

PUC

ISSN 0103-9741

Monografias em Ciência da Computação

n° 02/2015

Internet das Coisas para Conservação de Frutas: O Caso da Banana

Nathalia Moraes do Nascimento

Carlos José Pereira de Lucena

Hugo Fuks

Departamento de Informática

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO

RUA MARQUÊS DE SÃO VICENTE, 225 - CEP 22453-900

RIO DE JANEIRO - BRASIL

Internet das Coisas para Conservação de Frutas: O Caso da Banana

Nathalia Moraes do Nascimento, Carlos José Pereira de Lucena e Hugo Fuks

nnascimento@inf.puc-rio.br, lucena@inf.puc-rio.br

Abstract. Imagine a device capable of providing in advance an informative perspective on fruit shelf life based on local storage conditions. Also, it is capable of indicating the percentage of fresh fruit losses during transportation between farm and distribution. Through these features, the device makes it possible to monitor the storage period of fruit, between harvest and consumption. In addition, consumers can also monitor fresh fruit at home. Several questions about fruit shelf life can be answered, as follows: (i) Is it better to store fruit in the fridge? (ii) Can I put fruit in closed storages? (iii) If I wash fruit before storing it, will its shelf life decrease? (iv) Does lighting affect ripe fruit? We believe that the shelf life of fruit varies according to conditions of the environment in which it is stored. Therefore, through these information, both quantitative and qualitative losses can be considerably reduced. Our work proposal is to present a device named “Quantified Fruits”. This tool allows monitoring fruit storage and making inferences about it. The “Quantified Fruits” monitors environmental conditions, such as temperature, humidity, lighting and some gases which may affect fruit ripening. In addition, it shares all these data on the Internet. Different stored data about similar fruits share data that will predict how many days it takes for fruit to spoil under specific environmental conditions.

Keywords: Fruit Preservation, Internet of Things, Multi-Agent, “Quantified Things”, “Quantified Bananas”

Resumo. Imagine um dispositivo capaz de medir com antecedência o tempo real de validade de uma fruta de acordo com as condições locais de armazenamento? Ou de indicar a possível porcentagem de perda de carga no transporte de frutas? Com base nessas informações, todo o processo de abastecimento de frutas no mercado poderia ser minuciosamente acompanhado, desde as caixas utilizadas para transporte e distribuição das frutas pós-colheita, quanto aquelas para exposição de frutas em mercados e feiras. Os consumidores também poderiam monitorá-las dentro de casa. Uma série de questões relacionadas ao tempo de conservação de frutas poderiam ser respondidas: (i) É melhor guardar a fruta dentro da geladeira? (ii) Devo deixá-la em um recipiente fechado? (iii) Se eu lavá-la antes de guardar, irá estragar mais rápido? (iv) A luminosidade interfere no amadurecimento da fruta? Entendemos que a real validade de um alimento varia de acordo com o ambiente em que está imerso. E, tendo posse dessa informação, o enorme

desperdício de frutas pós colheita pode ser significativamente reduzido. A proposta deste trabalho, portanto, é apresentar o dispositivo chamado de “Quantified Fruits”. Este dispositivo permite monitorar e realizar inferências sobre o local em que uma fruta está armazenada, disponibilizando as informações na Internet. Para isso, dados do ambiente são monitorados, como a temperatura, umidade, luminosidade e alguns gases que interferem no processo de amadurecimento da fruta. Diferentes estoques de frutas coletam e compartilham esses dados, de modo que um padrão de apodrecimento seja estabelecido, permitindo ao dispositivo quantificar a validade da fruta diante de determinadas condições ambiente.

Palavras-chave: Conservação de frutas, Internet das Coisas, Multi-agentes, “Quantified Things”, “Quantified Bananas”

Responsável por publicações:

Rosane Teles Lins Castilho

Assessoria de Biblioteca, Documentação e Informação

PUC-Rio Departamento de Informática

Rua Marquês de São Vicente, 225 - Gávea

22453-900 Rio de Janeiro RJ Brasil

Tel. +55 21 3114-1516 Fax: +55 21 3114-1530

E-mail: bib-di@inf.puc-rio.br

Web site: <http://bib-di.inf.puc-rio.br/techreports/>

Sumário

Lista de Figuras	iv
Lista de Tabelas	v
1 Introdução	1
1.1 O Caso da Banana	2
1.2 Objetivos	2
1.3 O estado da arte	3
2 Fundamentação	3
2.1 Sistemas Multi-Agentes (SMA)	3
2.2 Redes Neurais Artificiais	4
2.2.1 Neurônio Artificial	4
2.2.2 Algoritmo de Retropropagação (Backpropagation)	6
2.3 A Internet das Coisas e o Arduíno	6
3 Material e Métodos	7
3.1 Características do Ambiente	7
3.1.1 Coleta de Dados	8
3.1.2 Modelo para Coleta, Compartilhamento e Interpretação dos dados	8
3.2 O Experimento com as Bananas	11
3.3 Avaliação Financeira	16
4 Resultados e Discussão	17
5 Conclusões	20
Referências	22

Lista de Figuras

1	Representação do Neurônio Artificial. Fonte: [Haykin, 1994]	5
2	Modelo estrutural de uma rede neural. Fonte: [Haykin, 1994]	5
3	Arduino Uno. Fonte: [Arduino, 2014]	7
4	Lista de sensores utilizado.	8
5	Modelo para gerar aplicações em Internet das Coisas.	9
6	Diagrama de atividades do agente criador.	9
7	Diagrama de atividades do dispositivo.	10
8	Adaptando o modelo para “Quantified Bananas”.	11
9	Camada física do “Quantified Bananas”.	11
10	Portal para “Quantified Things”.	12
11	Camada de aplicação do “Quantified Bananas”.	13
12	Monitoramento de dados e predição de resultados.	14
13	Estado inicial da banana.	14
14	Cenários de simulação.	15
15	Bananas do mesmo cacho situadas em diferentes cenários.	17
16	Diferença de erros entre 100 épocas.	18
17	Conexão de dois novos dispositivos e reconhecimento automático.	19
18	Coleta e inferência automática dos dados. Resultado Positivo.	20
19	Coleta e inferência automática dos dados. Resultado Negativo.	20

Lista de Tabelas

1	Descrição dos experimentos	15
2	Resultados obtidos com os experimentos para treinamento da rede.	17
3	Avaliação da rede pós-treinamento	19

1 Introdução

Uma nova tendência mundial de Mercado está emergindo: a chamada Internet das Coisas (sigla IoT, que significa “Internet of Things” em inglês). Todos os anos, a empresa americana Gartner, líder mundial na pesquisa de tecnologias da informação, publica um boletim de tendências de tecnologias emergentes, as quais têm potencial para um impacto significativo no mercado. No ano de 2014, a Internet das Coisas apareceu no topo da lista [Stamford, 2014].

A proposta da Internet das Coisas é difundir o processamento computacional nos mais diversos tipos de objetos, seja a cadeira do trabalho, o relógio pessoal, o ventilador, a porta de casa, o fogão, a fruteira, entre outros. A ideia é permitir que estes objetos possam estar conectados à internet, coletar dados a respeito do ambiente, disponibilizar e compartilhar essas informações na Internet, e fazer inferências sobre o ambiente. Neste contexto, novas linhas de pesquisa foram surgindo: cidades e casas inteligentes (“Smart cities and houses”), quantificação própria ou de grupos de pessoas (os termos utilizados nesse trabalho serão os originais em inglês: “Quantified Self” e “Quantified Us”) [Jordan and PFARR, 2014].

O “Quantified Self” surgiu com a ideia de permitir às pessoas um autoconhecimento, podendo avaliar a própria saúde e produtividade com base em dados reais. Existem pessoas quantificando o próprio sono, saúde, desempenho esportivo, entre outras coisas [Massaro, 2014]. Para isso, grandes empresas como a Apple [Apple, 2014] e Nike [Nike, 2014], por exemplo, desenvolveram dispositivos que irão permitir pessoas medir e monitorar informações sobre a temperatura, batimento cardíaco e movimentação. E o que seria possível inferir se as pessoas que estão se auto monitorando começassem a compartilhar esses dados entre elas? É com base nessa pergunta, que o “Quantified Us” emergiu. A proposta é que futuramente, por exemplo, uma pessoa com epilepsia consiga prever quando vai ter uma nova convulsão com base no histórico compartilhado por outras pessoas que possuem o mesmo problema [Jordan and PFARR, 2014].

Mas e se utilizássemos os conceitos de “Quantified Us” para quantificar coisas em geral? Dessa forma, ao invés de perguntar “o que **pessoas** conseguem aprender quando compartilham dados entre elas?”, faríamos a pergunta “o que **coisas** conseguem aprender quando compartilham dados entre elas?”.

