



## **INTELIGÊNCIA COLETIVA NA ANTECIPAÇÃO DE ALERTAS DE DOENÇAS NA AGRICULTURA**

**JARBAS LOPES CARDOSO JUNIOR** - jarbas.cardoso@cti.gov.br  
CENTRO DE TECNOLOGIA DA INFORMAÇÃO RENATO ASCHER - CTI

**SILVIO ERNESTO BARBIN** - barbin@usp.br  
UNIVERSIDADE DE SÃO PAULO - USP

**FREDERIC ANDRES** - frederic.andres@gmail.com  
NATIONAL INSTITUTE OF INFORMATICS, NII

**ALEXANDRE GUITTON** - alexandre.guitton@univ-bpclermont.fr  
CLERMONT UNIVERSITÉ, UNIVERSITÉ BLAISE PASCAL, LIMOS/CNRS/UMR  
6158 BP.

**ASANEE KAWTRAKUL** - asanee\_naist@outlook.com  
KASETSART UNIVERSITY, KU

**Resumo:** *TÉCNICAS DE MONITORAMENTO NA AGRICULTURA TRAZEM GRANDES BENEFÍCIOS ECONÔMICOS AOS AGRICULTORES. ESTE ARTIGO APRESENTA O PROJETO CBMA4 (CYBERBRAIN MASS AGRICULTURE ALARM ACQUISITION AND ANALYSIS) QUE TEM POR OBJETIVO MINIMIZAR OS IMPACTOS DE DOENÇAS E DESASTRES NATURAIS NO CULTIVO DE ARROZ. POR EXEMPLO, A DETECÇÃO PRECOCE DE PRAGAS PODE REDUZIR A QUANTIDADE DE INSETICIDA A SER APLICADO NOS ARROZAIIS. AGRICULTORES, TRABALHANDO COLABORATIVAMENTE E EQUIPADOS COM DISPOSITIVOS MÓVEIS, ATUAM COMO SENSORES HUMANOS, EXTRAINDO DADOS DE SENSORES DISTRIBUÍDOS PELO CAMPO E INSERINDO INFORMAÇÕES SOBRE A PLANTAÇÃO. O TRABALHO CONCENTRA-SE EM: AQUISIÇÃO DE DADOS PARA ANTECIPAÇÃO DE ALERTAS, MODELO PARA ANÁLISE BASEADO NO REFERENCIAL 5WIH, E USO DE REDE SOCIAL DE ARROZEIROS. O PROCESSO PARA MINIMIZAR OS RISCOS DE DOENÇAS COMPREENDE AS ETAPAS DE PLANEJAMENTO DA COLETA, AQUISIÇÃO E ANÁLISE DOS DADOS E DE ENRIQUECIMENTO DO CONHECIMENTO SOBRE DOENÇAS. OS SENSORES HUMANOS COMBINAM TÉCNICAS DE PROCESSAMENTO DE DADOS ADEQUADAS PARA EXTRAIR ALERTAS COM CONTEÚDO SEMÂNTICO DE ACORDO COM O MODELO DE INTELIGÊNCIA COLETIVA. CADA ALERTA, CHAMADO WARNCON, É ORGANIZADO COM METÁFORAS MULTIMÍDIAS E METADADOS RELACIONADOS ÀS METÁFORAS. COM ESSE CONHECIMENTO, UMA ABORDAGEM DE TOMADA DE DECISÃO BASEADA EM INTELIGÊNCIA COLETIVA DETERMINA AS AÇÕES A SEREM LANÇADAS SOBRE UM CONJUNTO DE WARNCONS PELOS ARROZEIROS.*

**Palavras-chaves:** *SISTEMA DE ANTECIPAÇÃO DE ALERTAS. REDES SOCIAIS. INTELIGÊNCIA COLETIVA. SERVIÇOS DE ALERTAS BASEADOS EM CONTEXTO. AGRICULTURA DE PRECISÃO.*

