis, usuários podem optar por dispositivos diferentes [Kawsar e Brush 2013], migrando fotografias e atividades entre eles [Neustaedter e Fedorovskaya 2009]. Soluções precisam considerar a interação entre dispositivos e a heterogeneidade entre eles, no presente e a longo prazo. Atualmente, a solução de fato para integrar esses múltiplos dispositivos são os chamados “serviços em nuvem”. Entretanto, esses serviços, e os modelos de negócios adotados com eles, apresentam ainda limitações para o uso de foto-memórias a longo prazo. Fatores como a falta de interoperabilidade e a centralização de dados (i.e., o modelo dos *walled gardens* [Cabello et al. 2013]) tornam a preservação de memórias dependente da continuidade do serviço, dificultam o uso de (ou migração para) aplicações alternativas e possibilitam usos abusivos de dados dos usuários por provedores de serviços ou parceiros destes.

Essas problemáticas, junto aos desafios e oportunidades levantados neste trabalho, apontam para questões ainda maiores relativas ao uso da Computação para preservar e consumir informações a longo prazo e de forma sustentável. Estas questões envolvem aspectos ambientais, como o consumo, durabilidade e impacto de tecnologias de armazenamento ao longo do tempo. Mas também envolvem aspectos humanos, e.g. soluções precisam nos auxiliar a preservar, localizar e redescobrir aquilo que consideramos importante, e a descartar o que para nós não tem mais valor. Para tornar tudo isso viável, aspectos tecnológicos precisam ser abordados, e.g. facilitar a interação entre dispositivos e a interoperabilidade entre aplicações, e projetar soluções para a evolução de dados armazenados e para o uso destes através de coleções dispersas.

## 6. Conclusão

Neste trabalho identificamos um conjunto de desafios e, associadas a eles, oportunidades de pesquisa em Computação, que precisam ser abordados para tornar viável o uso e preservação de foto-memórias por longo tempo, por exemplo, entre gerações. Esses desafios e oportunidades, muito embora, não sejam exaustivos permitem identificar um panorama inicial da temática, bem como de suas relações com outras áreas dentro (e também fora) da Computação. A partir disso, pesquisas futuras podem ser conduzidas, por exemplo aprofundando questões relacionadas a uma das necessidades encontradas ou apontando soluções para os desafios identificados. As oportunidades descritas sugerem direções que podem ser adotadas nesse sentido.

## Agradecimentos

Este trabalho foi apoiado pelo Grupo de Pesquisa em Artefatos Físicos de Interação (PAIRG) da Universidade Federal do Rio Grande do Norte (UFRN). Também agradecemos pelos recursos do Laboratório de Computação Física e Fisiológica do PAIRG (PAIRG L2PC) da UFRN.

## Referências

- Ahern, S., Eckles, D., Good, N.S., King, S., Naaman, M. e Nair, R. (2007) “Over-exposed? Privacy patterns and considerations in online and mobile photo sharing”, In: *ACM Conference on Human Factors in Computing Systems*, p. 357-366.
- Besmer, A. e Lipford, H.R. (2010) “Moving beyond untagging: Photo privacy in a tagged world”, In: *ACM Conference on Human Factors in Computing Systems*.

- Broekhuijsen, M., Hoven, E. v. d. e Markopoulos, P. (2017a) “Design directions for media-supported collocated remembering practices”, In: *Eleventh International Conference on Tangible, Embedded, and Embodied Interaction*, p. 21-30.
- Broekhuijsen, M., Hoven, E. v. d. e Markopoulos, P. (2017b) “From PhotoWork to PhotoUse: Exploring personal digital photo activities”. *Behaviour & Information Technology*, v. 36, n.7, p. 754-767.
- Cabello, F., Franco, M.G. e Haché, A. (2013) “The social web beyond “walled gardens”: Interoperability, federation and the case of Lorea/N-1”. *PsychNology Journal*, v. 11, n. 1, p. 43-65.
- Ceroni, A., et al. (2015) “Investigating human behaviors in selecting personal photos to preserve memories”, In: *Int. Conference on Multimedia Expo Workshops (ICMEW)*.
- Drazin A. e Frohlich D. (2007) “Good intentions: Remembering through framing photographs in english homes”. *Ethnos*, v. 72, n. 1, p. 51-76.
- Figueirêdo, H.F., Silva, J.P.R., Leite, D.F.B. e Baptista, C.S. (2012) “Detection of photos from the same event captured by distinct cameras”. In: *18th Brazilian symposium on Multimedia and the web (WebMedia '12)*, p. 51-58.
- Frohlich, D.M., Wall, S. e Kiddle, G. (2013) “Re-discovery of forgotten images in family photo collections”. *Pers Ubiquit Comput*, v. 17, n. 4, p. 729-740.
- Giaccardi, E., Churchill, E. e Liu, S. (2012) “Heritage matters: designing for current and future values through digital and social technologies”. In: *CHI '12 Extended Abstracts on Human Factors in Computing Systems (CHI EA '12)*, p. 2783-2786.
- Goh, D.H-L., Ang, R.P., Chua, A.Y.K. e Lee, C.S. (2009) “Why we share: A study of motivations for mobile media sharing”. In: *Active Media Technology*, v.5820.
- Gu, J., Wu, Y. e Hung, W. (2013) “Personal photo organization using event annotation”. In: *9th Int. Conference On Information, Communications & Signal Processing*, p.1-4.
- Kawsar, F. e Brush, A.J.B. (2013) “Home computing unplugged: why, where and when people use different connected devices at home”. In: *Proc. of the 2013 ACM Int. joint conference on Pervasive and ubiquitous computing (UbiComp '13)*, p. 627-636.
- Kindberg, T., Spasojevic, M., Fleck, R. e Sellen, A. (2005) “The ubiquitous camera: An in-depth study of camera phone use”. *IEEE Pervasive Computing*, v.4, n.2.
- LeBlanc, F. (1993) “Is everything heritage?”. *ICOMOS Canada Bulletin*, v.2, n.2, p.2-3.
- Lindley, S.E., Durrant, A., Kirk, D., e Taylor, A.S. (2009) “Editorial: Collocated social practices surrounding photos”. *Int. Journal of Human-Computer Studies*, v.67, n.12.
- Loach, K., Rowley, J. e Griffiths, J. (2016) “Cultural sustainability as a strategy for the survival of museums and libraries”, *Int. Journal of Cultural Policy*, v.23, n.2.
- Marshall, C.C. (2008a) “Rethinking personal digital archiving, part 1: Four challenges from the field”. *D-Lib Magazine*, v. 14, n. 3.
- Marshall, C.C. (2008b) “Rethinking personal digital archiving, part 2: Implications for services, applications, and institutions”. *D-Lib Magazine*, v. 14, n. 3.
- Marshall, C., Bly, S. e Brun-Cottan, F. (2006) “The long term fate of our personal digital belongings: Toward a service model for personal archives”, In: *Proc. of IS&T*