Neste trabalho, conceituamos essa pergunta como “Quantified Things”. Essas coisas podem ser máquinas industriais, que conseguem prever uma falha. Como também, lagos monitorados, de tal forma, em que medindo o nível de contaminação do lago, seja possível prever o nível de morte de uma determinada espécie. Podem ser plantações de feijão, que compartilham um histórico de experiências para permitir deduzir a taxa de produtividade de uma nova safra de acordo com as condições a que estão expostas. E porquê não, caixas para transporte e/ou armazenamento de alimentos? As quais irão informar a validade real do alimento com base nas condições locais de armazenamento, indicando se são boas ou não para conservar o alimento.

Desenvolvemos um modelo que permite gerar uma família de produtos para “Quantified Things”. O nosso primeiro foco é permitir que este modelo seja utilizado para criar um dispositivo capaz de quantificar o tempo real de validade de frutas de acordo com o local de armazenamento (esse dispositivo é chamado de “Quantified Fruits”), e, posteriormente, de alimentos em geral. O modelo criado permite identificar padrões no histórico de dados compartilhado e preenchido pelos armazenamentos de frutas, de tal forma que, com base em resultados anteriores, consiga fazer novas previsões.

Verificar em quais situações um determinado alimento pode estragar pode diminuir significativamente o problema de desperdício de comida, seja dentro de casa, no comércio ou em transportes para distribuição. E se há redução do desperdício, conseqüentemente poderá haver barateamento do alimento. Essa é uma ideia que, por exemplo, pode ser acoplada à geladeiras, para verificar se os níveis de umidade e temperatura na geladeira estão bons ou não para conservar os alimentos. Da mesma forma que pode ser dentro de uma fruteira, armário ou caixas transportadoras, de tal maneira que aponte quais alimentos dentro delas podem estragar naquelas condições.

1.1 O Caso da Banana

De acordo com o documento do SEBRAE (2008), o desperdício de frutas tropicais é extremamente alto. Devido à fragilidade e à alta perecibilidade das frutas tropicais, em geral, e da banana, em particular, os índices de perda são significativos. No caso da banana, estudos mostram que entre 40 e 60 por cento do volume produzido da fruta é perdido desde a colheita até o seu consumo. Segundo a Fundação Banco do Brasil (2010), a fase de pós colheita chega a ser responsável por 60 por cento das perdas. O desconhecimento das técnicas disponíveis para reduzir as perdas por parte de agentes da cadeia produtiva é a maior causa do desperdício.

As principais causas no atacado são a inadequação das embalagens e do armazenamento, bem como o transporte precário da mercadoria. Já no varejo, acredita-se que os mais sérios problemas associados à perda são o tempo entre a compra e venda da fruta e o manuseio inadequado pelo consumidor. Essas perdas poderiam ser reduzidas com o uso de embalagens adequadas e com a colocação dos frutos em câmaras frias com correta temperatura e umidade relativa controlada [Sebrae, 2008, Brasil, 2010].

Dessa forma, para demonstrar o uso do dispositivo “Quantified Fruits”, o cenário escolhido foi estoques de banana (“Quantified Bananas”). Armazenamentos de bananas do tipo prata compartilham informações afim de prever quantos dias a banana irá estragar nas condições específicas do ambiente. Os dados monitorados de cada armazenamento de banana são: temperatura, umidade, luminosidade e alguns gases, como metano (liberado pela fruta em seu apodrecimento) e hidrogênio.

1.2 Objetivos

O objetivo geral deste trabalho é desenvolver um dispositivo que permita fazer inferências sobre o local de armazenamento de frutas com base em experiências anteriores. As deduções podem ser a respeito do tempo real de validade da fruta e/ou das condições ideais de armazenamento. A princípio, um objetivo específico foi criado, que permitirá encaminhar para soluções gerais posteriormente: prever a data de validade real da banana prata de acordo com as condições de armazenamento. Para alcançar este objetivo específico, as seguintes etapas tiveram de ser executadas:

- Levantar as condições do ambiente que interferem no processo de apodrecimento da banana
- Definir os sensores que devem ser utilizados para auxiliar na coleta de dados
- Elaborar um modelo que permita:

- Reconhecimento dos dispositivos no ambiente;
 - Comunicação com dispositivos para coleta das condições ambientais;
 - Compartilhamento de dados na internet;
 - Processamento e interpretação dos dados; e
 - Adaptação à resultados inesperados
- Elaboração da base de dados contendo o histórico de experimentos com armazenamento de bananas;
 - Treinamento do sistema para reconhecimento de padrões;
 - Execução e análise de resultados.

1.3 O estado da arte

Algumas pesquisas na área de Internet das Coisas já vêm sendo desenvolvidas nas universidades e indústrias brasileiras. Porém, grande parte delas estão focadas em resolver questões operacionais, a exemplo de protocolos de comunicação.

Um dos domínios muito pouco abordado na Internet das Coisas, tanto no Brasil, quanto no mundo, é o da alimentação. No mundo, as pesquisas de maior destaque até então, são a da Philips [Philips, 2014] e o de um estudante de Design da Universidade de Brunel, em Londres [Dailymail, 2013]. A idéia da Philips é utilizar a Internet das Coisas para mudar a forma como o consumidor interage com a comida exposta à venda. Já o segundo projeto, discute uma fruteira inteligente, que monitora os gases liberados pelas frutas, para informar se as frutas estão começando a estragar ou não. Diferente do nosso, onde uma das propostas é fornecer essa informação com antecedência, permitindo que a pessoa tome uma atitude para intervir na previsão.

2 Fundamentação

Este tópico traz uma breve fundamentação dos principais temas abordados neste trabalho, com o intuito de auxiliar no entendimento do próximo capítulo, Material e Métodos. Os temas são Sistemas Multi-Agentes, Redes Neurais Artificiais, Backpropagation e Arduíno.

2.1 Sistemas Multi-Agentes (SMA)

A área de Sistemas Multi-Agentes (SMA) é uma síntese das áreas de Inteligência Artificial, Engenharia de Software e Computação Distribuída. A tecnologia de Sistemas Multi-Agentes (SMAs) é uma abordagem promissora para o desenvolvimento de aplicações em domínios complexos e distribuídos. O agente é uma abstração que permite usufruir das seguintes propriedades [Lucena and Nunes, 2013]:

- Autonomia: agentes operam sem intervenção humana ou de qualquer tipo de controle;
- Sociabilidade: agentes podem interagir uns com os outros, e também com humanos;
- Reatividade: os agentes percebem e interagem com o ambiente à sua volta;

- Pró-atividade: os agentes não só respondem ao ambiente à sua volta, como também agem com proatividade.

A tecnologia de agentes pode trazer vantagens para vários domínios de aplicação através da condução de experimentos (ex.: medicina, telecomunicações e simulação de meio-ambiente). Apesar de existirem muitos casos de sucesso de utilização da tecnologia de agentes, que já estão contribuindo substancialmente para diversas áreas de negócio e indústria, ainda há muita pesquisa e desenvolvimento a serem feitos para que todos os benefícios desta tecnologia sejam alcançados.

Alguns experimentos desenvolvidos utilizando MAS podem ser bastante complexos. Uma alternativa que tem se utilizado bastante para reduzir ou evitar essa complexidade, é atribuir aos agentes a capacidade de aprender, fazendo uso de algumas técnicas de Aprendizado de Máquina, a exemplo de redes neurais e os algoritmos de retropropagação. Para mais informações sobre sistemas multiagentes, ver [Lucena and Nunes, 2013].

2.2 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são frequentemente utilizadas para detectar tendências que são complexas para serem percebidas pelos seres humanos. RNAs são especialmente usadas para encontrar soluções genéricas para problemas onde um padrão de classificação precisa ser extraído [Tissot et al.].

2.2.1 Neurônio Artificial

Um neurônio artificial é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. A Figure 1 mostra o modelo de um neurônio, que forma a base para o modelo de Redes Neurais Artificiais. Neste modelo são identificados três elementos básicos do modelo neural [Haykin, 1994]:

- Um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso ou força própria. Especificamente, um sinal X_m na entrada da sinapse m conectada ao neurônio k é multiplicado pelo peso sináptico W_{km} ;
- Um somador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio;
- Uma função de ativação para restringir a amplitude de saída do neurônio. A função de ativação também é referida como função restritiva, já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito. Tipicamente, o intervalo normalizado da amplitude de saída de um neurônio é escrito como um intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

A rede neural pode incluir também um bias aplicado externamente, representado por b_k . O bias b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é negativo ou positivo, respectivamente, além de assegurar que o valor de saída da função de ativação seja diferente de zero, mesmo quando todas as entradas são [Haykin, 1994].