**Área:** 8 - *GESTÃO DO CONHECIMENTO ORGANIZACIONAL*

**Sub-Área:** 8.5 - *GESTÃO DO CONHECIMENTO EM SISTEMAS PRODUTIVOS*

## COLLECTIVE INTELLIGENCE IN EARLY WARNING OF DISEASES IN AGRICULTURE

**Abstract:** *MONITORING TECHNIQUES IN AGRICULTURE BRING GREAT ECONOMIC BENEFITS TO FARMERS. THIS PAPER PRESENTS THE CBMA4 PROJECT (CYBERBRAIN MASS AGRICULTURE ALARM ACQUISITION AND ANALYSIS) WHICH AIMS TO MINIMIZE THE IMPACTS OF DISEASES AND NATURAL DISASTERS IN RICE CULTIVATION. FOR EXAMPLE, EARLY DETECTION OF PESTS CAN REDUCE THE AMOUNT OF PESTICIDE TO BE APPLIED IN THE PADDY FIELD. FARMERS WORKING COLLABORATIVELY AND SUPPORTED WITH MOBILE DEVICES, ACT AS HUMAN SENSORS, EXTRACTING DATA FROM SENSORS DISTRIBUTED ACROSS THE FIELD AND ENTERING INFORMATION ON THE PLANTATION. THE WORK FOCUSES ON: DATA ACQUISITION FOR EARLY ALERTS, MODEL FOR ANALYSIS BASED ON 5WIH REFERENCE, AND USE OF SOCIAL NETWORKING OF RICE FARMERS. THE PROCESS TO MINIMIZE THE RISK OF DISEASES COMPRISES THE PLANNING STAGES OF COLLECTION, ACQUISITION AND ANALYSIS OF DATA AND ENRICHMENT OF KNOWLEDGE ABOUT DISEASES. HUMAN SENSORS COMBINE APPROPRIATE DATA PROCESSING TECHNIQUES TO EXTRACT WARNINGS WITH SEMANTIC CONTENT ACCORDING TO THE COLLECTIVE INTELLIGENCE MODEL. EACH WARNING, CALLED WARNCON, IS ARRANGED WITH MULTIMEDIA METAPHORS AND METADATA RELATED TO THE METAPHORS. WITH THIS KNOWLEDGE, AN APPROACH BASED ON COLLECTIVE INTELLIGENCE DECISION-MAKING DETERMINES THE ACTIONS TO BE LAUNCHED ON A SET OF WARNCONS BY RICE FARMERS.*

**Keyword:** *EARLY WARNING SYSTEM. SOCIAL NETWORKS. COLLECTIVE INTELLIGENCE. SERVICES BASED ON CONTEXT ALERTS. PRECISION AGRICULTURE.*

## 1. Introdução

Sob a liderança da Organização para a Alimentação e Agricultura das Nações Unidas (FAO/ONU), há clara recomendação para a redução do uso de produtos químicos (fertilizantes, inseticidas) na agricultura e para antecipação de doenças na agricultura e de desastres naturais. Diversas tecnologias foram desenvolvidas para tentar obter produtos agrícolas mais seguros e de menor impacto ambiental (Poissot, 2007). O impacto dos desastres naturais e de doenças na agricultura pode ser determinado por dois fatores, um natural e outro social (UN, 2014a, 2014b; UNISDR, 2014). O fator natural está relacionado com a magnitude de um fenômeno natural e a degradação do meio ambiente provocada no local. Intensidade das secas, chuvas torrenciais, granizo, inundações, enchente, deslizamento de terra, geada, pragas e doenças em culturas são exemplos de fenômenos naturais. O fator social está relacionado à suscetibilidade ou à vulnerabilidade das comunidades, povos ou culturas aos perigos que os desastres ou doenças podem causar. Conhecendo as dificuldades de controlar os fenômenos naturais, a antecipação de alertas e a prevenção são fundamentais para minimizar os problemas decorrentes dos fatores naturais. Os fatores sociais podem ser controlados, modificados ou, pelo menos, mitigados pela intervenção humana.

A agricultura de precisão (AP) tem proporcionado informações e conhecimento valiosos para atingir esse objetivo (AUBERT et al, 2012; NASH et al, 2009). Considera-se que uma comunidade de produtores rurais fornece a dimensão colaborativa necessária para implementar a AP. O projeto CBMa4 (*CyberBrain Mass Agriculture Alarm Acquisition and Analysis*), desenvolvido em colaboração entre instituições do Brasil, Japão, Tailândia e França, busca fazer com comunidades de agricultores experimentem comportamentos de colaboração e compartilhamento de suas observações sobre as plantações de arroz e de informações sobre o ciclo de cultivo (condições de cultivo e de clima) para uma tomada de decisão visando melhorar a produtividade e ter uma melhor antecipação de alertas e prevenção de doenças e de sua propagação e ampliação da gravidade (CARDOSO Jr. et al, 2015; KAWTRAKUL et al 2008; KAWTRAKUL et al, 2014; POISOT, 2007).

Neste trabalho de pesquisa, é adotada a seguinte arquitetura de monitoramento. Sensores climáticos, autônomos e estáticos (SC) são implantados em arrozais. Eles realizam medições periódicas, tais como, temperatura, umidade do ar, umidade do solo etc. Os agricultores são equipados com dispositivos móveis (p.ex., celulares) são chamados de sensores humanos (SH). O principal papel dos SH é recuperar dados coletados pelos SC. Assim que o agricultor recebe os dados na sua área de trabalho diário, ele propaga as

informações para o agricultor mais próximo e este para o seguinte e assim por diante, até atingir uma estação (ou entidade) central, que pode estar localizada na cidade, longe dos campos, ou na sede da cooperativa. Nessa central, os dados são carregados em um banco de dados acessível a todos os agricultores da rede. O processo de tomada de decisão coletiva tem acesso à base de dados para gerar alertas e dar orientação aos agricultores.