- Archiving 2006*, p. 25-30.
- Miller, A.D. e Edwards, W.K. (2007) “Give and take: A study of consumer photo-sharing culture and practice”, In: *Proc. of the SIGCHI Conference on Human Factors in Computing Systems*, p. 347-356.
- Mols, I., Hoven, E. v. d. e Eggen, B. (2014) “Making memories: A cultural probe study into the remembering of everyday life”, In: *Proc. of NordiCHI '14*, p. 256-265
- Neustaedter, C. e Fedorovskaya, E. (2009) “Understanding and improving flow in digital photo ecosystems”. In: *Proc. of the Graphics Interface 2009 Conference*.
- Niederée, C., Kanhabua, N., Gallo, F. e Logie, R.H. (2015) “Forgetful digital memory: Towards brain-inspired long-term data and information management”, In: *SIGMOD Record*, v. 44, n. 2, p. 41-46.
- Olsson, T., Soronen, H. e Väänänen-Vainio-Mattila, K. (2008) “User needs and design guidelines for mobile services for sharing digital life memories”, In: *Proc. MobileHCI '08*, p. 273-282.
- Pargman, D. e Raghavan, B. (2014) “Rethinking sustainability in computing: From buzzword to non-negotiable limits”, In: *Proc. of NordiCHI '14*, p. 638-647.
- Petrelli, D. e Whittaker, S. (2010) “Family memories in the home: contrasting physical and digital mementos”. *Pers Ubiquit Comput*, v. 14, n. 2, p. 153-169.
- Rodden, K. e Wood, K.R. (2003) “How do people manage their digital photographs?”, In: *Proc. of the SIGCHI Conference on Human Factors in Computing Systems*.
- Sarvas, R. e Frohlich, D.M. (2011) “From snapshot to social media: The changing picture of domestic photography”, Springer, 1ª ed.
- Soini, K. e Birkeland, I. (2014) “Exploring the scientific discourse on cultural sustainability”, *Geoforum*, v. 51, p. 13-223.
- Van Dijck, J. (2008) “Digital photography: Communication, identity, memory”. *Visual Communication*, v. 7, n. 1, p. 57-76.
- Van House, N.A. (2009) “Collocated photo sharing, story-telling, and the performance of self”. *Int. J. Hum.-Comput. Stud.*, v. 67, n. 12, p. 1073–1086.
- Van House, N.A. (2011) “Personal photography, digital technologies and the uses of the visual”. *Visual Studies*, v. 26, n. 2, p. 125–134.
- Vyas, D., Nijholt, A. e Veer, G.C. v. d. (2013) “Practices surrounding event photos”. In: *14th Int. Conference on Human-Computer Interaction – INTERACT*, p. 55-72.
- Wang, Q. e Brockmeier, J. (2002) “Autobiographical Remembering as Cultural Practice: Understanding the Interplay between Memory, Self and Culture”. *Culture & Psychology*, v. 8, n. 1, p. 45-64.
- Whittaker, S., Bergman, O. e Clough, P. (2010) “Easy on that trigger dad: A study of long term family photo retrieval”. *Pers Ubiquit Comput*, v. 14, n. 1, p. 31-43.
- Wolters, M.K., Niven, E., Runardotter, M., Gallo, F., Maus, H. e Logie, R.H. (2015) “Personal photo preservation for the smartphone generation”. In: *Proc. of the 33rd ACM Conference Extended Abstracts on Human Factors in Computing Systems*.

# Rumo à Melhoria de Produtividade e Sustentabilidade Agrícola por meio da Classificação Automática do Vigor de Sementes de Soja

Marcelo de Souza Junior<sup>1</sup>, Rafael S. Bressan<sup>1</sup>, Douglas F. Pereira<sup>1</sup>,  
Priscila T. M. Saito<sup>1,2</sup>, Pedro H. Bugatti<sup>1</sup>

<sup>1</sup>Departamento de Computação Universidade Tecnológica Federal do Paraná (UTFPR) – Cornélio Procópio – PR – Brasil

<sup>2</sup>Instituto de Computação Universidade de Campinas (UNICAMP) – Campinas, SP – Brasil

{marcelojunior.2015, rafaelbressan, douglaspereira}@alunos.utfpr.edu.br  
{psaito, pbugatti}@utfpr.edu.br

**Abstract.** *Brazil is one of the largest producers and exporters of soybeans in the world. Its great acceptance is given to its nutritional and industrial peculiarities. In view of higher productivity, the use of high quality seed is an important factor. In this sense, the tetrazolium test has been outstanding, due to its precision and speed in the evaluation of the vigor of soybean seeds. However, the analysis process is entirely related to the knowledge and experience of the seed analyst. Thus, this article aims to develop an automatic methodology for the classification of soybean seeds by means of image analysis, using computational vision techniques added to deep learning.*