Uma rede neural artificial é um arranjo entre neurônios artificiais. A Figure 2 representa um modelo estrutural de uma rede neural. A forma como esse arranjo é organizado

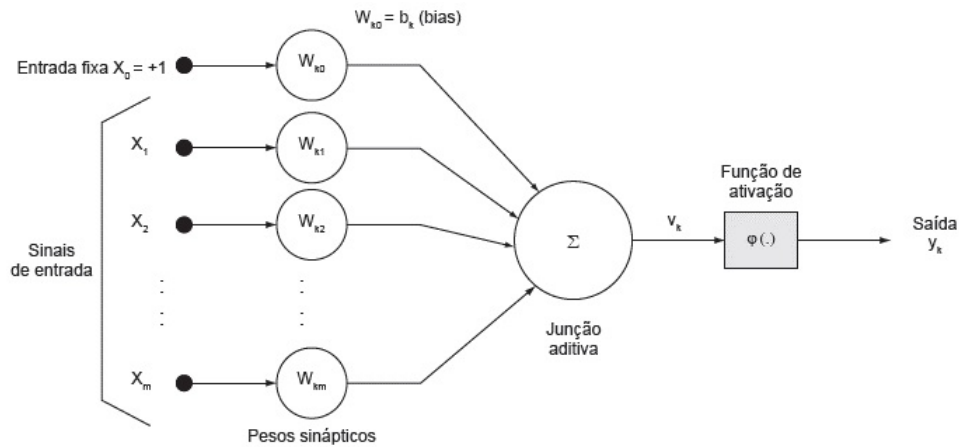


Figura 1: Representação do Neurônio Artificial. Fonte: [Haykin, 1994]

dá margem à criação de diferentes tipos de redes neurais. As redes perceptron multicamadas, por exemplo, são redes “feedforward” constituídas por:

- Uma camada de entradas: onde os padrões são apresentados à rede;
- Pelo menos uma camada neural escondida: Estes neurônios ocultos capacitam a rede a aprender tarefas complexas extraindo progressivamente as características mais significativas dos padrões de entrada;
- Uma camada neural de saída: onde o resultado final é apresentado.




Figura 2: Modelo estrutural de uma rede neural. Fonte: [Haykin, 1994]

As redes perceptron de múltiplas camadas tem sido comumente empregadas como aproximador universal de funções; reconhecimento de padrões; previsão de séries temporais; identificação de sistemas e controle; e processamento de imagens.

O modelo de cada neurônio deste tipo de rede inclui uma função de ativação não-linear. Uma função normalmente utilizada de não-linearidade que satisfaz esta exigência é a função sigmóide [Haykin, 1994]:

$$y_k = \frac{1}{(1 + e^{-v_k})}; \quad (1)$$

onde v_k é a soma ponderada de todas as entradas sinápticas acrescidas do bias no neurônio k e o y_k é a saída do neurônio.

2.2.2 Algoritmo de Retropropagação (Backpropagation)

As redes neurais artificiais são modeladas para categorizar dados de entrada, devendo passar por um processo de aprendizagem para que seu desempenho seja melhorado. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos. O aprendizado ocorre quando a rede neural encontra uma solução generalizada para uma classe de problemas.

O aprendizado pode se dar por uma forma supervisionada ou não-supervisionada. No modo supervisionado, o ajuste de pesos é feito a partir de uma comparação da saída da rede com a resposta desejada para um padrão de entrada. No caso do aprendizado não-supervisionado, não existe indicações de respostas.

Um algoritmo comumente utilizado para treinar redes neurais do tipo perceptron, de forma supervisionada, é o de retropropagação de erro ("error back-propagation"). Basicamente, a aprendizagem por retropropagação de erro consiste de dois passos através das diferentes camadas da rede: um passo para a frente, a propagação, e um passo para trás, a retropropagação. No passo para frente, um padrão de entrada é apresentado a rede, e se propaga camada por camada. Nesta etapa do aprendizado, todos os pesos sinápticos são fixos. Já durante o passo para trás, os pesos sinápticos são todos ajustados de acordo com uma regra de correção de erro.

Especificamente, a resposta real da rede é subtraída de uma resposta desejada para produzir um sinal de erro. Este sinal de erro é então propagado para trás através da rede, contra a direção das conexões sinápticas. Os pesos sinápticos são ajustados para fazer com que a resposta atual da rede se aproxime da resposta desejada, em um sentido estatístico.

Define-se como uma época a apresentação de N padrões de entrada para o treinamento da rede. Ao final de uma época, todo o conjunto de treinamento que irá ser processado é apresentado a rede. Os ajustes dos pesos são realizados de acordo com os respectivos erros calculados para cada padrão apresentado.

Para finalizar o processo de treinamento, um critério de parada deve ser estabelecido. Uma forma é definir o número de épocas que deverão ser executadas. Outra forma é estabelecendo uma taxa mínima de variação do erro quadrático médio (EQM) entre duas épocas subsequentes, pois de acordo com Haykin (1994), "considera-se que o algoritmo de retropropagação tenha convergido quando a taxa absoluta de variação do erro quadrático médio por época for suficientemente pequena". Neste caso, basta adicionar ao algoritmo de retropropagação um valor de precisão, que interrompa o treinamento da rede quando esta apresentar uma taxa de variação do erro quadrático médio menor do que este valor.

Para mais informações sobre redes neurais, o algoritmo de retropropagação e outros algoritmos de aprendizado, ver [Haykin, 1994].

2.3 A Internet das Coisas e o Arduíno

A tendência, prevista pelas pesquisas da empresa Gartner [Stamford, 2014], é que a Internet das Coisas seja uma das maiores revoluções tecnológicas dos últimos anos. Cada

vez mais, haverão objetos conectados à Internet, podendo ser monitorados e controlados de forma autônoma, mudando totalmente o foco na computação centralizada para a distribuída.

E o que está auxiliando na realização deste paradigma é a fascinante emergência de microcontroladores de baixo custo e de alto potencial para conectar à Internet. Eles que são a chave para a Internet das Coisas, onde vários tipos de dispositivos se tornarão a interface da Internet com o mundo físico [Pfister, 2011].

É possível notar também uma popularização desses microcontroladores, não só pelo preço, mas também pela facilidade que vem sendo proporcionada para utilizá-los. Um dos dispositivos que encabeçou essa tendência foi o Arduino, promovendo sua plataforma para prototipagem eletrônica com base no Hardware Livre (se referindo aos princípios do Softwares Livre - para mais informações, ver [Jaeger and Metzger, 2002]). A Figura 3 traz uma foto do Arduino Uno, o dispositivo que está sendo utilizado neste trabalho.




Figura 3: Arduino Uno. Fonte: [Arduino, 2014]

3 Material e Métodos

A metodologia empregada neste trabalho transcorre de acordo com as etapas levantadas para alcançar o objetivo citado.

3.1 Características do Ambiente

O primeiro passo foi realizar um levantamento das condições que interferem no processo de amadurecimento da fruta pós-colheita. Existem as condições relacionadas ao estado da banana no momento da colheita e aos fatores ambientais. Em relação ao estado da banana, os fatores relevantes são, por exemplo, a forma como o cacho é retirado, se a banana possui lesões na casca e se ainda está verde. Já os fatores ambientais que interferem são a temperatura, umidade relativa, a presença de outra fruta madura ou podre no mesmo recipiente (produzindo os gases etileno e metano), teor de oxigênio e dióxido de carbono [Boe and Salunkhe, 1967]. Outro fator considerado neste trabalho é a luminosidade, apesar de não ter encontrado trabalhos que comprovassem o relacionamento deste fator com o processo de amadurecimento das frutas pós-colheita [Miller and Schomer, 1947, Mpelkas and Kenyon, 1972].

3.1.1 Coleta de Dados

Alguns desses fatores são mais complicados de serem medidos, e, por isso, a princípio, não foram utilizados nesse trabalho. Apesar de poderem interferir nos resultados dos experimentos, os fatores relativos ao estado da banana foram desconsiderados. Para automatizar a coleta desses dados, um módulo para processamento de imagens deveria ser acoplado ao dispositivo, de forma a identificar a cor e machucados da banana.

Já os demais fatores foram selecionados de acordo com os recursos disponíveis no mercado brasileiro para medi-los (ver Figura 4). Para isso, foi utilizado um sensor de temperatura e umidade relativa de alta precisão, um sensor de luminosidade (permitindo detectar se a fruta está em um recipiente fechado ou não, por exemplo), um sensor de gás metano (gás liberado pela fruta podre) e um de gás hidrogênio.



Figura 4: Lista de sensores utilizado.

3.1.2 Modelo para Coleta, Compartilhamento e Interpretação dos dados

Como foi dito anteriormente, desenvolvemos um modelo que permite gerar várias aplicações em Internet das Coisas, inclusive para “Quantified Things”. Dessa forma, primeiramente iremos apresentar o modelo e os conceitos envolvidos em sua concepção, e, posteriormente, as adaptações realizadas para desenvolver o dispositivo para quantificar bananas.

O modelo citado é apresentado na Figura 5. Ele prevê o reconhecimento automático de dispositivos em diferentes ambientes; a comunicação de aplicações com esses dispositivos, de forma que possa receber os dados coletados; processamento e interpretação dos dados; e adaptação à resultados inesperados. Este modelo é totalmente baseado nos paradigmas da Inteligência Artificial, como sistemas multiagentes e redes neurais.