O principal objetivo do CBMa4 é minimizar os impactos de doenças e desastres em culturas de arroz com base na antecipação de alertas, resolução colaborativa de problemas e na adoção das melhores práticas compartilhadas pela comunidade de agricultores (KAWTRAKUL et al, 2014). Por exemplo, a detecção precoce de larva de insetos pode reduzir a quantidade de defensivo agrícola a ser aplicado nos arrozais. Para alcançar este objetivo, os seguintes tópicos precisam ser considerados: (i) aquisição de dados para antecipação de alertas, (ii) modelo para análise baseado no referencial 5W1H, e (iii) uso inteligente de rede social composta por arroteiros e técnicos agrícolas.

Os alertas antecipados são gerados de acordo com duas estratégias complementares: (i) coleta de dados, por exemplo, quando um limite do nível de água de um rio está prestes a ser excedido, e (ii) de tomada de decisão colaborativa, por exemplo, quando medições independentes indicarem um evento crítico. A tomada de decisão sobre a antecipação do alerta baseado em inteligência coletiva é construída a partir de uma função de composição semântica contextual de alertas e da fusão de dois indicadores obtidos através referencial Bayesiano (HÜLLERMEIER, 2011). Além disso, o grau de confiança na medida de probabilidade permite determinar o nível de enriquecimento para entendimento dos alertas e para agir de acordo com a gravidade da ocorrência.

Este artigo apresenta um componente inovador para o sistema de coleta alertas de melhoraria do processo de tomada de decisão que resulta na antecipação do alerta. O componente proposto envolve dois módulos: (i) coleta de alerta, baseado em sensores humanos, e (ii) enriquecimento do conhecimento sobre os alertas, baseado na inteligência coletiva (CI). Sensores humanos combinam técnicas básicas de processamento de dados orientadas para a extração do conteúdo semântico dos alertas de acordo com o modelo de CI proposto. O resultado final esperado é a identificação dos diferentes tipos de alertas com conteúdo semântico, chamados *warncons*, incluindo metáforas multimídia e metadados relacionados a essas metáforas. Além disso, são apresentadas métricas para medir as relações entre *warncons*. Com esse conhecimento, o processo de tomada de decisão baseado na CI pode determinar as ações (mobilizadoras, preventivas, redutoras de impacto etc.) a serem

realizadas pelos agricultores de acordo com um ou um conjunto de *warncons*. Note-se que a abordagem baseada na CI está consistente com as técnicas de classificação *Support Vector Machines* (HAWASHIN et al, 2010) e *Fuzzy K-means* (HÜLLERMEIER, 2011), mas essa discussão está fora do escopo deste trabalho.

Este artigo está organizado da seguinte forma. No capítulo 2 são apresentados os metadados para antecipação de alertas baseados no referencial 5W1H e o estudo de caso de comunidade inteligente de agricultores. No capítulo 3 é apresentada a segunda versão da estratégia para definir o quão antecipado os alertas podem ser (a primeira versão foi apresentada por CARDOSO Jr. et al, 2015). No capítulo 4 são discutidos os desafios e ações futuras para melhorar a produtividade nos arrozais tailandeses onde o modelo proposto está sendo empregado.

## **2. Sistema de Gestão de Antecipação de Alertas na Agricultura**

O estabelecimento de um sistema de gestão de antecipação de alertas de desastres naturais e de doenças na agricultura é uma das prioridades da Organização das Nações Unidas (ONU) no mundo todo (UN, 2014a). Essas prioridades são apontadas em seu referencial de ações estratégicas para os próximos anos, onde são também estabelecidas as principais recomendações para a abordagem do risco de desastres e doenças na agricultura (UN, 2014a, 2014b). Essas recomendações focam na definição de métodos confiáveis de busca e de integração das diversas informações disponíveis em diferentes fontes, para tratá-las e entregá-las aos agricultores em zonas de risco para eles possam tomar decisões e agir antes dos eventos, a fim de mitigá-los. Ainda segundo as recomendações da ONU, é necessário que haja: (i) conhecimento prévio dos riscos e vulnerabilidades enfrentados pelas comunidades de agricultores, (ii) monitoramento do ambiente local para garantir alertas precisos e oportunos aos agricultores, (iii) divulgação de informação relevante e confiável, e (iv) ganho de conhecimento sobre as ameaças e sobre a capacidade de enfrentá-las. Por exemplo, durante um período de fortes chuvas, o alerta pode ser iniciado pelo CBMa4 através de SC e de SH que fornecem informações que orientam os agricultores sobre a regulação dos níveis de água de reservatórios, rios ou barragens na sua região, a fim de atenuar o risco de ruptura e as consequentes perdas de colheitas por inundação.