**Resumo.** *O Brasil é um dos maiores produtores e exportadores de sementes de soja do mundo. Sua ótima aceitação é dada a suas peculiaridades nutritivas e industriais. Tendo em vista a maior produtividade, a utilização de semente de alta qualidade é um fator importante. Nesse sentido, o teste de tetrazólio têm se destacado, devido à sua precisão e rapidez na avaliação do vigor de sementes de soja. No entanto, o processo de análise é totalmente relacionado ao conhecimento e experiência do analista de semente. Dessa forma, este artigo propõe uma metodologia automática para classificação de sementes de soja por meio de análise de imagens, empregando técnicas de visão computacional agregado ao aprendizado profundo.*

## Introdução

O Brasil é um dos maiores produtores e exportadores de grãos do mundo. Para a safra 2016/2017 o Brasil obteve produção de 237.671, 4 mil toneladas, em uma área plantada em 60.889, 3 mil hectares. Entre as diversas culturas semeadas, a soja se destaca, sendo a principal cultura cultivada no país, tal sucesso é dado devido sua liquidez e a possibilidade de melhores rendimentos em relação a outras culturas. A produção de soja para a safra 2016/2017 foi de 114.075, 3 mil toneladas em uma área plantada de 33.909, 4 mil hectares e um rendimento de 3.364 kg/ha, sendo por mais um ano seguido a safra recorde de recebimento de sementes soja [CONAB 2018].

Para um maior rendimento da cultura de soja, a utilização de sementes de alta qualidade é um fator primordial, pois com a utilização das mesmas, é possível o estabelecimento de plantas mais produtivas. A qualidade da semente pode variar em relação a alguns fatores, como danos mecânicos, deterioração por umidade, ataques de percevejos, entre outros [Moreano 2012]. Para o sucesso da lavoura, o controle de qualidade da indústria de sementes deve ser rápido e preciso, fornecendo resultados corretos de forma eficiente. [França-Neto et al. 1998].

Com a lentidão na obtenção dos resultados do teste de germinação, o processo de tomada de decisões na indústria de sementes torna-se limitado. Além disso, na sua forma tradicional de avaliação, o teste não fornece informações sobre o vigor da semente, e não permite a identificação das causas que afetam sua qualidade.

Dentre os testes para avaliação da qualidade fisiológica de sementes, o teste de tetrazólio tem se destacado, devido ao grande número de informações que fornece sobre os lotes de sementes, visando diagnosticar com um baixo custo, os fatores responsáveis pela redução da qualidade das mesmas [França-Neto et al. 1998]. No entanto, o teste de tetrazólio é realizado de forma manual por um analista de sementes, o qual analisa milhares de sementes por inspeção visual diariamente.

Sendo assim, a tarefa é altamente cansativa e suscetível a erros, bem como seu resultado está diretamente relacionado à prática do analista na realização da tarefa. Além disso, por tratar-se de um processo de análise visual humana, a detecção e classificação de danos pode sofrer da subjetividade intrínseca a tal processo. Um especialista em treinamento ou que apresente menor grau de especialização pode apresentar classificações divergentes em relação a um especialista com maior experiência, podendo ocasionar graves perdas de capital. Pode ocorrer também a possibilidade do processo de classificação ser enviesado de forma espúria e deliberada tanto por parte do beneficiador das sementes, como do comprador de lotes, gerando obviamente detrimento a uma das partes.

A partir de tais princípios, fica clara a necessidade de desenvolvimento de uma metodologia automática para a classificação de sementes de soja, mediante ao teste de tetrazólio, por meio de análise por imagens. Sendo assim, o presente trabalho aborda a etapa de extração de características de imagens das sementes de soja, com intuito de obter informações de interesse das mesmas, para a discriminação entre os tipos de danos sofridos durante a lavoura de soja.

A escrita do presente artigo é estruturada de forma que na Seção 2 são apresentados conceitos necessários para o entendimento da metodologia proposta no mesmo. Na Seção 3 é apresentada em detalhes a metodologia proposta. As Seções 4 e 5 explicitam, respectivamente, os experimentos realizados para a análise e validação da presente metodologia proposta e as conclusões.

## **Fundamentação**

Para maior produtividade na safra de soja, a preocupação com a utilização de sementes de alta qualidade é um fator importante, dado que interfere diretamente no desenvolvimento da semente de soja. A análise de qualidade torna-se essencial para a identificação de sementes mais produtivas, resultando positivamente em plantas vigorosas e menos expostas a pragas e doenças, e conseqüentemente reduzindo o uso de fungicidas e agroquímicos para a proteção da cultura na lavoura.

O aprendizado profundo vem contribuindo para o estado da arte para vários problemas em geral, entre eles é bastante utilizado na solução de problemas envolvendo a análise de imagens em processos que requerem métodos de visão computacional. Nos últimos anos, rede neural por convolução (*Convolutional Neural Networks - CNN*), um dos paradigmas que envolvem o conceito de aprendizado profundo, se destacou na resolução de diversos problemas complexos (e.g. reconhecimento de dígitos manuscritos, reconhecimento de fala, reconhecimento visual de objetos, detecção de face, entre outros).

O paradigma de rede neural por convolução é motivado pelo processo biológico de percepção visual, para tanto aplica uma rede neural de múltiplas camadas (*Multilayer Perceptron - MLP*), porém não totalmente conectada como tradicionalmente aplicado na literatura [Caroline et al. 2016]. A mesma aplica campos locais de percepção por meio de neurônios que são ativados localmente em um mapa bidimensional no caso de imagens. Tal processo é realizado por meio da amplamente conhecida operação de convolução, como aplicada no espaço bidimensional em técnicas de processamento de imagens.

Nesse caso, o processo de aprendizado de tal arquitetura visa o aprendizado dos pesos das máscaras/filtros (*kernels*) aplicados ao mapa bidimensional de entrada (e.g. imagem), com o intuito de detectar características intrínsecas ao mesmo. Por exemplo, no caso de imagens, as primeiras camadas de uma CNN, durante seu processo de treinamento, aprendem pesos aos filtros especificados que sejam capazes de detectar primitivas geométricas como retas de diferentes orientações. Já em camadas posteriores, os neurônios de tais camadas são incumbidos do aprendizado de informações de maior abstração da imagem por meio da agregação das informações das camadas anteriores. Ainda considerando o exemplo de imagens, tal passo caracteriza-se como a junção de diferentes primitivas, como retas, detectando “cantos”, e assim sucessivamente em camadas posteriores à mesma, detectando então cores, texturas e formas (e.g. quadrados) mais complexas. As camadas que realizam tais operações são denominadas camadas por convolução (*convolutional layers*).