O modelo define três camadas para desenvolver o produto: a física, a de comunicação e a de aplicação. Cada dispositivo (coisa) no ambiente (camada física) pode ser controlado por um agente inteligente (agente adaptativo). Esta comunicação entre um agente e seu respectivo dispositivo ocorre através da Internet. Cada dispositivo possui um endereço (ip), disponibilizando os dados coletados a partir dele. Assim, o agente pode acessar este endereço e manipular as informações necessárias.

A aplicação é baseada no desenvolvimento de três tipos de agentes: (i) agente criador; (ii) agente adaptativo; e (iii) agente observador. A principal função do agente criador é detectar os novos dispositivos que estão tentando se conectar ao sistema. Para cada um deles, o agente criador cria um novo agente adaptativo, que ficará responsável por controlar e manipular seus dados. Dessa forma, o agente criador permite uma conexão automática dos dispositivos ao sistema, excluindo a necessidade de configurações manuais. Essas atividades são claramente apresentadas no diagrama da Figura 6.

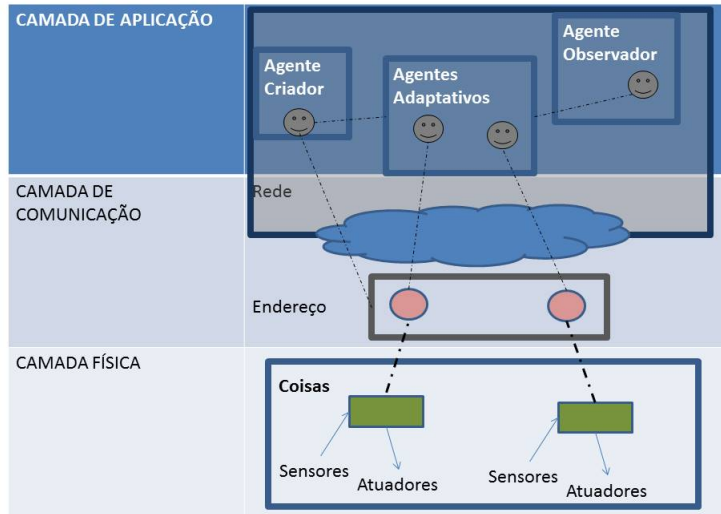


Figura 5: Modelo para gerar aplicações em Internet das Coisas.

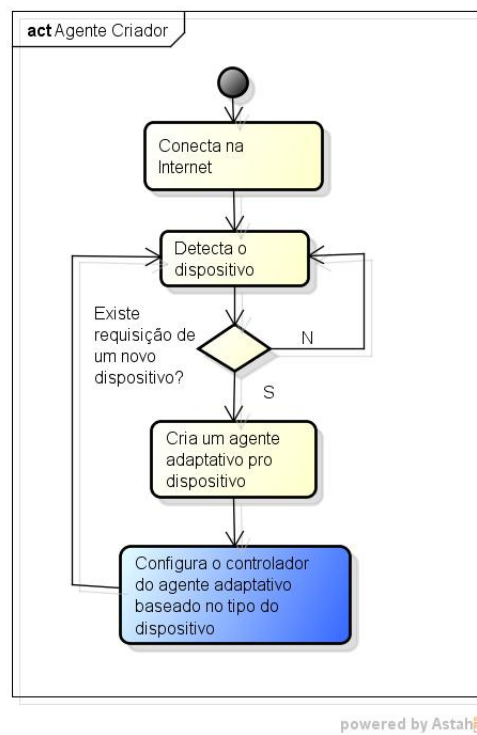


Figura 6: Diagrama de atividades do agente criador.

Cada agente adaptativo executa uma sequência de três atividades: (1) coletar os dados dos dispositivos; (2) tomar decisões; e (3) agir. A tarefa de coleta de dados consiste em ler e interpretar os dados dos dispositivos. As decisões tomadas pelos agentes são processadas em seu controlador, o qual pode ser uma rede neural. A saída do controlador varia de

acordo com os dados coletados, e essa informação é utilizada para determinar as ações a serem executadas. Essas ações podem ser atividades como enviar mensagem para outros agentes, definir a(s) saída(s) do dispositivo, a exemplo de um sinal de alarme.

Existe também um agente observador, como é mostrado na Figura 5. Este agente é responsável por avaliar as ações executadas pelos agentes adaptativos. Ele faz isso com o intuito de verificar se o agente adaptativo necessita passar por um processo de adaptação ou não. Quando as saídas dos agentes estão longe do que era esperado, um método de aprendizado é executado, a exemplo do de retropropagação, apresentado na seção 2.2.2.

O processo de adaptação consiste em gerar novas configurações para o controlador dos agentes adaptativos e testar como eles irão se comportar no ambiente após a mudança. A configuração usada quando os agentes apresentam um comportamento desejado é escolhida para controlar os agentes durante a execução do sistema.

Já que os agentes têm uma sequência de passos a serem seguidos, para que um dispositivo faça uso desse modelo, ele deve ser desenvolvido de acordo as atividades apresentadas no diagrama da Figura 7.

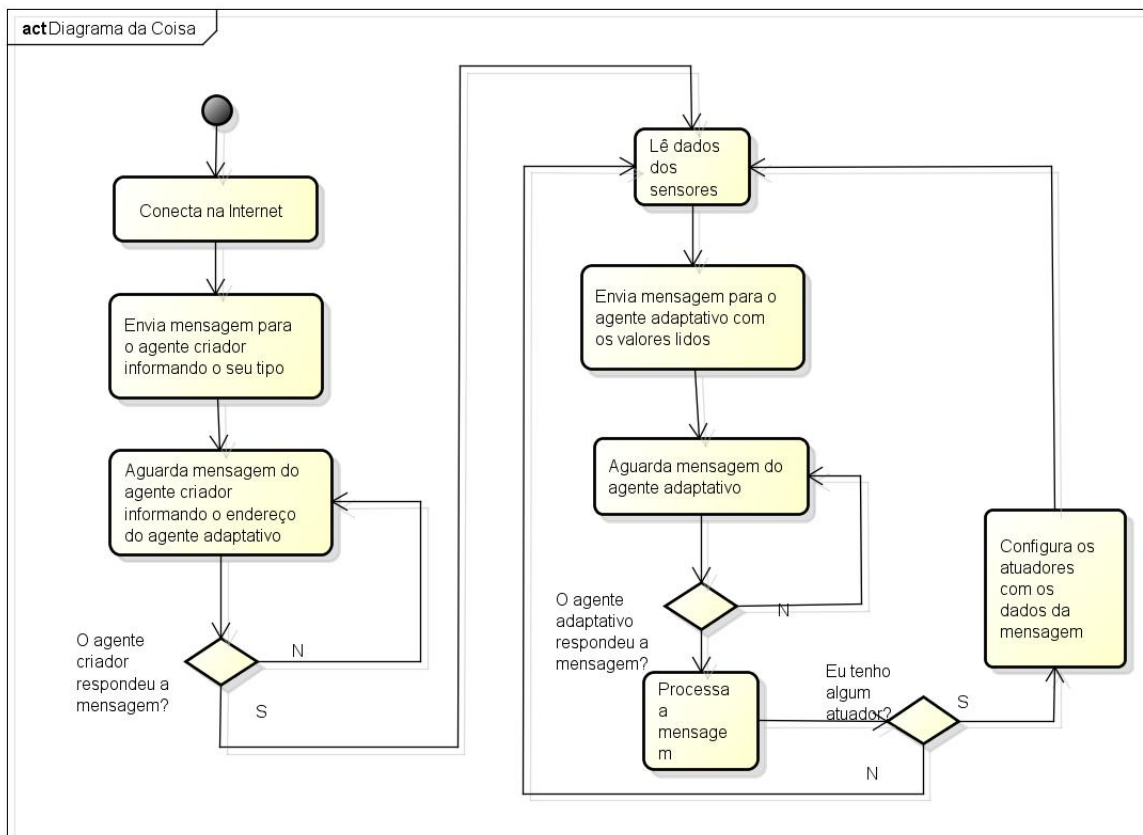


Figura 7: Diagrama de atividades do dispositivo.

Dado o modelo, o próximo passo é adaptá-lo para criar os dispositivos que irão permitir quantificar bananas. As aplicações baseadas em quantificação, no geral seguem a proposta apresentada na Figura 8. Dispositivos em diferentes locais são monitorados por agentes distintos. Por sua vez, esses agentes ajudam a montar um histórico de dados coletados

e resultados obtidos, que fica disponível na nuvem e compartilhado entre eles. Novos agentes que se conectam, podem acessar os dados do histórico e fazer inferências sobre as condições do dispositivo que está monitorando.