### **2.1 Metadados de alertas baseado no referencial semântico 5W1H**

Com base nessas prioridades e sobre as decisões e ações decorrentes, ONU, cientistas e, sobretudo, agricultores podem ter um enriquecimento da compreensão sobre antecipação de

alertas em seu ambiente. Neste trabalho é aplicado o referencial 5W1H (“Who?”, “What?”, “Why?”, “Where?”, “When?”, “How?”, respectivamente, “Quem?”, “O quê?”, “Por quê?”, “Onde?”, “Quando?”, “Como?”; ANDRES & FUKAMI, 2007) para melhorar a compreensão do processo de antecipação de alertas usando informações relacionadas com a prevenção, preparação e ações específicas para os agricultores ou comunidades de agricultores.

Os atributos de metadados com base no referencial 5W1H são mostrados na Figura 1. Eles compõem um *warcon* conforme descrição abaixo:

- O Quê (*What?*). Traz as informações sobre o alerta. Ontologias sobre doenças na agricultura ou em desastres naturais e recursos de inteligência coletiva são usados para definir o alerta.
- Por Quê (*Why?*). Descreve a razão para o alerta. Traz a descrição contextual e semântica das razões do alerta.
- Quando (*When?*). Indica a hora, e a data de quando a observação foi feita. Por exemplo, mostra a data e a hora de quando a coloração amarela e a aparência de seca das folhas de arroz foram observadas.
- Onde (*Where?*). Lugar ou local definido por GPS onde foi observado o alerta.
- Quem (*Who?*). Descrição (perfil) do agricultor (sensor humano) ou do sensor (por exemplo, sensor de umidade do solo ou sensor de temperatura) que participam da observação do alerta.
- Como (*How?*). Descrição sobre como a observação do alerta foi feita.

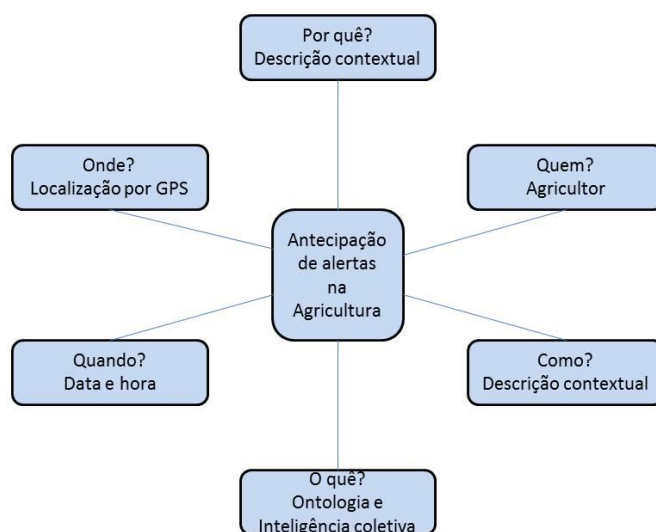


FIGURA 1 – Visão generalizada dos metadados de antecipação de alertas com base no referencial 5W1H. (Adaptado de CARDOSO Jr. et al, 2015.)

## 2.2 Estudo de caso de alertas em arrozal

Para este estudo de caso sobre alertas em campos de arroz é definida uma arquitetura hierárquica de três camadas como se segue (SHAH et al, 2003).

A camada de base dessa arquitetura é constituída pelos diferentes tipos de sensores climáticos, por exemplo, sensores de umidade de solo, de umidade de ar, de temperatura, pluviômetro. Estes sensores são autônomos, isto é, operam independentes de infraestrutura de instalação elétrica e de comunicação e têm capacidade limitada de energia (bateria e solar). São instalados em pontos fixos nos arrozais. Podem, alternativamente, se comunicarem entre si através de uma rede sem fio.

A camada intermediária da arquitetura é constituída pelos SH, constituídos pelos agricultores munidos de dispositivos móveis como, por exemplo, *smartphones*. Esses dispositivos, operados pelos agricultores, interagem com os SC (na camada de base) para a coleta dos dados e entre si. Eles utilizam software livre e não necessitam de torres de comunicação ou de operadoras de telefonia para se comunicarem. O dispositivo móvel dispõe também de software para comunicação com uma central de coleta dos dados.