Além de tais camadas, outras podem ser aplicadas para a inclusão de certa não-linearidade ao processo de aprendizado, da mesma forma que em redes MLPs tradicionais, como por exemplo camadas de ativação que apliquem funções sigmóide ou as *Rectified Linear Unit (ReLU)*, dentre outras da literatura. Outra possibilidade de aplicação de camadas ao processo refere-se às denominadas camadas de subamostragem (*pooling layers*) com o intuito tanto de diminuir o custo computacional do processo, quanto de prover maior robustez e invariância às diferenças espaciais e de escala para detecção de características dos dados de entrada [Dao-Duc et al. 2015, Shijie et al. 2017]. Geralmente, como camada de saída aplicam-se camadas sucessivas totalmente conectadas como no modelo tradicional, sendo que a última camada trata-se da aplicação de uma transformação das probabilidades do aprendizado da rede para que o mesmo seja mapeado para valores nos intervalos [0:1], para tanto pode-se utilizar a função conhecida como *softmax*, bem como outras existentes na literatura.

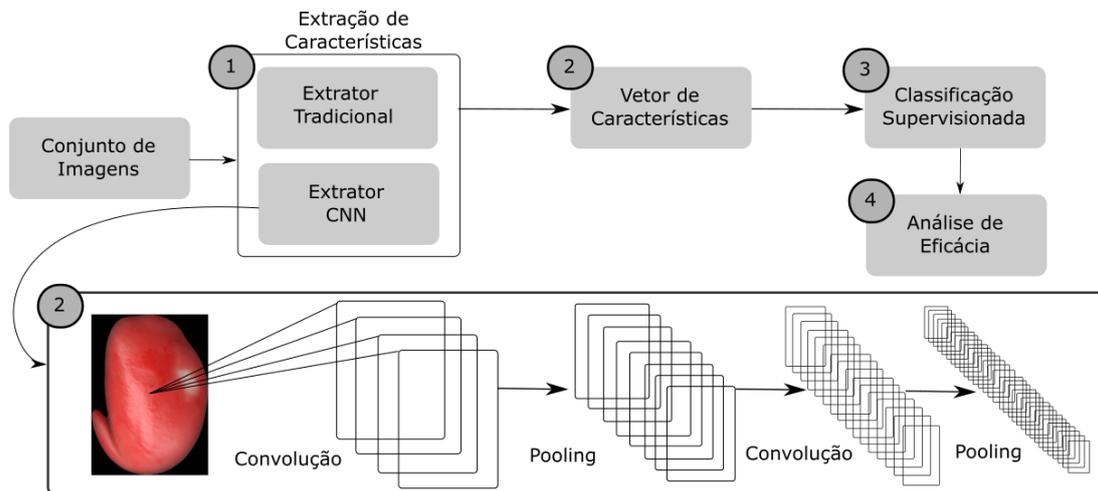
Existem inúmeras arquiteturas CNN propostas por diversos trabalhos na literatura. De maneira geral, a definição de tais arquiteturas recai sobre o mesmo empirismo da definição de arquiteturas tradicionais MLPs que são altamente dependentes do problema. Para [Bezerra 2016], a forma mais simples para arquitetar uma CNN é organizá-la em

etapas. Cada etapa é constituída por uma ou mais camadas de convolução em sequência, seguidas por uma camada de subamostragem, que por sua vez pode, opcionalmente, ser normalizada por meio de uma camada de normalização, como por exemplo utilizando métodos de regularização baseados na norma  $L_2$ , dentre outros.

Segundo [Albawi et al. 2017] o ponto de vista mais benéfico das redes neurais por convolução é a redução do número de parâmetros, ao comparar a quantidade dos mesmos em relação às arquiteturas MLPs tradicionais.

## Metodologia Proposta

Na presente seção são descritas as etapas para a atingir os objetivos do atual trabalho, elucidando para tanto a metodologia proposta. A Figura 1 ilustra o *pipeline* proposto para o desenvolvimento do presente trabalho. A metodologia é dividida em quatro etapas principais.



**Figura 1. Pipeline da metodologia proposta.**

A primeira etapa consiste em realizar a extração de características intrínsecas das imagens. Para tanto, foram extraídas características *hand-crafted*, por meio de descritores de imagens tradicionais de baixo nível (baseados em cor e textura). Apenas características baseadas em cor e textura foram extraídas, uma vez que para a descrição dos danos em sementes, geralmente, a forma das mesmas não apresenta alterações. Além disso foram extraídas as características *deep*, utilizando arquiteturas CNN. Para tanto, foi aplicado o processo de *transfer learning* [Yosinski et al. 2014] e consideradas diferentes arquiteturas pré-treinadas a partir do conjunto de imagens do *ImageNet* [Deng et al. 2009].

Em seguida, na Etapa 2, são gerados os vetores de características para cada técnica de extração (Tabela 2). Após tal passo, os mesmos são submetidos à terceira etapa, na qual são gerados os respectivos conjuntos de treinamento e teste para cada um dos conjuntos de características obtidos. Tais conjuntos de treinamento e teste são então submetidos ao processo de aprendizado supervisionado. Diferentes modelos de classificação são gerados a partir dos conjuntos de treinamento e diferentes técnicas de classificação. Por fim, na Etapa 4 é realizada a análise de desempenho das diferentes técnicas de extração de

características e de classificação. O Algoritmo 1 apresenta em detalhes a metodologia proposta.

