

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO

Calibration framework for low-cost environmental micro-sensors Urbansense Platform

Tiago Filipe dos Santos Lourenço



Programa de Mestrado de Engenharia da Informação

Orientador: Sérgio Crisóstomo

Co-orientador: Ana Aguiar

31 de Outubro de 2016

Calibration framework for low-cost environmental micro-sensors Urbansense Platform

Tiago Filipe dos Santos Lourenço

Programa de Mestrado de Engenharia da Informação

Resumo

A plataforma Urbansense é uma infra-estrutura à escala urbana, para monitorização da qualidade do ar, nível de ruído, radiação solar e parâmetros meteorológicos, implementada na cidade do Porto.

A plataforma é composta por várias unidades de sensores distribuídas pela cidade. Estas unidades enviam os dados recolhidos para um servidor central, seja através de uma infraestrutura de fibra metropolitana, ou através de uma rede veicular. As unidades são compostas por sensores *low-cost* que tendem a apresentar desvios crescentes dos valores medidos, devido ao envelhecimento e à exposição a condições atmosféricas adversas. Por esse facto, estes sensores necessitam de ser calibrados periodicamente (para além da calibração inicial).

O objetivo deste trabalho é o desenvolvimento uma arquitetura de *software*, a ser integrada na plataforma Urbansense, com vista à automatização dos processos de calibração. Esta arquitetura apresenta como principais requisitos (1) o suporte para a utilização de técnicas de *Machine Learning* na derivação dos modelos de calibração, e (2) a calibração periódica de todos os sensores da plataforma, recorrendo a nós especiais de calibração móveis; e (3) o armazenamento central dos dados brutos, com vista à derivação centralizada dos modelos de calibração e à calibração centralizada dos dados.

Abstract

The Urbansense platform is an urban-scale infrastructure for monitoring the air quality, noise levels, solar radiation, and weather conditions, that is currently being deployed in the city of Porto.

The platform is composed by several sensing units, deployed all over the city, that send the collected data to a cloud infrastructure, either via a static wireless infrastructure, or via a mobile vehicular network that relays the sensed data to the cloud infrastructure. Each sensing unit is composed by low-cost sensors whose accuracy of reported values degrades over time, due to ageing and to the exposure to adverse atmospheric conditions. Thus, these sensing units need, not only an initial calibration, but also periodic re-calibration.

The goal of this work is to develop a software *framework*, to be integrated in the Urbansense platform, enabling the automatisation of the calibration processes. The main requirements for this software *framework* were: (1) to enable an easy application of machine learning techniques in the derivation of the calibration models; (2) the periodic calibration of the sensor units, without requiring that they are unmounted for manual calibration, resorting to special mobile calibration nodes; (3) the central storage of the raw-data sensed values, thus allowing the centralised derivation of the calibration models and a centralised calibration of the sensed values.

Agradecimentos

Este trabalho apresenta o culminar de uma etapa da minha vida académica. Não poderia concluí-la sem antes de mais agradecer a todos os contribuintes para a sua realização.

Ao orientador Doutor Sérgio Crisóstomo pela confiança depositada como pelo apoio prestado. Proporcionando a conclusão desta dissertação através de críticas construtivas, ensino e estímulo, dando oportunidade do desenvolvimento e expansão do conhecimento obtido.

Ao co-orientador Doutora Ana Aguiar pelo apoio prestado e a oportunidade de desenvolver trabalho no projeto como a Urbansense. O pilar para desenvolvimento desta dissertação, permitindo um trabalho colaborativo com o resto do grupo do projeto.

Um especial à Doutora Sofia Sousa e seu aluno de doutoramento Pedro Branco pelo apoio prestado nas áreas das químicas. Ajudando a intervir com melhor clareza no desenvolvimento do projeto, conseguindo concluir vários questões subjacentes à utilização dos sensores.

Um agradecimento especial à Doutora Tânia Calçada por me integrar no projeto Urbansense e acreditar nas minhas capacidades para trabalhar junto da sua equipa. Agradeço também o incentivo dado para me integrar no programa de mestrado e as possibilidades que obtive desde então. Foi sem dúvida o maior incentivo para hoje estar aqui.

Ao IT-Porto por me dar as condições necessárias para o meu trabalho se realizar, como a toda a equipa nela presente. Eles foram uma mais-valia dado ao conhecimento transmitido durante as dificuldades que foram apresentadas.