A trajetória do agricultor pelo campo de arroz depende de sua rotina de trabalho. Na etapa inicial dos trabalhos de pesquisa a trajetória não é pré-estabelecida. Faz-se necessário respeitar o limite máximo para transmissão dos dados entre os agricultores. Esse limite é definido pela potência do dispositivo móvel. Para a primeira versão do experimento, está



sendo utilizados *smartphones* ZTE Open C<sup>1</sup> com o sistema Android 4.4 e serviço de rede *mesh* Serval<sup>2</sup>. A rede *mesh* Serval é uma solução de software de livre para telefones móveis, de acordo com seu fabricante “permite a comunicação mesmo na falta de torres de telefonia e outras infraestruturas de apoio à comunicação móvel (GARDNER-STEPHEN et al, 2013).

A camada superior dessa arquitetura é constituída pelos coletores inteligentes locais (ou no inglês, SVC, *Smart Village Collector*). Cada SVC é estático, conectado à Internet, e não tem limitações de energia. Cada SVC interage com a plataforma CBMa4 (KAWTRAKUL et al, 2014). A Figura 2 ilustra a demonstração do funcionamento do sistema para produtores rurais na Tailândia.

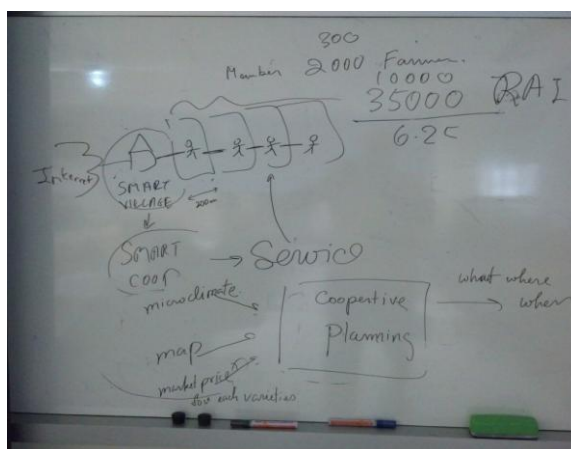


FIGURA 2 – Representação da rede *mesh* constituída pelos agricultores. A figura explicativa foi utilizada em discussões com dirigentes e técnicos arroteiros para ampliação do experimento (CI@PracticeDay, 2015).

Para este estudo de caso, os dados coletados estão relacionados com o cultivo do arroz, realizado por cooperativas de pequenos agricultores na Tailândia e estão organizados de acordo com o conjunto de metadados recomendado por LOUSANGFA et al (2008). A tabela 1 exibida a seguir descreve um subconjunto dos metadados utilizados.

TABELA 1 - Atributos do metadado de alerta de doenças a que um arrozal está sujeito.

Atributo do Metadado	Descrição do Atributo
Emergency Data Exchange Language (EDXL)	Mensagem padrão para compartilhamento de dados entre sistemas de informação sobre emergências.
EventsML-G2	Padrão para a transmissão de informações sobre o evento em observado.
Ag-Event AP	Perfil de aplicação de metadados usado para a troca de informações de eventos dentro da comunidade de agricultores.
rice_var_rd	Descrição da variedade do arroz utilizado no cultivo de objeto do estudo, definido pelo Departamento do Arroz, Tailândia.

<sup>1</sup> Configuração do smartphone ZTE open C: 1.2 GHz Qualcomm Snapdragon MSM8210 200, processador dual core e 512 MB de RAM e 4GB de ROM.

<sup>2</sup> SERVAL Project. <http://www.servalproject.org>, acesso em julho de 2015.

rice_var_doe	Descrição sobre extensão variedade do arroz utilizado no cultivo de objeto de estudo, conforme definição do Departamento do Arroz, Tailândia.
rice_var_ptt	Descrição da variedade do arroz utilizado no cultivo de objeto de estudo, conforme definição do Pathumthani Rice Research Center, Tailândia.
rice_var_bat	Descrição da variedade do arroz utilizado no cultivo de objeto de estudo, conforme definição da empresa Bio Agro Thai Co., Tailândia.
rice_cul_rd	Descrição sobre o cultivo do arroz utilizado no cultivo de objeto de estudo, conforme definição da empresa Rakbankerd Co., Tailândia.
rice_cul_the	Descrição sobre o cultivo do arroz utilizado no cultivo de objeto de estudo, conforme definição dada pela Enciclopédia Tailandesa de Arroz.
rice_pro_rd	Descrição sobre a proteção de arroz dada pelo Departamento do Arroz, Tailândia.
rice_pro_doe	Descrição sobre a proteção de arroz dada pelo Departamento de Extensão Agrícola, Tailândia.
rice_pro_ptt	Descrição sobre a proteção de arroz dada pelo Pathumthani Rice Research Center, Tailândia.
soil_char_ddd	Descrição sobre as características do solo dada pelo Departamento de Desenvolvimento Agrário, Tailândia.
soil_char_cmu	Descrição sobre as características do solo dada pela Universidade Chaing Mai, Tailândia.
farmer	Descrição sobre os agricultores utilizados no sistema especialista de fertilizantes.