---

**Algorithm 1:** Metodologia proposta

---

**Entrada** : conjunto de imagens  $I$   
**Saida** : conjunto de acurácias  $\mathcal{A}_{ij}$   
**Auxiliares:** conjuntos de características tradicionais  $\text{HandCrafted}_s$ , conjunto  $E_s$  de extratores tradicionais, conjuntos de características CNN  $\text{Deep}_l$ , conjunto  $\mathcal{T}_l$  de arquiteturas CNN, conjunto  $\mathcal{F}$  com características  $\text{HandCrafted}_s$  e  $\text{Deep}_l$ , conjuntos de treinamento  $\mathcal{Z}_i$ , modelos de aprendizado  $\mathcal{M}_{ij}$ , conjunto de técnicas de classificação  $\mathcal{C}$

- 1  $\text{HandCrafted}_s \leftarrow \text{extracaoTrad}(I, E_s)$ ;
- 2  $\text{Deep}_l \leftarrow \text{extracaoCNN}(I, \mathcal{T}_l)$ ;
- 3  $\mathcal{F}_n \leftarrow \{\text{HandCrafted}_s\} \cup \{\text{Deep}_l\}$ ;
- 4 **for** cada  $i \in \mathcal{F}$ ,  $i = 1, \dots, n$  **do**
- 5      $\mathcal{Z}_i \leftarrow \mathcal{F}_i$ ;
- 6     **for** cada  $j \in \mathcal{C}$ ,  $j = 1, \dots, m$  **do**
- 7          $\mathcal{M}_{ij} \leftarrow \text{treinamento}(\mathcal{Z}_i, \mathcal{C}_j)$ ;
- 8          $\mathcal{A}_{ij} \leftarrow \text{desempenho}(\mathcal{M}_{ij})$ ;
- 9     **end**
- 10 **end**

---

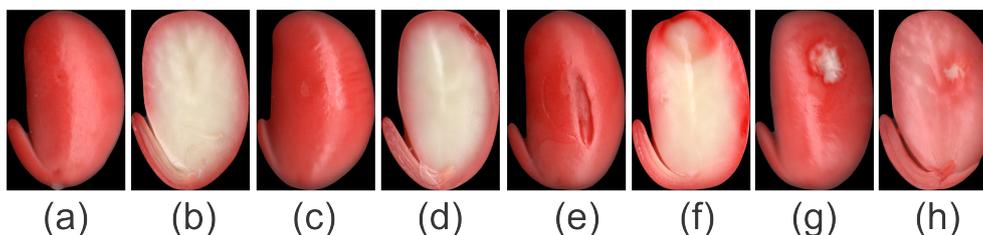
## Experimentos

### Descrição do Conjunto de Imagens

Para a realização dos experimentos do presente trabalho foi utilizado um conjunto de imagens de sementes de soja submetidas ao teste de tetrazólio. O conjunto é composto por 1.333 imagens distribuídas em 10 classes. A Tabela 1 ilustra a quantidade de imagens em cada classe do conjunto de imagens. A Figura 2 ilustra exemplos de imagens de sementes de soja, após aplicação do teste de tetrazólio, com diferentes tipos de danos.

Para melhor entendimento de tais classes foi especificada uma nomenclatura para o nome das mesmas, a qual é definida por 3 caracteres. O primeiro caractere especifica o grau do dano (0 a 3), sendo que quanto maior o valor, maior o dano apresentado na semente. O segundo caractere descreve o tipo do dano encontrado na semente. Por exemplo, o caractere  $U$  descreve um dano causado por umidade excessiva, o caractere  $M$  representa um dano mecânico (i.e. quando a semente pode apresentar uma fratura ou porção faltante), o caractere  $P$  denota um dano causado por percevejos. Já o caractere  $X$  especifica a ausência de danos na semente (i.e. semente perfeita), por tal motivo sempre que houver o caractere  $X$ , o mesmo estará agregado ao caractere de grau de dano 0. Tal redundância foi gerada para manter a padronização da quantidade de caracteres na definição das classes, uma vez que na prática não existe um dano de grau 0. Por fim, o terceiro caractere especifica a porção da semente capturada, visto que para a análise do vigor baseada no teste de tetrazólio é necessário avaliar tanto a porção externa da semente (denotada pelo caractere  $E$ ) como a porção interna da mesma (caractere  $I$ ).

Todas as imagens foram rotuladas e validadas por especialistas durante a análise das sementes. Tais especialistas pertencem a um laboratório de análises inserido em uma unidade de beneficiamento de sementes (UBS) de soja. Tal UBS caracteriza-se dentre uma das maiores unidades beneficiadoras de sementes de soja do país, a qual gera impacto na produção de inúmeros produtores de soja no Brasil.



**Figura 2.** Exemplo de imagens de sementes de soja submetidas ao teste de tetrazólio apresentando diferentes tipos de danos: (a) Perfeita porção externa; (b) Perfeita porção interna; (c) Dano por umidade porção externa; (d) Dano por umidade porção interna; (e) Dano mecânico porção externa; (f) Dano mecânico porção interna; (g) Dano por percevejo porção externa; (h) Dano por percevejo porção interna.

**Tabela 1.** Descrição do conjunto de imagens, com suas respectivas classes, tipos de danos e quantidade de amostras.

Classe	Descrição	#Amostras
1 - 0XE	Perfeita porção externa	502
2 - 0XI	Perfeita porção interna	529
3 - 2UE	Dano por umidade nível 2 porção externa	23
4 - 2UI	Dano por umidade nível 2 porção interna	7
5 - 3ME	Dano mecânico nível 3 porção externa	36
6 - 3MI	Dano mecânico nível 3 porção interna	28
7 - 3PE	Dano por percevejo nível 3 porção externa	83
8 - 3PI	Dano por percevejo nível 3 porção interna	40
9 - 3UE	Dano por umidade nível 3 parte externa	36
10 - 3UI	Dano por umidade nível 3 parte interna	49

## Cenários

Para extração das (*hand-crafted* e *deep*) características foram utilizados diferentes extratores. As características *deep* foram obtidas por meio das CNNs. Já as características *hand-crafted* foram obtidas por meio de extratores baseados em cor e textura. A Tabela 2 apresenta os extratores, a respectiva categoria e a quantidade de características obtidas por cada um deles. Para as arquiteturas CNNs foram utilizados os modelos providos pela biblioteca Keras<sup>1</sup>, bem como foram utilizados os parâmetros padrão especificados pela mesma.