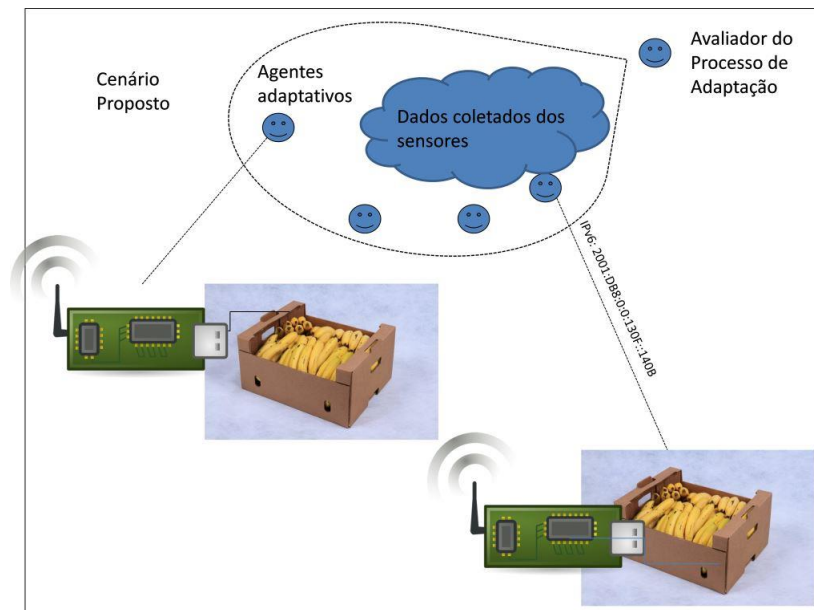


Figura 8: Adaptando o modelo para “Quantified Bananas”.

3.2 O Experimento com as Bananas

Como já foi dito, o modelo utilizado por esse sistema prevê a construção de três camadas: a física, de comunicação e de aplicação. Como não há necessidade de alterar a camada de comunicação para construir esse sistema, ela não será mais abordada.

A Figura 9 representa a camada física do sistema para “Quantified Bananas”. Ela constitui em uma caixa de papelão contendo uma banana ou mais, e o nosso dispositivo. Esse dispositivo é composto pelos sensores levantados no subtópico anterior, por leds vermelhos, que são utilizados para sinalizar uma situação crítica de armazenamento, e do Arduino. O Arduino permitirá o envio dos dados sensorados para a Internet.



Figura 9: Camada física do “Quantified Bananas”.

Um outro componente que será integrado à camada física em um próximo protótipo do dispositivo será o cooler (normalmente utilizado para resfriar componentes eletrônicos). Ele será usado para permitir à caixa de armazenamento que não só dê sugestões ao usuário,

mas que também seja autônoma para realizar ações no momento que as achar necessárias (exemplo: o dispositivo detectou um padrão que diz que em determinados valores de umidade e concentração de gases, a temperatura deve ser 20°C. Então, o dispositivo, sem precisar de intervenção humana, irá acionar o cooler para que essa temperatura seja alcançada).

O próximo passo é definir a camada de aplicação. Nesta camada é preciso estabelecer quais informações serão inferidas e os dados que são importantes para mostrar aos usuários. No caso das frutas em geral, a priori, estabelecemos que o sistema deveria permitir ao usuário monitorar o ambiente através de um aplicativo e inferir sobre a real data de validade. Mostrando a quantidade de dias previstos para a fruta estragar em determinada situação, espera-se que esta informação auxilie o usuário à encontrar meios de prolongar a durabilidade da fruta.

Futuramente, o aplicativo será adaptado para que sejam feitas análises específicas sob os fatores monitorados. Por exemplo, deseja-se que o sistema esteja apto a sugerir as mudanças que devem ser feitas para estender o prazo de conservação da fruta em ambientes específicos (exemplos de sugestões: diminua a temperatura em 5° e coloque em um ambiente de umidade relativa 70; retire a fruta podre que está na caixa).

Criamos um portal online, que ainda está em fase de construção, para concentrar aplicações em “Quantified Things” [Nascimento, 2014]. A ideia é facilitar o uso do dispositivo que estamos propondo neste trabalho e mostrar que esses conceitos podem ser facilmente estendidos para outros experimentos e domínios de aplicação.

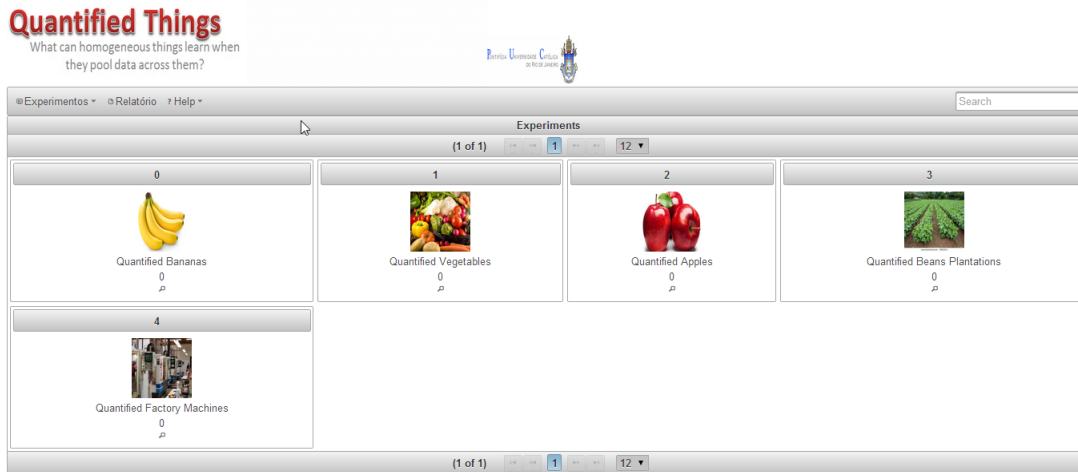


Figura 10: Portal para “Quantified Things”.

A Figura 11 apresenta o controlador cadastrado para experimentos em “Quantified Bananas”. Ele que será utilizado pelos agentes adaptativos para tomarem as ações necessárias. Neste caso, a ação esperada é que o sistema informe a validade real da banana de acordo com os fatores ambientais.

Como são diversos os fatores que interferem no amadurecimento da fruta, de forma dependente, é difícil encontrar um padrão que os correlacione. Sabe-se, por exemplo, que não é só a temperatura que atua, mas a relação da temperatura com a umidade relativa e com o gás etileno. Por isso escolhemos o uso de redes neurais artificiais. As redes

neurais são massivamente utilizadas para mapear sistemas complexos, sem a necessidade de conhecer eventuais modelos matemáticos que descrevam o seu comportamento. É como se a rede neural encontrasse uma função que provesse uma relação satisfatória entre os fatores do ambiente e o prazo de validade. Ela também permite identificar a relevância das entradas para o resultado obtido, visto que os pesos definem o quanto uma determinada entrada contribui para a saída.

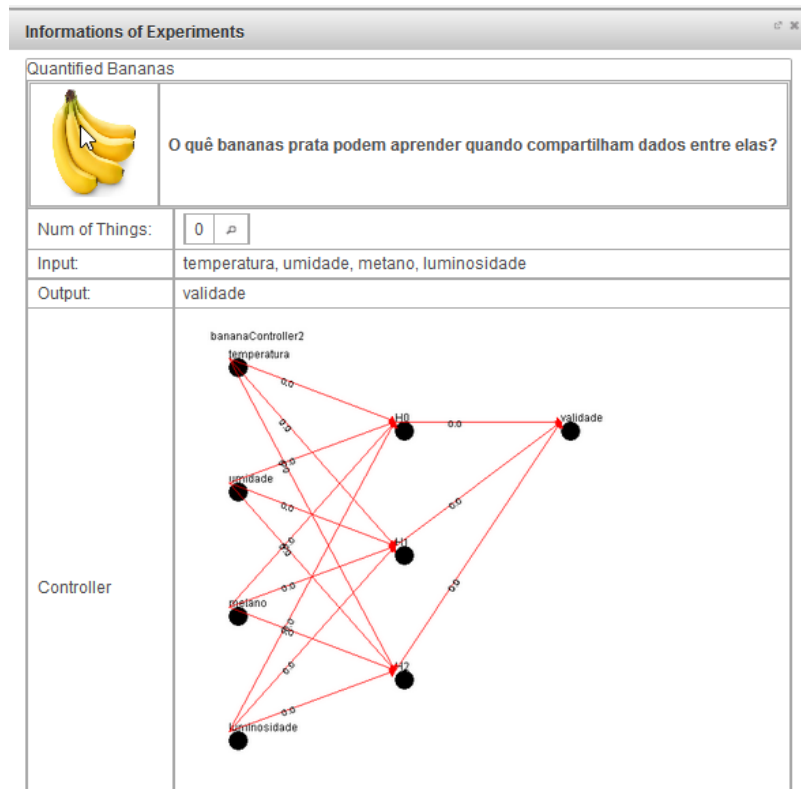


Figura 11: Camada de aplicação do “Quantified Bananas”.

Ao seleccionar um dos experimentos, é possível acompanhar os dispositivos conectados, monitorando os dados e os resultados previstos, conforme ilustrado na Figura 12.