A Figura 3 mostra uma área experimental localizada na região de Baan Khaam, nordeste da Tailândia, cuidada por uma comunidade composta por cerca de 30 pequenos agricultores. A área total é de 1,8 ha. Cada subdivisão mostrada na figura é uma simplificação da área de plantio sob responsabilidade de uma ou mais famílias de agricultores. Os símbolos indicam o local de instalação e o tipo de sensor (SC, estático) no campo. Os símbolos em amarelo representam os sensores de umidade do solo (SCUS), enquanto que os azuis representam os sensores de temperatura (SCT). Eles realizam medições periódicas e se comunicam com os sensores humanos por conexão direta (aproximação) de suas interfaces sem fio. Os SH transportam os dados e os registros iniciais de metadados de alerta. Dessa forma, os SH atuam como mulas de dados (Shah et al, 2003), ou seja, atuam como entidades que transportam fisicamente um computador com capacidade de armazenamento entre locais remotos para efetivamente criar uma conexão de comunicação de dados.



FIGURA 3 – Ilustração da área de plantio e da distribuição de sensores climáticos (Cardoso et al, 2015).

Os dados (por exemplo, tipo de alerta, ação a ser realizada, comentários feitos por agricultores e técnicos agrícolas) podem ser transferidos sempre que o sensor humano faz um percurso de forma a ficar dentro do raio de alcance de um dispositivo SVC, de um SC ou de outro SH para constituir a rede *mesh*. Em outras palavras, os sensores são capazes de localizar outros dispositivos desde que estejam no seu raio de alcance que, no experimento, é de cerca de 200 metros. Geralmente, no final do dia, os SH descarregam os dados no SVC.

A Figura 4 exibe a foto de uma demonstração do dispositivo SVC como o elo central da coleta dos dados via rede *mesh* realizada para produtores de arroz na Tailândia (CI@PracticeDay, 2015).




FIGURA 4 – Demonstração do uso do SVC sobre a representação do sistema CBMa4. O dispositivo SVC aparece sobreposto no centro da nuvem exibida na projeção (CI@PracticeDay).

### 2.3 Posicionamento e percurso dos sensores humanos

Com base na topologia da rede, é definido um grafo  $G = (V, E)$ , onde  $V$  representa o conjunto de SH (nós) e  $E$  (arestas) representa o conjunto de rotas possíveis de comunicação direta entre os SH. Os SH, em um dado instante, estão representados por pontos vermelhos na Figura 5, ou seja, cada ponto representa a posição do agricultor em sua área de cultivo. A localização de cada SH é conhecida por meio de um dispositivo de GPS.




FIGURA 5 – (a) Rede de sensores humanos, num determinado instante, nas áreas de plantio de arroz (direita). (b) Exemplo de um grafo formado por sensores humanos (esquerda). (Cardoso et al, 2015)

De maneira formal, existe uma aresta  $(i, j)$  entre  $SH_i$  e  $SH_j$ , se, e somente se,  $i$  e  $j$  estão dentro de seus raios de alcance. O grafo  $G$  é ponderado de tal maneira que cada aresta  $(i, j)$  está associada ao peso  $\omega_{ij}$  calculado da seguinte forma:

$$\omega_{ij} = \exp(d_{ij}^2)/2\delta^2$$

onde  $d_{ij}$  representa a distância entre os sensores  $i$  e  $j$ , e  $\delta$  representa o limite máximo de comunicação entre os SH. O peso  $\omega_{ij}$  indica o entendimento de quanto fácil ou difícil é a comunicação direta entre dois SH e, conseqüentemente, a complexidade da constituição dinâmica da rede *mesh*.

### 3. Estratégia de Observação para Identificação de Alertas

O processo de coleta de informações de alerta é feito em tempo real de acordo com a mobilidade dos SH e a forma como os agricultores trabalham em seus arrozais. Além disso, os SH podem ser usados para melhorar a compreensão dos alertas e aumentar a confiança na informação passada, tanto para como dos agricultores. Com efeito, se um alerta aparece a partir de, pelo menos, um SC ou SH, uma avaliação de risco é iniciada, a fim de aumentar a

confiança no alerta, especialmente se a confiança é considerada baixa por alguma razão (suspeita de problemas com sensor ou com a coleta do dado, ou “falso-positivo” etc.). Nesses casos, o ambiente CBMa4 solicita ao agricultor, através dos seus dispositivos móveis, que ele se aproxime da área onde houve a observação de modo a obter uma nova observação de acordo com os requisitos CBMa4 e, conseqüentemente, tornar o alerta mais confiável.