Para classificação foram utilizados os classificadores *Random Forest* - RF [Breiman 2001], *k-Nearest Neighbors* - *k*-NN [Cover and Hart 1967], *Support Vector Machines* - SVM [Hearst et al. 1998] e *Optimum-Path Forest* - OPF [Papa et al. 2012].

<sup>1</sup><https://keras.io/>

Para fins de validação, além das acurácias médias gerais, foi calculada a acurácia por cada classe, afim de analisar a quantidade de acertos de cada classificador por respectiva classe de danos. Para a obtenção de tais acurácias considerando os classificadores tradicionais foi realizado o processo de validação cruzada estratificada com 10-folds.

**Tabela 2. Propriedades de cada extrator de características, especificando a categoria e a dimensionalidade dos vetores de características gerados.**

Extratores	Categoria	#Caraterísticas
F <sub>1</sub> - MobileNet [Howard et al. 2017]	CNN	2048
F <sub>2</sub> - InceptionV3 [Szegedy et al. 2015]	CNN	2048
F <sub>3</sub> - VGG16 [Simonyan and Zisserman 2014]	CNN	512
F <sub>4</sub> - VGG19 [Simonyan and Zisserman 2014]	CNN	512
F <sub>5</sub> - Xception [Chollet 2016]	CNN	2048
F <sub>6</sub> - BIC [Stehling et al. 2002]	Cor	128
F <sub>7</sub> - GCH [Stricker and Orengo 1995]	Cor	255
F <sub>9</sub> - LCH [Smith and Chang 1996]	Cor	135
F <sub>8</sub> - LBP [Guo et al. 2010]	Textura	256
F <sub>10</sub> - Haralick [Haralick et al. 1973]	Textura	15
F <sub>11</sub> - MPOC [Irons and Petersen 1981]	Textura	18

## Resultados

A Tabela 3 apresenta as acurácias médias gerais em porcentagem, obtidas por cada uma das características extraídas e os respectivos classificadores supervisionados. Pode-se verificar que a maior acurácia obtida foi de 78.01%, utilizando o classificador RF com as características extraídas pela arquitetura VGG19. Além de tal resultado, nota-se também que para os classificadores RF e  $k$ -NN as características obtidas pelas diferentes arquiteturas CNNs apresentam melhores resultados em relação às características tradicionais.

Considerando as melhores acurácias atingidas por cada classificador supervisionado é possível verificar que o classificador  $k$ -NN obteve a maior acurácia (75,61%) com as características obtidas por meio da arquitetura Xception. Já para os classificadores SVM e OPF, as maiores acurácias foram obtidas, respectivamente, pelas características oriundas das arquiteturas VGG19 alcançando 78,01%, e VGG16 apresentando 69.16% de acurácia.

Além de analisar a acurácia geral do processo de classificação, mais relevante ainda é a avaliação da acurácia obtida por cada classe de imagens. Ao realizar tal análise, pôde-se verificar que, apesar dos bons resultados denotados por meio da acurácia geral dos classificadores, a acurácia específica de cada classe apresentou bons resultados apenas para as classes de sementes perfeitas (i.e.  $0XE$  e  $0XI$ ), sendo que para as classes que agregam grau e tipo do dano, bem como a porção da semente, as acurácias apresentadas foram baixas. Dessa forma, os resultados de acurácia geral obtidos por meio da primeira análise estavam camufladas pelas altas acurácias obtidas apenas pelas duas classes de imagens de sementes perfeitas.

As Figuras 3 (a)-(d) ilustram de maneira conclusiva tal constatação, sendo que as melhores acurácias obtidas, dentre as classes anteriormente citadas, foram de aproximadamente 40% para a classe  $3PE$ , utilizando as características *deep*, obtidas pelas arqui-

**Tabela 3. Acurácias gerais obtidas, considerando cada um dos extratores e classificadores supervisionados. Valores explicitados em negrito referem-se às melhores acurácias atingidas por cada classificador. Já o valor denotado em sublinhado refere-se à melhor acurácia obtida dentre todas.**

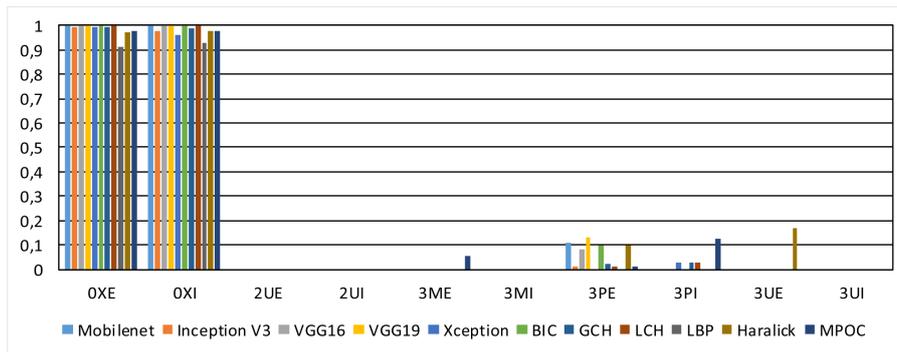
	RF	$k$ -NN	SVM	OPF
MobileNet	77,86	68,64	72,91	66,99
InceptionV3	76,36	64,89	73,06	62,79
VGG16	77,71	69,76	76,89	<b>69,16</b>
VGG19	<u>78,01</u>	69,24	<b>78,01</b>	68,82
Xception	75,61	<b>75,61</b>	70,44	63,91
BIC	77,79	66,69	77,26	65,49
GCH	76,89	66,01	77,11	64,59
LCH	77,41	67,21	77,64	65,94
LBP	71,11	55,58	75,01	54,91
Haralick	76,44	65,56	77,04	63,76
MPOC	76,29	65,94	76,86	64,51

turas MobileNet e VGG16 para o classificador SVM. Já a segunda melhor acurácia, de aproximadamente 35%, foi obtida com as mesmas características e classificador para a classe *3PI*. No entanto, ainda é possível perceber que as características obtidas pelas diferentes arquiteturas CNNs, geralmente, apresentam melhores resultados quando comparadas com as características tradicionais.