Elaboração da base de dados para treinamento da rede

A proposta do “Quantified Things” é prever resultados com base em um histórico de experiências prévias. Alguns sites disponibilizam uma série de bases de dados (“datasets”) para as mais variadas medições (a maioria concentrada em questões de saúde) [UCI, 2014]. Porém, não foi encontrado nada que estivesse correlacionado a validade de alimentos. Assim, o maior desafio deste trabalho foi desenvolver a base de dados, pois foi necessário criar uma série de experimentos para poder montar um histórico inicial.

Esse é um dos motivos para que o modelo criado permitisse adaptação em tempo de execução. À medida que as bananas vão sendo monitoradas, a base de dados vai sendo montada e o controlador vai se adaptando de acordo com os resultados obtidos. Se a previsão é de que a fruta estrague em cinco dias, e o usuário informa que ela estragou

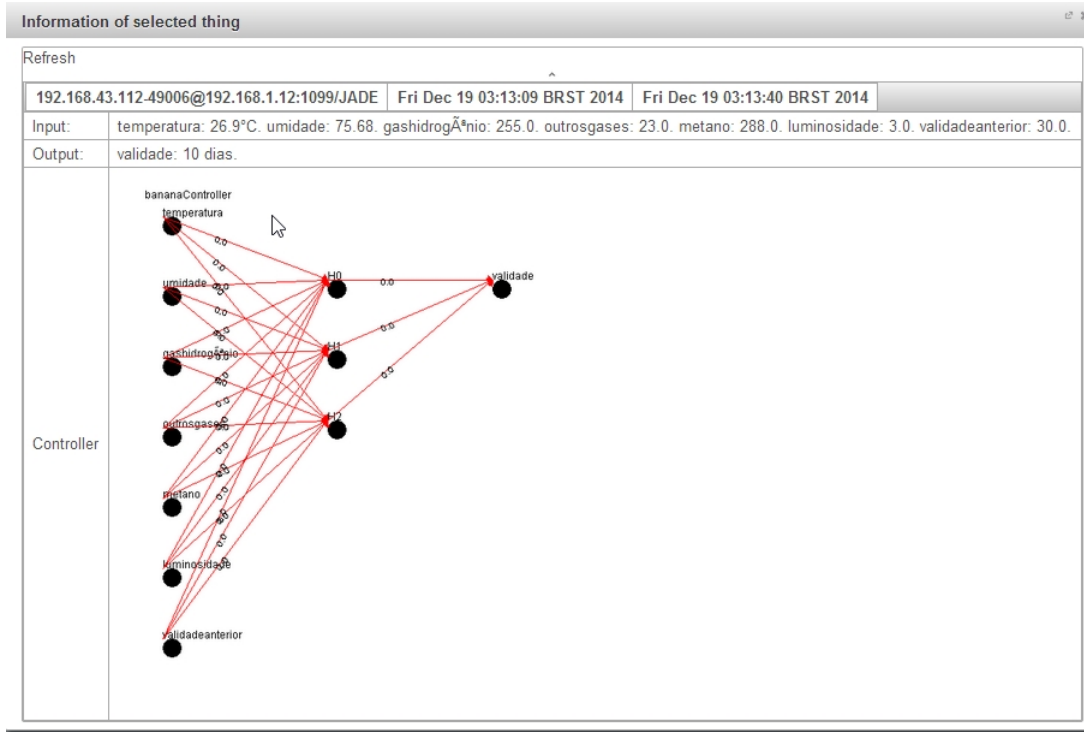


Figura 12: Monitoramento de dados e previsão de resultados.

em três dias, a rede neural automaticamente vai passar por um processo de adaptação, permitindo que essa falha seja corrigida.

Dentre os inúmeros cenários possíveis beneficiados pelo conceito de quantificação, essa também é a principal justificativa pela escolha inicial de trabalhar com bananas. Por ser uma fruta tropical e com menor tempo de conservação, permite medir a sua fase de amadurecimento em tempo hábil. Dessa forma, foi possível realizar a simulação de mais de dez experimentos para o apodrecimento de bananas em menos de três meses.

Dez desses experimentos foram utilizados para elaborar a base de dados para o treinamento inicial do sistema. Como os fatores físicos da banana que interferem no processo de amadurecimento não foram medidos, houve um cuidado em escolher dez bananas similares para utilizar nos diferentes cenários de teste. A Figura 13 mostra o estado físico da banana ao início de cada execução.



Figura 13: Estado inicial da banana.

Os cenários foram montados de acordo com a combinação de quatro fatores: se a caixa está aberta ou não, se a banana está dentro ou fora da geladeira, se há a presença de outras frutas, que já estejam maduras ou podres. A Tabela 1 e a Figura 14 apresentam as configurações realizadas para gerar os dez cenários de simulação.

Tabela 1: Descrição dos experimentos

<i>Experimento</i>	<i>Caixa fechada</i>	<i>Na geladeira</i>	<i>Com banana podre</i>	<i>Com banana madura</i>
1				
2				X
3			X	
4			X	X
5	X			
6	X			X
7	X		X	X
8	X		X	
9	X	X	X	
10		X	X	



Figura 14: Cenários de simulação.

Para cada um desses experimentos, serão realizadas medições pontuais no momento em que cada experimento for iniciado. Os valores de entrada medidos serão temperatura, umidade, gás hidrogênio, metano e luminosidade. Já para a saída será a quantidade de dias que a banana levou para estragar.

O parâmetro considerado para indicar se a banana estragou ou não será a cor da casca da banana (se preta). Mais uma vez, é preciso dizer que essa indicação será realizada a partir de observação humana, não podendo, portanto, garantir uma precisão dos resultados.

Treinamento do sistema para reconhecimento de padrões

Só de olhar para a Tabela 1 como um todo, que considera apenas quatro situações, já é possível perceber o quão difícil é encontrar um padrão de validade que considere a relação entre esses itens.

Dessa forma, tentando identificar este padrão, foi utilizada uma rede neural “feed-forward” para ser treinada de acordo com as entradas e saídas a serem apresentadas. Quanto maior a base de treinamento, mais precisa poderá ser a rede. Essa rede neural é composta de três camadas: a de entrada, com cinco neurônios (um para cada entrada), a intermediária com três neurônios e a de saída, com um único neurônio.

O processo de treinamento dessa rede será realizado fazendo uso do algoritmo de “back-propagation”. Para isso, foi estabelecido uma diferença mínima de erro entre as iterações, de forma que os pesos sejam ajustados até que essa condição seja atendida.

Assim que esteja concluída a etapa de treinamento, a Rede estará apta para realizar o processamento dos dados de entrada que será realizado logo na sequência. E o sistema será capaz de continuar se adaptando durante a fase de execução. Caso um dos resultados previstos não saia como o esperado, o produtor da banana poderá informar o erro de previsão, e o sistema se auto adaptará para se adequar aos novos resultados. Dessa forma, o treinamento continua mesmo quando o dispositivo já estiver em uso. Isso viabiliza também a adaptação do sistema para caso novos fatores venham a ser considerados posteriormente.

Execução e análise de resultados

Após a fase de treinamento, dois novos cenários foram escolhidos para teste: um em que a banana é colocada em uma caixa aberta, sob o sol; e outro em que a banana é colocada em uma caixa fechada dentro da geladeira. Para esses dois novos e para os experimentos da fase de treinamento, a rede será executada no intuito de medir a sua taxa de porcentagem de erros.

Em certos casos, uma determinada topologia pode ter desempenho satisfatório no treinamento (menor erro relativo), mas durante a fase de execução produzir resultados insatisfatórios.

3.3 Avaliação Financeira

Este tópico foi adicionado à este documento afim de fornecer informações de custo para o desenvolvimento do protótipo. O objetivo é mostrar a viabilidade de implantação do produto não só à nível de funcionalidades, como também financeira.

Os preços apresentados são condizentes aos de lojas autorizadas dentro do país:

- Arduino com conexão wi-fi embutida: R\$300
- Dois sensores de gás: R\$60,0
- Sensor de temperature e umidade de alta precisão: R\$50
- Nossa plataforma online para “QuantifiedThings”: Gratuito

Estes preços podem ser reduzidos com a adoção de tecnologias menos modernas, mas que exigem maior conhecimento em eletrônica.

4 Resultados e Discussão

A Tabela 2 apresenta as medições e resultados apresentados para cada um dos experimentos indicados na Tabela 1. Foram realizadas medições pontuais no momento em que cada experimento foi iniciado. Os resultados poderiam ser mais precisos se dados fossem coletados continuamente ao longo do tempo, já que todos os fatores apontados estão suscetíveis às condições do ambiente, que são variáveis. Porém, por questões práticas, preferimos considerar as variações abruptas de medidas, que estão relacionadas aos quatro fatores já indicados (por exemplo, se está dentro ou fora da geladeira).

As medidas de hidrogênio, metano e luminosidade estão sendo representadas pela voltagem (V.) de saída do sensor. Para processamento da rede neural, não foi necessário converter esses valores para as correspondentes grandezas, a exemplo de partes por milhão (ppm), grandeza comumente utilizada na medição de gases.

Tabela 2: Resultados obtidos com os experimentos para treinamento da rede.