As estratégias de melhor da compreensão de alerta ou aumento do grau de confiança do alerta incluem:

- (a) Cada SH (ou “mula de dados”) pode melhorar e transmitir os alertas observados para outro SH mais perto do SVC.
- (b) Cada SH (ou “mula de dados”) pode trocar os alertas observados para serem enriquecidos com outros SH e agregá-los, a fim de economizar largura de banda na comunicação dos dados.

A estratégia de enriquecimento do da compreensão dos alertas pode ser realizada por qualquer um sensor humano ou por um conjunto deles, mas não é tratada no escopo deste artigo. A avaliação de desempenho e otimização de rede *mesh* constituída pelos agricultores está sendo planejada para realizar em futuro próximo.

#### 4. Desafios e Trabalhos Futuros

Este projeto apresenta diversos desafios de pesquisa que podem ser considerados como trabalhos futuros (MOßGRABER et al, 2013). São eles:

- (a) Cada tipo de sensor tem um conjunto de dados em sua memória. Este conjunto de dados pode ser utilizado para melhorar a compreensão e aumentar o grau de confiança sobre os alertas.

Como representar este conjunto de dados? Existe uma álgebra orientada para esta tarefa? Quais são as operações permitidas nesta álgebra?

Como obter a taxa de confiança para um aviso? Devemos usar uma ontologia para caracterizar o risco? Como implementar esta função para dispositivos de recursos limitados?

Como decidir qual a informação a ser enviada, e quais informações devem ser removidas da memória primeiro (quando a memória fica cheia)?

- (b) Os SH podem melhorar a compreensão do processo de antecipação de alertas, pedindo leituras adicionais de outros sensores climáticos ou de outros SH.

Qual subconjunto de dispositivos deve ser solicitado?

Como modelar a consulta se o “nó” observador pode não saber com antecedência que tipo de leitura poderia melhorar o alerta corrente (*warncon*)?

Como encaminhar a consulta para os dispositivos que devem ter se movimentado para longe da zona onde o alerta foi originado? Que informações sobre a topologia da região o agricultor (ou SH) precisa saber para passar para o elo seguinte da rede *mesh*?

O efeito da mudança climática sobre a propagação e gravidade de doenças nas culturas de arroz não é bem conhecida. Lembrando que, de acordo com o ONU, o arroz é o grão mais consumido no mundo pelos humanos (KAWTRAKUL et al, 2008; POISOT, 2004). Com este projeto, os autores esperam reduzir a lacuna de conhecimento através da pesquisa estratégica aplicada. Os cientistas serão capazes de mapear e quantificar o impacto das mudanças climáticas sobre a perda de rendimento das culturas de arroz devido a duas importantes doenças do arroz, predominante na região: mancha foliar bacteriana e rajadas de ar. Eles serão capazes de investigar as interações patógeno-arrozais sob diferentes cenários climáticos e identificar genes de resistência. Os cientistas precisam explorar o conhecimento tácito e nativo sobre doenças no arroz dos agricultores locais e todas as experiências de mudanças climáticas que os agricultores já tenham observado. Assim, os resultados do projeto vão permitir que patologistas de arrozais e produtores rurais identifiquem quais estirpes de agentes patogênicos são, de onde vieram e quando eles ocorreram, e se as mudanças climáticas produzem algum efeito sobre a sua gravidade. Eventualmente, isso pode levar ao desenvolvimento de variedades regionais resistentes a estas cepas de mancha foliar bacteriana e a rajadas de ar, tendo a gestão concomitante com as mudanças climáticas em mente.

## Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, CNPq, e ao Programa Ciência sem Fronteiras (projeto 400730/2012-0) pelo suporte ao projeto de pesquisa. Os autores agradecem também ao *Japan Society for the Promotion of Science*, JSPS, pelo suporte do projeto de pesquisa no Japão (projeto 25540143). Também merece o agradecimento dos autores o apoio dado pela *Kasetsart University* (KU) para realização dos trabalhos de campo.

## Referências

ANDRES, F.; FUKAMI, N. Advanced semantic management of digital resources. In Proceedings of the *International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies*, UBIKOMM'07. IEEE Computer Society, Washington, DC, USA, p. 249- 254, 2007.

DOI=10.1109/UBICOMM.2007.6.

AUBERT, B. A.; SCHROEDER, A.; GRIMAUDO, J. IT as enabler of sustainable farming: an empirical analysis of farmers' adoption decision of precision agriculture technology, *Decision Support System*, v. 54, n. 1, December, p. 510-520, 2012. DOI=10.1016/j.dss.2012.07.002.