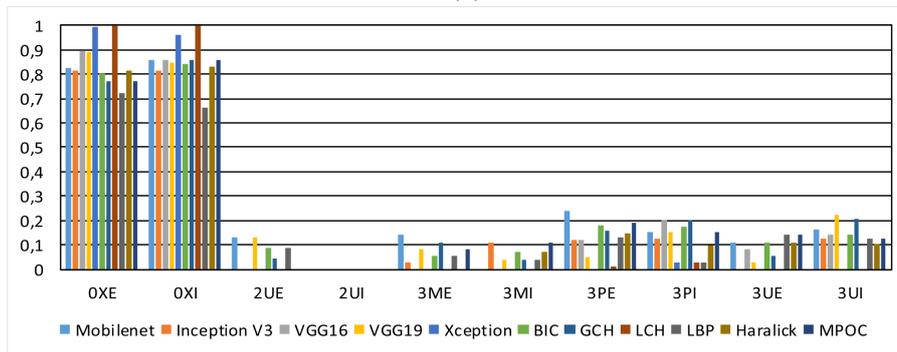
É importante ressaltar que tais resultados baixos de acurácia por classe obtidos pela metodologia proposta, podem ser justificados principalmente pelo alto desbalanceamento de imagens por classe. Ao analisar a Tabela 1, descrita na Seção 4.1, nota-se claramente o relevante desbalanceamento entre as classes. Dessa forma, como é amplamente conhecido na literatura, classificadores supervisionados geralmente apresentam resultados consideravelmente baixos quando aplicados em problemas altamente desbalanceados, fato que ocorreu no presente trabalho.

No entanto, apesar de tais resultados, vale ressaltar que o presente trabalho configura-se como uma metodologia seminal para a análise do problema de classificação do vigor de sementes de soja por meio de características tanto tradicionais como baseadas em arquiteturas profundas pré-treinadas. Além disso, a metodologia proposta foca no problema de classificação mais desafiador possível, atrelado ao contexto da definição automática do vigor de sementes de soja, uma vez que propõe em um único passo de classificação a definição de três especificidades com semânticas diferentes relacionadas às imagens, que são: nível do dano, tipo do dano e porção da semente.

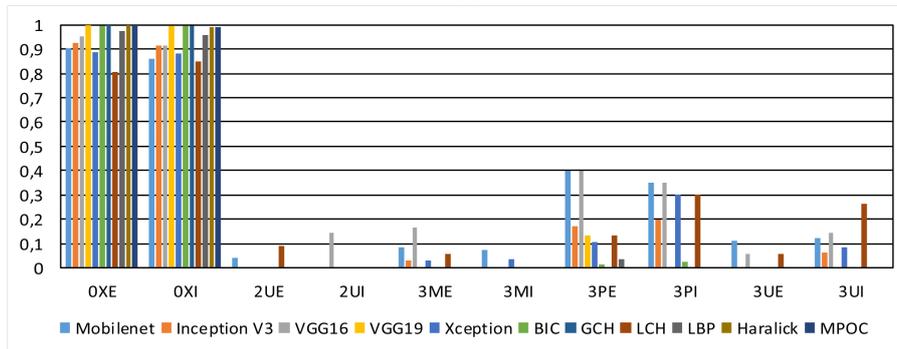
Portanto, verifica-se a partir de tal ponto outra justificativa plausível para as baixas acurácias obtidas, uma vez que trata-se de um problema hierárquico de classificação, em que sub-passos de classificação poderiam ser aplicados a cada uma das especificidades para posterior agregação de classificação. No entanto, o presente trabalho optou por traçar o caminho mais desafiador por meio da definição em único passo da classificação de todas as especificidades, com o intuito de prover melhor eficiência e escalabilidade ao processo, visto que diariamente um único especialista analisa visualmente milhares de sementes.



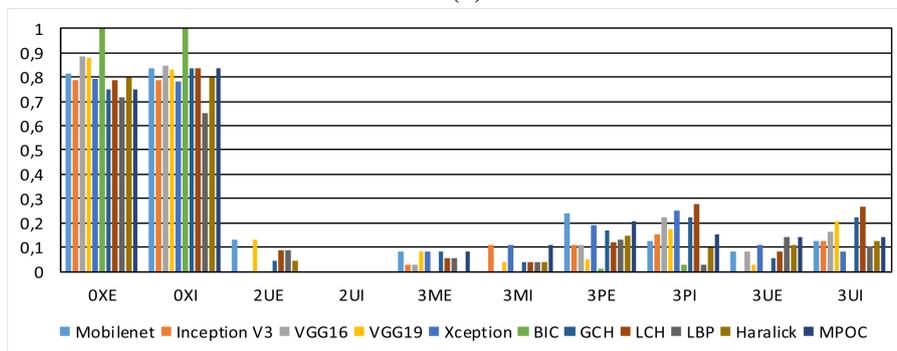
(a)



(b)



(c)



(d)

**Figura 3. Médias das acurácias por classe obtidas, considerando cada um dos extratores e classificadores (a) RF, (b)  $k$ -NN, (c) SVM e (d) OPF.**

## Conclusão

No presente trabalho foi apresentada uma nova metodologia para a classificação automática de danos em sementes de soja submetidas ao teste de tetrazólio, e consequentemente, para a definição do vigor das mesmas. Na presente metodologia foram aplicadas tanto características tradicionais extraídas de uma base de imagens de sementes, bem como características obtidas por meio de arquiteturas CNNs pré-treinadas por meio do conceito de *transfer learning*.