Ao Yuniur Luis, Carlos Penichet, Pedro Santos e Bruno Fernandes equipa da Urbansense que sempre se dispuseram ajudar para o desenvolvimento do meu projeto.

Ao Doutor Daniel Moura, pelo apoio inicial dado ao estudo dos dados, partilhando técnicas e conhecimento essenciais para as conclusões e resultados obtidos durante o meu trabalho.

Um grande agradecimento há minha família e amigos pelo apoio dado durante esta fase da minha vida, sem dúvida um apoio essencial para conseguir ultrapassar todas as dificuldades nunca me deixando desanimar. Conseguindo seguir sempre o melhor caminho para conclusão de esta fase muito importante para mim.

A todos aqueles que diretamente ou indiretamente contribuíram na concretização deste trabalho, os meus sinceros e profundos agradecimentos

Tiago Filipe dos Santos Lourenço

“Items of interest will be located, identified, monitored, and remotely controlled through technologies such as radio-frequency identification, sensor networks, tiny embedded servers, and energy harvesters - all connected to the next-generation internet using abundant, low-cost, and high-power computing.”

David Petraeus

Conteúdo

1	Introdução	1
1.1	Motivação	1
1.2	Contextualização	2
1.2.1	Plataforma Urbansense	2
1.2.2	Arquitectura da Plataforma Urbansense	4
1.3	Objectivos	5
1.4	Estrutura da dissertação	6
2	Enquadramento	7
2.1	Problema principal	7
2.2	Estado de arte	8
2.2.1	Problemas de calibração dos sensores <i>low-cost</i>	9
2.2.2	Estratégias de calibração	10
2.3	Calibração à escala urbana	12
2.4	Trabalho relacionado	12
3	Estratégia de calibração para a Plataforma Urbansense	15
3.1	Estratégia de calibração	15
3.1.1	Calibração com o Ground Truth	18
3.1.2	Calibração do primeiro hop	19
3.2	<i>Framework</i> de calibração	20
3.3	Integração dos modelos de calibração	23
3.3.1	Requisitos	24
3.3.2	Instalação	25
4	Resultados	27
4.1	Avaliação dos sensores	27
4.1.1	Qualidade dos sensores <i>low-cost</i>	27
4.1.2	Sensibilidade cruzada dos sensores <i>low-cost</i>	28
4.1.3	Análise ao sensor de NO_2	32
4.1.4	Coerência dos sensores <i>low-cost</i>	34
4.2	Calibração com o <i>Ground Truth</i> - segundo hop	35
4.2.1	Derivação dos modelos do segundo hop	35
4.3	Calibração do primeiro hop	38
4.3.1	Derivação do modelo (<i>DCU</i> - <i>DCU</i>)	38
4.4	Calibração multi-hop	39

5	Conclusões	43
5.1	Trabalho futuro	43
A	Base de dados de calibração	45
B	Arquitectura da <i>Framework</i>	47
C	Integração dos modelos	51
D	Resultados	53
	Referências	57

Lista de Figuras

1.1	Arquitectura da plataforma Urbansense	3
1.2	Aspecto externo da DCU	4
1.3	Arquitectura do hardware da DCU	5
1.4	Arquitectura detalhada da plataforma Urbansense	6
2.1	Tipos de calibração	8
2.2	Estratégias de calibração para os problemas dos sensores low-cost	9
2.3	Electroquímico	10
2.4	Resistivo	10
2.5	Árvore de decisão	11
2.6	Redes neuronais	11
3.1	Estratégia de calibração proposta a dois hops	15
3.2	Momentos de calibração do segundo hop	17
3.3	Validação do período de contacto na mesma localização	17
3.4	Detecção do contacto por coordenadas GPS	18
3.5	Integração da <i>framework</i> de calibração na plataforma Urbansense	20
3.6	Base de dados de calibração	21
3.7	Mensagem de notificações para a calibração em tempo real	22
3.8	Arquitectura da integração dos modelos de calibração	23
3.9	Support calibration models	24
4.1	Matriz de sensibilidade cruzada dos sensores <i>low-cost</i> disponíveis na plataforma Urbansense num período de seis meses	29
4.2	Matriz de correlação de sensibilidade cruzada entre os sensores HQ e <i>low-cost</i> em ambiente urbano	31
4.3	Aplicação de um filtro passa baixo ao sinal de CO	32
4.4	Baixas concentrações de CO em ambiente urbano durante o período de teste	33
4.5	Correlação, distribuição e linearidade do O_3 e NO_2	34
4.6	Baixas concentrações de NO_2 em ambiente urbano durante o período de teste	35
4.7	Teste em laboratório do sensor de NO_2	36
4.8	Distribuição das concentrações presentes durante os dois testes	37
4.9	Primeiro hop, respectivo ao modelo (<i>DCU</i> - <i>DCU</i>) baseado em regressão linear	40
4.10	Calibração com a estratégia multi-hop desenhada, utilizando a <i>framework</i> de calibração para integração dos modelos treinados	41
B.1	Metodologia de calibração	48
B.2	Protocolo de notificação (Cliente/Servidor)	49