CARDOSO Jr., J. L.; ANDRES, F.; GUITTON, A.; KAWTRAKUL, A.; BARBIN, S. E. Collective intelligence-based early warning management for agriculture. *World Academy of Science, Engineering and Technology*, v. 13, n. 2, p. 193-197, 2015. ISSN 1307-6892.

GARDNER-STEPHEN, P.; CHALLAN, R.; LETEMAN, J.; BETTISSON, A.; GARDNER-STEPHEN, D.; LOYD, M. The Serval mesh: a platform for resilient communication in disaster and crisis. *Global Humanitarian Technology Conference*, GHTC/IEEE, San Jose, USA, p. 162-160, 2013.

HAWASHIN, B.; FOTOUHI, F.; GROSKY, W. *Diffusion maps: a superior semantic method to improve similarity join performance*, In Proceedings of the *IEEE International Conference on Data Mining Workshops*, ICDMW'10. IEEE Computer Society, Washington, DC, USA, p. 9-16. DOI=10.1109/ICDMW.2010.77.

HULLERMEIER, E. *Fuzzy sets in machine learning and data mining*. Applied Soft Computing, v. 11, n. 2, March, p. 1493-1505, 2011. DOI=10.1016/j.asoc.2008.01.004.

KAWTRAKUL, A.; PUUSITTIKUL, A.; KHUNTHONG, V.; SUKTARACHAN, M.; IENDEE, S.; LERTSUCHATAVANICH, U.; UJJIN, S. *Development of an Information Integration and Knowledge Fusion Platform for Spatial and Time Based Advisory Services: Precision Farming as a Case Study*. Global Conference SRII. p.241,248, April, 2014. DOI=10.1109/SRII.2014.42.

KAWTRAKUL, A.; SRIWASDI, W.; WUTTILERDCHAROENWONG, S.; KHUNTHONG, V.; ANDRES, F.; LAOVAYANON, S.; JENKOLLOP, D.; NARKWIBOONWONG, W.; PUSITTIGUL, A. *Cyberbrain: towards the next generation social intelligence*. In IAALD AFITA WCC, Tokyo, 24-27 August, 2008.

LOUSANGFA, P.; SAHAVECHAPHAN, N.; BURANARACH, M.; VANNRAT, S.; KAWTRAKUL, A. *Survey and Modeling Metadata Schema Relationship in Agriculture Domain for Better Metadata Schema Service*. In *Proceeding of World Conference on Agriculture Information and IT: IAALD AFITA and WCCA*. Tokyo, Japan. August, 2008.

MOBGRABER, J.; CHAVES, F.; MIDDLETON, S.; ZLATEV, Z.; TAO, R. *The Seven Main Challenges of an Early Warning System Architecture*. In Proceedings of the *10th International ISCRAM Conference*, Baden-Baden, Germany. T. Comes, F. Fiedrich, S. Fortier, J. Geldermann and T. Muller (eds), p. 322-331, 2013.

NASH, E.; DREGER, F.; SCHWARZ, J.; BILL, R.; WERNER, A. Development of a model of data-flows for precision agriculture based on a collaborative research project. *Computer & Electronic Agriculture*, v. 66, n. 1, April, p. 25-37, 2009. DOI=10.1016/j.compag.2008.11.005.

Poisot, A. S. *Good Agricultural Practices – Background paper for the FAO Internal Workshop on Good Agricultural Practices a working concept*. Rome, Italy 27-29 October 2004, revisited version, 2007, 29pp.

SHAH, R. C.; ROY, S.; JAIN, S.; BRUNETTE, W. *Data MULEs: modeling a three-tier architecture for sparse sensor network*. In Proceedings of the *First IEEE International Workshop on Sensor Network Protocols and Applications*, p.30-41, 2003, DOI=10.1109/SNPA.2003.120335.

UN, UNITED NATIONS. *Agriculture and disaster risk: a contribution by the United Nations to the consultation leading to the third UN World Conference on Disaster Risk Reduction*, WCDRR, 2014 (a). Disponível em [www.preventionweb.net/english/professional/publications/v.php?id=38775](http://www.preventionweb.net/english/professional/publications/v.php?id=38775).

UN, UNITED NATIONS. *Sendai framework for disaster risk reduction 2015-2030*. The *third UN World Conference on Disaster Risk Reduction*, WCDRR, 2014 (b). Disponível em [http://www.preventionweb.net/files/43291\\_sendaiframeworkfordrren.pdf](http://www.preventionweb.net/files/43291_sendaiframeworkfordrren.pdf).

UNISDR, UNITED NATIONS OFFICE FOR DISASTER RISK REDUCTION. *Work Programme 2014-2015*. Update, November 2014, 8pp. Disponível em: [www.unisdr.org/we/inform/publications/40896](http://www.unisdr.org/we/inform/publications/40896).