A partir dos resultados obtidos pôde-se verificar o quão desafiador o problema caracteriza-se, uma vez que demanda a classificação de diferentes fatores semânticos intrínsecos à definição do vigor em sementes de soja. Tais fatores referem-se ao tipo de dano, ao nível de severidade de um dado dano, bem como à porção da semente ao qual um determinado dano é detectado. Dessa forma, visto que o processo de definição do vigor deve ser altamente escalável, dado o grande volume de dados analisados diariamente pelo analista em sementes, a presente metodologia visou aplicar em um único passo de classificação a definição conjunta de todos os fatores semânticos envolvidos no problema.

Apesar das acurácias por classe obtidas terem apresentando valores baixos, o presente trabalho abre novos caminhos para inúmeras melhorias ao processo explicitado por meio da metodologia proposta. Tais melhorias podem ser atingidas primeiramente pelo balanceamento das classes de danos. Entretanto, uma vez que não é trivial realizar tal balanceamento por meio da coleta in-situ, em que geralmente, imagens de sementes perfeitas são a regra (em virtude dos controles das unidades de beneficiamento de sementes), vislumbra-se a aplicação de técnicas de *data augmentation* para realizar tal balanceamento.

Assim, a partir dos pontos elencados, acredita-se que a presente metodologia seminal para o problema em questão, pode gerar considerável impacto na melhoria da produtividade e sustentabilidade agrícola relacionada à produção de soja no Brasil. Além disso, uma vez refinada, a mesma pode ser também utilizada como uma contraprova às definições de vigor realizadas pelo especialista, auxiliando assim o mesmo em tal processo, bem como evitando adulterações de caráter escuso nos resultados do vigor, oriundas de interesses monetários.

## Agradecimentos

O presente trabalho recebeu apoios oriundos do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq): grants #472625/2014-4, #431668/2016-7, #422811/2016-5; Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES); Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná; Secretaria da Ciência, Tecnologia e Ensino Superior (SETI); Belagrícola; e Universidade Tecnológica Federal do Paraná (UTFPR).

## Referências

Albawi, S., Mohammed, T. A., and Al-Zawi, S. (2017). Understanding of a Convolutional Neural Network. In *Proceedings of the International Conference on Engineering and Technology*, pages 1–6.

- Bezerra, E. (2016). Introdução à Aprendizagem Profunda. In Ogasawara, V., editor, *Tópicos em Gerenciamento de Dados e Informações - Simpósio Brasileiro de Banco de Dados*, pages 57–86. Sociedade Brasileira de Computação.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.
- Caroline, A., Vargas, G., Paes, A., and Vasconcelos, C. N. (2016). Um Estudo sobre Redes Neurais Convolucionais e sua Aplicação em Detecção de Pedestres. In *Proceedings of the Conference on Graphics, Patterns and Images*, pages 1–4.
- Chollet, F. (2016). Xception: Deep learning with depthwise separable convolutions. *arXiv preprint*.
- CONAB (2018). Companhia nacional de abastecimento: Acompanhamento da Safra Brasileira Grãos, V.5 - SAFRA 2016/17 - N.6 - Sexto Levantamento — Março 2018. *Monitoramento agrícola- Safra 2017*, 5:1–126.
- Cover, T. and Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1):21–27.
- Dao-Duc, C., Xiaohui, H., and Morère, O. (2015). Maritime Vessel Images Classification Using Deep Convolutional Neural Networks. In *Proceedings of the Sixth International Symposium on Information and Communication Technology*, pages 1–6. ACM Press.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Kai Li, and Li Fei-Fei (2009). ImageNet: A large-scale hierarchical image database. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255. IEEE.
- França-Neto, J. B., Krzyzanowski, F. C., and da Costa, N. P. (1998). *O Teste de Tetrazólio em Sementes de Soja*. Embrapa - Centro Nacional de Pesquisa de Soja, Londrina.
- Guo, Z., Zhang, L., and Zhang, D. (2010). Rotation invariant texture classification using LBP variance (LBPV) with global matching. *Pattern Recognition*, 43(3):706–719.
- Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6):610–621.
- Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., and Scholkopf, B. (1998). Support vector machines. *IEEE Intelligent Systems and their Applications*, 13(4):18–28.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *CoRR*, abs/1704.04861.
- Irons, J. R. and Petersen, G. W. (1981). Texture transforms of remote sensing data. *Remote Sensing of Environment*, 11:359–370.
- Moreano, T. B. (2012). *Evolução das Qualidades Física e Fisiológica da Semente de Soja no Beneficiamento*. Dissertação, Universidade Estadual de Maringá, Maringá.
- Papa, J. P., Falcão, A. X., de Albuquerque, V. H. C., and Tavares, J. M. R. S. (2012). Efficient supervised optimum-path forest classification for large datasets. *Pattern Recognition*, 45:512–520.

- Shijie, J., Ping, W., Peiyi, J., and Siping, H. (2017). Research on data augmentation for image classification based on convolution neural networks. In *Proceedings of the Chinese Automation Congress*, pages 4165–4170. IEEE.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556.
- Smith, J. R. and Chang, S.-F. (1996). Local color and texture extraction and spatial query. In *Proceedings of the International Conference on Image Processing*, pages 1011–1014.
- Stehling, R. O., Nascimento, M. A., and Falcão, A. X. (2002). A compact and efficient image retrieval approach based on border/interior pixel classification. In *Proceedings of the International Conference on Information and Knowledge Management*, pages 102–109.
- Stricker, M. A. and Orengo, M. (1995). Similarity of color images. In *Storage and Retrieval for Image and Video Databases III*, volume 2420, pages 381–393. International Society for Optics and Photonics.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2015). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 2818–2826.
- Yosinski, J., Clune, J., Bengio, Y., and Lipson, H. (2014). How transferable are features in deep neural networks? In *Proceedings of the International Conference on Neural Information Processing Systems*, pages 3320–3328.

## Patrocinador Diamante



**GOVERNO**  
DO RIO GRANDE DO NORTE

---

## Patrocinadores Bronze



## Apoio Financeiro



MINISTÉRIO DA  
EDUCAÇÃO