C.1	Inserção do algoritmo de calibração	51
C.2	Inserção da parametrização	52
D.1	Análise externa das influências dos sensores <i>low-cost</i> a outras concentrações através da sensibilidade cruzada e correlação	54

Lista de Tabelas

1.1	Lista dos sensores e suas características	3
4.1	Correlação de spearman com o Ground Truth	28
4.2	Correlação spearman entre sensores <i>low-cost</i> iguais	34
4.3	Avaliação dos modelos de calibração do segundo hop	37
4.4	Avaliação dos modelos do primeiro hop	38
4.5	Avaliação da calibração multi-hop	39
4.6	Valores limiares mínimos legislados	39
D.1	Análise da correlação entre todas as DCUs entre os sensores NO_2 e O_3	55

Abreviaturas e Símbolos

DCU	Data Collector Unit
Mobile DCU Reference	Calibrated Data Collector Unit
Ground Truth Reference	Ground Truth sensor
DTN	Delay-tolerant networking
ML	Machine Learning
O_3	Ozone
NO_2	Nitrogen dioxide
CO	Carbon monoxide
GSM	Global System for Mobile Communications
GPS	Global Positioning System
RSSI	Received signal strength indication
IoT	Internet of things
Corr	Correlation
MAE	Mean absolute error
RAE	Root absolute error
LR	Linear regression
MLR	Multiple linear regression

Capítulo 1

Introdução

O uso de sensores *low-cost* em aplicações urbanas tem vindo a crescer nos últimos anos. O foco deste trabalho vai ao encontro dos problemas que estes sensores apresentam nestes novos ambientes. A calibração dos sensores *low-cost* requer novas estratégias, uma vez que estes apresentam problemas acrescidos em relação aos sensores de alta performance.

A plataforma Urbansense é uma plataforma de escala urbana para monitorização da qualidade do ar, ruído, luminosidade e condições atmosféricas. O uso de sensores *low-cost* torna desta plataforma uma solução mais económica. A possibilidade de poder obter dados fidedignos para os mais diversos estudos depende da calibração e da estratégia aplicada.

1.1 Motivação

As dificuldades apresentadas pelos sensores *low-cost* dependem da sua tecnologia ([Aleixandre e Gerboles, 2012](#)) e do composto que vão medir ([Piedrahita et al., 2014](#)). Vários fatores afetam a leitura do sensor ([Beutel et al., 2011](#)), tal como o envelhecimento e desgastes sofrido ao longo do tempo. Para conseguir detetar e corrigir estes problemas, é necessário estudos contínuos dos sensores bem como a sua calibração periódica ([Hasenfratz, 2015](#); [Beutel et al., 2011](#); [Kumar et al., 2015](#)). No entanto, as técnicas de calibração clássicas não são aplicáveis a plataformas de redes de sensores à escala urbana.

O uso de uma plataforma real permite uma contribuição com outra visão nos diferentes estudos e problemas. Um dos objetivos desta plataforma é permitir um fácil acesso aos diferentes grupos de estudo à plataforma como aos seus dados, sem necessidade de conhecimento técnico nas áreas das TIC.

Como objetivos deste trabalho, temos (1) a conceção de uma estratégia de calibração que automatize parte do processo de calibração e que seja adequada a sensores *low-cost*; (2) o desenvolvimento de uma interface de fácil acesso aos dados para calibração, (3) o desenvolvimento de mecanismos de gestão de toda a estratégia de calibração.