<i>Experimento</i>	<i>Temperatura(°C)</i>	<i>Umidade (H)</i>	<i>Hidrogênio(V.)</i>	<i>Metano(V.)</i>	<i>Luminosidade(V.)</i>	<i>Dias</i>
1	27.62	70.22	2	184.0	15.0	14
2	27.59	70.39	9	231.0	10.0	12
3	28.02	72.53	8	275.0	10.0	5
4	27.92	72.67	19.0	271.0	5.0	5
5	27.81	72.75	3.0	258.0	3.0	10
6	27.74	71.35	15.0	262.0	3.0	9
7	28.26	73.23	18.0	309.0	3.0	3
8	28.69	71.75	7.0	316.0	4.0	3
9	27.77	59.89	5.0	411.0	2.0	4
10	25.86	70.08	5.0	331.0	40.0	6

A última coluna da Tabela 2 indica a quantidade de dias que a banana levou para estragar em cada um dos dez cenários. A Figura 15 aponta bananas do mesmo cacho que foram situadas em diferentes cenários. Nesta situação, a banana que foi colocada em uma caixa fechada já encontrava-se estragada, enquanto que aquela da caixa aberta, não. A segunda banana levou mais quatro dias para estragar.



Figura 15: Bananas do mesmo cacho situadas em diferentes cenários.

À medida em que os experimentos vão sendo executados já é possível observar acontecimentos peculiares e ir identificando alguns padrões para amadurecimento das frutas. Nos experimentos 4 e 7, por exemplo, em que há contato de uma fruta madura com uma fruta podre, é possível observar a mudança na produção de gás hidrogênio de forma significativa, o que pode estar relacionado com a aceleração na produção de etileno. Porém, não é de nosso interesse, neste trabalho, fazer observações experimentais, visto que nossa

proposta é automatizá-las a partir do uso de redes neurais.

Inicialmente, a entrada de dados foi realizada através de um arquivo texto composto pelas seis colunas da Tabela 2, contendo os dados citados anteriormente mais o valor esperado da Rede. Fazendo uso apenas dos dez padrões de entrada da Tabela 2, a rede neural *feedforward* foi treinada inicialmente por cem épocas e conseguiu obter um erro quadrático médio de 0.1 (o que ainda não é bom). A Figura 16 apresenta a diferença do erro quadrático médio entre essas iterações.




Figura 16: Diferença de erros entre 100 épocas.

Como os pesos gerados inicialmente são aleatórios, em certas ocasiões é necessário que esses pesos passem por mais adaptações para alcançar o valor desejado, o que implica em uma maior execução de épocas para se obter o EQM ideal. E devido ao erro produzido inicialmente poder ser bastante elevado, após as alterações de pesos, as variações de EQM são feitas de forma mais abrupta, ou seja, apesar de alcançar valores muito pequenos de EQM, a variação que acontece entre EQMs de épocas consecutivas acontece de forma elevada.

Então, uma forma mais indicada para treinamento é definindo a diferença mínima permitida entre os erros calculados de duas iterações seguidas. Nesse caso, foi definido a diferença mínima de 0,0001 (10^{-4}). Estamos definindo que ao encontrar essa diferença mínima, já seja possível parar o treinamento atual. Dessa forma, diante do conjunto de dados disponível, estamos considerando que não seja mais possível encontrar uma solução que seja distintamente melhor do que a já encontrada. Foi necessário executar mais de cinco milhões de épocas (5.310.561) para alcançar a diferença de erro de (10^{-4}).

Os experimentos de treinamento foram reexecutados para agora avaliar a taxa de acertos da rede. Esses resultados são apresentados na Tabela 3 e os valores utilizados são de acordo com a normalização feita com os dados da rede.

Somente três dos resultados deram valores praticamente nulos (experimentos 1, 9 e 10). Mas somente dois experimentos ficaram com valor de erro acima do esperado, que foram os experimentos 4 e 6. As características em comum desses experimentos é que ambos estão fora da geladeira e com uma banana já madura dentro da caixa. Uma possível forma de solucionar isso é realizar mais experimentos envolvendo uma banana já madura dentro da caixa.

Tabela 3: Avaliação da rede pós-treinamento

<i>Experimento</i>	<i>Resultado esperado</i>	<i>Resultado alcançado</i>	<i>Erro</i>
1	1.0	0.999	≈ 0
2	0.857	0.866	-0.0095
3	0.35	0.340	0.01
4	0.357	0.382	-0.025
5	0.714	0.719	-0.005
6	0.642	0.614	0.028
7	0.214	0.207	0.006
8	0.214	0.225	-0.010
9	0.285	0.285	≈ 0
10	0.428	0.428	≈ 0

Após o processo de treinamento, dois novos dispositivos se conectaram ao sistema (Figura 17). Dessa vez, o sistema fornece uma predição de validade ao experimento, e, após certo tempo, o usuário pode indicar se houve acerto ou não.



Figura 17: Conexão de dois novos dispositivos e reconhecimento automático.

O primeiro dispositivo estava localizado fora da geladeira e dentro de uma caixa aberta, similar a alguns outros cenários já cobertos. A Figura 18 apresenta um recorte do site já apresentado aqui, que permite monitorar os dados do dispositivo e visualizar a predição realizada para a validade. A previsão foi bastante próxima, visto que a banana levou aproximadamente 12 dias para estragar.

Já o segundo dispositivo estava em um cenário ainda não coberto: dentro de uma caixa fechada na geladeira e sem frutas podres por dentro. A previsão de duração foi de apenas 5 dias, conforme ilustrado na Figura 19, porém ela permaneceu válida por mais 10 dias.

Dessa forma, um novo processo de treinamento teve de ser iniciado, pois o resultado foi bem diferente do esperado. O treinamento anterior não é perdido. O que acontece é que este novo resultado irá provocar ajustes na configuração da rede neural.

Os resultados poderiam ser mais precisos se fosse possível submeter a banana à condições laboratoriais, onde não houvesse uma mudança constante dos fatores do ambiente. Por exemplo, se a banana for sempre submetida à uma temperatura de 30°, em quantos dias ela apodreceria? Isso permitiria realizar um melhor treinamento da rede e ter um maior domínio da contribuição de cada fator para o resultado. Outra melhora sugerida é a de automatizar o processo de classificação da banana a partir de um módulo de processamento de imagens, estabelecendo um padrão para identificar se a mesma já estragou ou não. Pois como o resultado final é oriundo de observação humana, torna a classificação mais suscetível à erros.

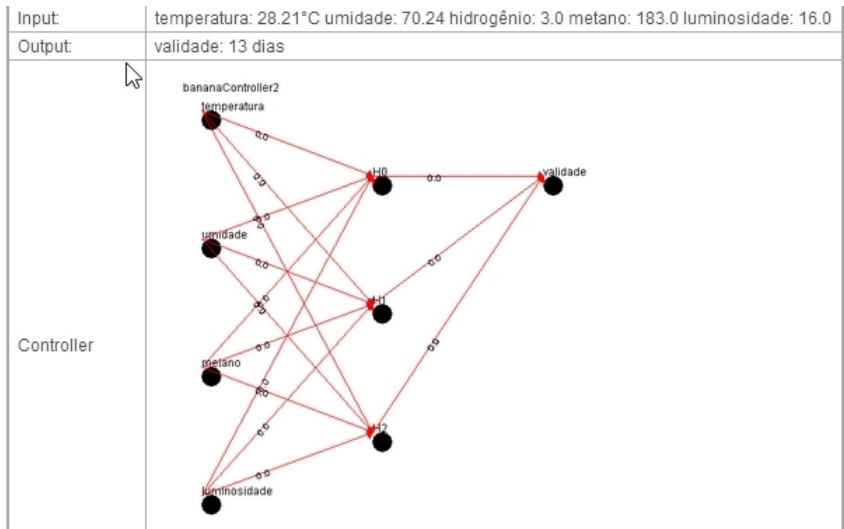


Figura 18: Coleta e inferência automática dos dados. Resultado Positivo.

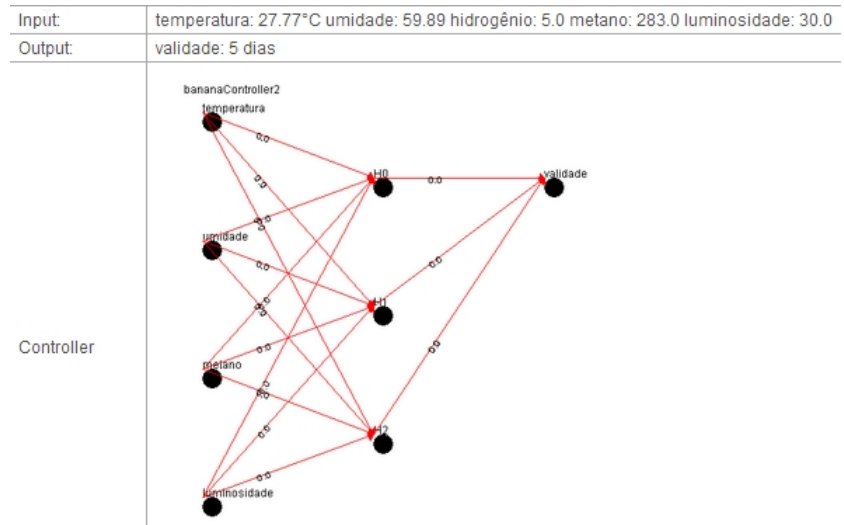


Figura 19: Coleta e inferência automática dos dados. Resultado Negativo.

Mesmo que as taxas de erros apresentadas ainda não tenham sido suficientemente boas, fazer uso de outros recursos para encontrar um modelo matemático que represente a contribuição e relação dos fatores para o amadurecimento da banana pode ser algo bastante complexo, visto a necessidade de correlacionar inúmeros fatores. As taxas de erro utilizando esta modelagem podem ser reduzidas submetendo bananas à mais situações de exemplo.

5 Conclusões

Uma série de questões em relação a conservação de alimentos são feitas com frequência por produtores, vendedores e consumidores em todo o país. Questões que quando respondidas,

podem, por exemplo, ajudar na prevenção de doenças causadas pelo consumo ou contato com alimentos estragados. Podem também aumentar a qualidade e o abastecimento dos alimentos para consumo dentro e fora do país, conseqüentemente ajudando a reduzir os custos.

O conceito por de trás do “Quantified Fruits” é compartilhar experiências passadas afim de realizar inferências sobre processo de conservação de frutas. E tudo isso de forma automatizada.

Como são diversos os fatores que interferem no amadurecimento da fruta, de forma dependente, é difícil encontrar um padrão que os correlacione. Por isso a importância de fazer uso de redes neurais, que mais uma vez se mostrou eficiente em mapear sistemas complexos, sem se ter a necessidade de conhecer eventuais modelos matemáticos que descrevam o seu comportamento.

Foi abordado de forma significativa o modelo criado para generalizar a criação de aplicações para “Quantified Things”. O intuito disso é mostrar que o trabalho apresentado aqui pode ser facilmente replicado para alcançar outros domínios, como o de frutas, no geral. A banana foi escolhida para iniciar esses experimentos por ser uma fruta tropical e com menor tempo de conservação. Dessa forma, foi possível realizar a simulação de mais de dez experimentos para o apodrecimento da banana em menos de três meses, ou seja, tornou viável a montagem da base de dados em tempo hábil.

A idéia deste experimento foi iniciar o treinamento quantificando bananas, e ir adicionando outras frutas à medida em que a rede neural for sendo adequada. Além de criar aplicações em outros domínios, esse modelo também mostrou ser possível permitir a avaliação de outros tipos de características, não somente a validade. Assim como apontar a importância de cada elemento para a conservação do alimento, podendo indicar quais devem sofrer alterações para prolongar o seu tempo útil (por exemplo, aumente a temperatura em 3°C). E também focar no tempo e porcentagem de perda de carga no transporte de frutas.

A partir dessas informações, é viável elaborar uma situação ideal de armazenamento para conservação da fruta. Essa descrição das características que permitam prolongar o tempo de duração da fruta pode auxiliar no desenvolvimento de uma caixa auto suficiente, de modo que não só monitore os fatores, como também possa alterá-los.

Como foi dito anteriormente, o desconhecimento das técnicas disponíveis para reduzir as perdas por parte de agentes da cadeia produtiva é o maior parceiro do desperdício no processo pós-colheita. E este problema também pode ser amenizado com o uso do dispositivo “Quantified Fruits”. Como os carregamentos de frutas estarão sendo monitorados e disponibilizando as informações na Internet, o produtor pode eleger uma pessoa mais experiente para minuciosamente acompanhar todo o processo de abastecimento e dar sugestões aos executores.

A facilidade proporcionada por sistemas multiagentes, que é a de permitir sistemas complexos operarem de forma distribuída e independente, também agrega mais valor ao produto. Esses paradigmas viabilizaram a criação de dispositivos capazes de serem detectados automaticamente e agirem de forma autônoma, sem necessitar de configurações manuais. Esses pontos o torna facilmente comerciável, podendo ser utilizado tanto pelos participantes da cadeia produtiva, quanto para vendedores e consumidores.

As expectativas de uso desse dispositivo é reduzir o desperdício de frutas, desde o processo de distribuição até a casa dos consumidores. Também auxiliar na pesquisa de fatores

que interferem no amadurecimento da fruta pós-colheita, a exemplo da luminosidade que vem sendo abordada neste trabalho, e da aceleração na produção de hidrogênio provocada pelo contato da banana madura com a banana podre. Mais experimentos com a banana devem ser realizados afim de aprimorar o sistema para reconhecimento de padrões, comprovando a eficácia do dispositivo, e, permitindo que o modelo seja aplicado em outros domínios posteriormente.

Referências

- [Apple, 2014]APPLE. **Watch**. Dezembro 2014. <https://www.apple.com/br/watch/>.
- [Arduino, 2014]ARDUINO. **Arduino**. Dezembro 2014. <http://www.arduino.cc/>.
- [Boe and Salunkhe, 1967]BOE, A.; SALUNKHE, D. Ripening tomatoes: ethylene, oxygen, and light treatments. **Economic Botany**, Springer, v. 21, n. 4, p. 312–319, 1967.
- [Brasil, 2010]BRASIL, F. B. do. **Fruticultura - Banana**. [S.l.], 2010.
- [Dailymail, 2013]DAILYMAIL. **No more furry peaches: The fruit bowl that warns you BEFORE your food goes mouldy**. Junho 2013.
- [Haykin, 1994]HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Macmillan, 1994. ISBN 9780023527616. Disponível em: <<http://books.google.com.br/books?id=PSAPAQAAMAAJ>>.
- [Jaeger and Metzger, 2002]JAEGER, T.; METZGER, A. **Open-source-Software**. [S.l.]: Beck, 2002.
- [Jordan and PFARR, 2014]JORDAN, M.; PFARR, N. **Forget the Quantified Self. We Need to Build the Quantified Us**. April 2014. <http://www.wired.com/2014/04/forget-the-quantified-self-we-need-to-build-the-quantified-us/>.
- [Lucena and Nunes, 2013]LUCENA, C.; NUNES, I. Contributions to the emergence and consolidation of agent-oriented software engineering. **Journal of Systems and Software**, v. 86, n. 4, p. 890 – 904, 2013. ISSN 0164-1212. {SI} : Software Engineering in Brazil: Retrospective and Prospective Views. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0164121212002567>>.
- [Massaro, 2014]MASSARO, A. **Quantified Self e Finanças pessoais**. Dezembro 2014. <http://exame.abril.com.br/rede-de-blogs/voce-e-o-dinheiro/2014/10/30/quantified-self-e-financas-pessoais/>.
- [Miller and Schomer, 1947]MILLER, E. V.; SCHOMER, H. A. The effect of ultraviolet light on subsequent ripening of the fruit of the tomato (*lycopersicon esculentum*). **Plant physiology**, American Society of Plant Biologists, v. 22, n. 4, p. 608, 1947.
- [Mpelkas and Kenyon, 1972]MPELKAS, C.; KENYON, E. **THE EFFECT OF LIGHT QUALITY ON THE RIPENING OF DETACHED TOMATO FRUIT**. [S.l.], 1972.

- [Nascimento, 2014]NASCIMENTO, N. **Quantified Things: What can homogeneous things learn when they pool data across them?** Dezembro 2014. [Http://www.quantifiedthings.com/seeexperiments.xhtml](http://www.quantifiedthings.com/seeexperiments.xhtml).
- [Nike, 2014]NIKE. **NIKE FUELBAND SE.** Dezembro 2014. [Http://www.nike.com/nikeplus-fuelband/](http://www.nike.com/nikeplus-fuelband/).
- [Pfister, 2011]PFISTER, C. **Getting Started with the Internet of Things: Connecting Sensors and Microcontrollers to the Cloud.** 1st. ed. [S.l.]: O'Reilly Media, Inc., 2011. ISBN 1449393578, 9781449393571.
- [Philips, 2014]PHILIPS. **Attracting customers with light.** [S.l.], 2014.
- [Sebrae, 2008]SEBRAE. **Estudo de Mercados Sebrae: Banana.** [S.l.], 2008.
- [Stamford, 2014]STAMFORD, C. **2014 Hype Cycle for Emerging Technologies Maps the Journey to Digital Business.** <http://www.gartner.com/newsroom/id/2819918>, August 2014.
- [Tissot et al.]TISSOT, H.; CAMARGO, L.; POZO, A. Treinamento de redes neurais feedforward: comparativo. In: **Encontro Nacional de Inteligência Artificial.** [S.l.: s.n.].
- [UCI, 2014]UCI. **Machine Learning Repository.** Dezembro 2014. [Https://archive.ics.uci.edu/ml/datasets.html](https://archive.ics.uci.edu/ml/datasets.html).