1.2 Contextualização

Em 2012 foi criado na Cidade do Porto um centro de competências para as cidades do futuro (Fut), focado nas necessidades das populações nas grandes cidades através da exploração das TIC na conceção de soluções, de forma a proporcionar melhores condições para as cidades. Este centro criou condições de trabalho para grupos de diferentes áreas trabalharem em colaboração.

A plataforma Urbansense é um dos projetos desenvolvidos neste centro (Fut; Luis Rojo et al., 2016). Trata-se de uma infraestrutura em larga escala desenhada para monitorizar diferentes fenómenos ambientais, equipada por diferentes sensores *low-cost*. Tem instalado 23 unidades de sensorização designadas como Data Collection Units (DCUs), fixas em locais estratégicos na cidade do Porto. Cada DCU está equipado com uma variedade de sensores para medição da qualidade do ar, ruído, luminosidade e condições atmosféricas. O transporte dos dados recolhidos pelas diversas DCUs é feito por uma conexão Wi-Fi para uma rede de fibra metropolitana ou para a rede veicular.

A rede veicular, também é um dos projetos de origem do centro de competências (Meireles et al., 2010). Tem disponíveis 600 nós ativos em diversos veículos públicos, com suporte de comunicações *vehicle-to-vehicle* e *vehicle-to-infrastructure*.

1.2.1 Plataforma Urbansense

A Plataforma Urbansense é composta por três camadas: a camada de recolha de dados composta por unidades de sensorização (DCU); a camada de transporte de dados que possibilita a utilização de diferentes infraestruturas de comunicação; e a camada de processamento constituída por servidores de *Backoffice* para registo e processamento de todas as medições, (ver figura 1.1). O *Backoffice* disponibiliza um interface para partilha dos dados com terceiros, mantendo as suas medições online para consulta.

As DCUs, (ver figura 1.2) são os componentes fundamentais da Plataforma Urbansense. Elas são unidades de sensorização equipadas com diferentes tipos de sensores. Elas encontram-se instaladas em locais estratégicos por toda a cidade para permitir monitorizar locais com características distintas. As diferentes áreas de estudo são: parques/jardins; áreas residenciais, industriais, de ensino, históricas/turísticas; áreas de forte tráfego automóvel, e áreas à beira-mar. Estes dados podem ser transportados usando a rede veicular (Meireles et al., 2010), ou a rede fibra metropolitana até ao servidor.

Esta unidade divide-se em três componentes: a *Sensor Board* onde se encontram instalados a maior parte dos sensores; a *Control Board* para controlo acesso de todos os sensores; e por último a *Processing Board* para armazenamento e processamento dos dados, (ver figura 1.3). A unidade de processamento estabelece ligação com as diferentes infraestruturas de rede, possuindo diferentes protocolos para um correto funcionamento na rede de sensores.




Figura 1.1: Arquitectura da plataforma Urbansense

1.2.1.1 Sensores

As *DCUs* podem operar com diversas combinações de sensores disponíveis. Os sensores que equipam as *DCUs* estão representados na tabela 1.1.

Tabela 1.1: Lista dos sensores e suas características

Sensor	Ref.	Humid. range	Temp. Range	Detect. limit	Resolution/ Sensitivity	Group
O_3	MICS 2614	5 to 95%	-40 to 70°C	10 – 1000 <i>ppb</i>	10 <i>ppb</i>	Air Quality
NO_2	MICS 2717	5 to 95%	-30 to 85°C	0.05 to 5 <i>ppm</i>	0.05 <i>ppm</i>	
CO	NAP 505	15 to 90%	-20 to 50°C	0 to 1000 <i>ppm</i>	5 <i>ppm</i>	
Partículas	PPD42NS	0 to 95%	0 to 45°C		1 μm	
Temperatura.	RTH03			-40 to 80°C	0.1°C	B. Env.
Humidade.	RTH03			0 to 100%	0.1%	
Luminosidade	TSL2591		-30 to 70°C	0 to 65535	0	
Precipitação	80422				0.28 mm	Weather
Velocidade do vento	80422				2.4 km/h	
Direção do vento	80422			0 to 337.5 °	16 Posições	
Sonómetro	LL814S	0 to 70%	0 to 40°C	40 to 130 dB	2 dB	Ruído

Como se pode verificar na tabela 1.1, os sensores encontram-se agrupados por diferentes grupos. Os sensores atmosféricos (*Weather*) e de ruído são sensores externos à *Sensor Board*. Ligam-se diretamente à *Control Board*. Os grupos *Basic Environment* e *Air quality* são o foco desta dissertação. Eles encontram-se instalados na *Sensor Board*, estando sempre disponíveis nas *DCUs*.




Figura 1.2: Aspecto externo da DCU

Alguns dos sensores tais como de Temperatura, Humidade e o Sonómetro, vêm com uma calibração de fábrica. Os sensores de Partículas e Luminosidade são digitais; apresentam uma maior estabilidade de funcionamento. Os sensores que têm apresentado mais problemas são os de gases. O sensor de Ozono (O_3), Dióxido de Nitrogénio (NO_2) e de Monóxido de Carbono (CO) são analógicos. Podem ser do tipo eletroquímico ou resistivo. No entanto, são conhecidos por sofrerem de sensibilidade cruzada e de terem um limite mínimo de deteção elevado para as concentrações urbanas. São estes sensores que mais necessitam de uma calibração contínua, obrigando à implementação de uma estratégia e estudo de calibração para correção dos seus problemas. Os sensores de condições atmosféricas são eletromecânicos. Não apresentam grandes problemas de sensorização, e já dispõem de calibração.

1.2.2 Arquitectura da Plataforma Urbansense

A Urbansense é uma infraestrutura à escala urbana de monitorização dos diferentes fenómenos ambientais, equipada por unidades estáticas de recolha de dados (DCU) por toda a cidade. A plataforma é composta por três principais componentes, a unidade de recolha de dados (DCU), que garante a sensorização dos diferentes pontos da cidade; um *Backoffice* para armazenamento de todas as medições das DCUs como para partilha com terceiros, e por último, os meios de comunicação para transporte dos dados, com disponibilidade de três serviços diferentes, (ver figura 1.1 e 1.4).

O elemento chave desta plataforma são as DCUs, (ver figura 1.2), equipadas com uma diversidade de sensores *low-cost* para qualidade de ar, condições atmosféricas e ruído. Elas enviam os dados recolhidos via comunicação *Wifi* para três diferentes meios: fibra metropolitana, redes móveis ou por rede veicular *delay-tolerant networking* (DTN). Todos eles fazem chegar os dados até ao *Backoffice* para processamento e armazenamento. O uso da DTN implica um atraso na disponibilidade das medições como não garante um acesso à unidade para manutenção. No entanto garante a cobertura de áreas mais remotas das cidades. A disponibilidade dos dados a terceiros é feita por tecnologias de *Internet of things* (IoT). Pela perspetiva da IOT o *Backoffice* serve de




Figura 1.3: Arquitectura do hardware da DCU

Gateway, permitindo a visibilidade de todos os nós nele conectados à IoT, dividindo a carga por os diferentes meios de transporte de dados.

O esforço do projeto Urbansense foi desenvolver uma unidade *low-cost* de sensorizações (DCU) capaz de operar em ambientes urbanos a uma escala urbana. Ela é composta por três partes: placa de sensores onde se encontram instalados a maioria dos sensores *low-cost*, a placa de controlo faz a gestão da comunicação entre os placa de sensores e a unidade de processamento, como também permite a ligação de alguns sensores externos, a unidade de processamento também garante o envio dos dados para o *Backoffice*, (ver figura 1.2 e 1.3). As *DCUs* podem funcionar com diferentes combinações de sensores ativos. Estes sensores diferem entre si, alguns são digitais outros analógicos, podendo ser resistivos ou eletroquímicos. Uns requerem um elemento de aquecimento, acondicionamento ou circuito viés. Esta diversidade requer diferentes técnicas de calibração, para resolver os diferentes problemas que possam apresentar.

1.3 Objectivos

Tirar rentabilidade de uma plataforma *low-cost*, implica a solução de inúmeros problemas. Alguns desses problemas ainda tem a necessidade de ser estudados. Para isso, é necessário desenhar uma estratégia de calibração, capaz de calibrar uma rede de sensores à escala urbana. Esta deverá garantir a calibração periódica de todos os nós e sensores.

Os métodos de calibração convencionais não se enquadram em parte, em plataformas deste tipo. Estas plataformas dispõem de ambientes reais para derivação dos seus modelos de calibração, contraindo novos problemas para os dados de treino. É necessário compreender o comportamento dos sensores nestes ambientes, percebendo quais os seus fatores de distúrbio. A calibração tende




Figura 1.4: Arquitectura detalhada da plataforma Urbansense

a ser mais complexa para estes sensores. Requerem algoritmos de *Machine Learning* (ML) para conseguir reduzir as diferentes interferências sofridas, ajustando a sua curva de calibração.

Para integração de diferentes técnicas e soluções a fim de calibrar a plataforma Urbansense, é necessário o desenvolvimento de um módulo de calibração. Este deverá controlar a estratégia desenvolvida, como os modelos de calibração. O fácil acesso aos dados e aos modelos deve ser garantido por este módulo. Permitir a monitorização dos sensores e atualização dos seus modelos é outro fator importante.

1.4 Estrutura da dissertação

Esta dissertação está organizada da seguinte forma.

No Capítulo 2 apresenta-se o estado da arte focando nos problemas apresentados pelos sensores em geral, e os problemas dos sensores *low-cost* e as soluções já desenvolvidas para a sua calibração.

O Capítulo 3 começa por apresentar as soluções já existentes, seguindo-se a estratégia desenhada para calibrar a plataforma Urbansense. A sua implementação é apresentada neste Capítulo bem como o seu funcionamento e interação.

A apresentação dos resultados vem no Capítulo 4, descrevendo uma série de estudos e resultados realizados ao longo deste projeto, apresentando no final os resultados de calibração dos sensores.

Por último, no Capítulo 5, são apresentadas as conclusões e trabalho futuro para melhoramentos deste projeto.

Capítulo 2

Enquadramento

Já existe até ao momento vários estudos realizados sobre plataformas idênticas à Urbansense como aos sensores *low-cost*. Encontra-se divulgado alguns dos problemas de sensorização por parte de estes sensores em ambientes urbanos como as suas técnicas solucionais. Estes estudos vem ajudar a compreender o comportamento e a necessidade deste tipo de sensores e plataformas. Oferece correções de melhoramento para obter uma plataforma mais estável reduzindo os erros presentes nos sensores. Grande parte dos problemas são conhecidos como as suas soluções. Elas tem vindo demonstrar resultados positivos durante as suas implementações em ambientes urbanos. Esta informação torna-se importante e necessária para melhoramento da qualidade e prestígio da plataforma Urbansense.

2.1 Problema principal

O principal problema apresentado por qualquer sensor é a sua calibração, ela torna-se mais simples ou não dependendo da qualidade dos sensores. Mesmo os de alta qualidade e mais caros necessitam de ser calibrados pelo menos uma vez por ano. Esta calibração serve para corrigir o desvio que o sensor sofre ao longo do tempo aproximando-o do valor real esperado. Diretamente relacionado com o preço está a sua qualidade. Os sensores mais baratos normalmente tende para uma pior qualidade e precisão, requerendo a calibração com maior frequência ([Spinelle et al., 2015](#)). A probabilidade de sofrerem de sensibilidade cruzada é elevada para os sensores mais baratos. Requerendo novas técnicas de calibração para correção destes problemas.

A calibração convencional nem sempre é a mais indicada, é importante compreender os ambientes envolventes para calibrar os sensores Este tipo de soluções para calibração tendem a ser manuais e de custo mais elevado. Obriga o deslocamento de cada unidade para um local de calibração, fazendo de esta unidade indisponível por um certo período de tempo ([Whitehouse, 2002](#); [Hasenfratz, 2015](#); [Spinelle et al., 2015](#)). Este tipo de calibração é designada como calibração manual. É das soluções mais usadas, resultando num certificado de calibração onde indica o erro do sensor como a equação ou valor de correção.

Como mencionado no artigo (Whitehouse, 2002), esta solução de calibração é desadequada para redes de sensores. O custo tende a ser mais elevado devido ao elevado número de unidades. Outro problema é que os sensores *low-cost* com o passar do tempo necessitam de uma calibração mais frequente, obrigando a um maior tempo de indisponibilidade do sensor.




Figura 2.1: Tipos de calibração

Como mostra a figura 2.1, existe uma alternativa à calibração manual. Esta permite usar os ambientes reais para calibração com a presença de pelo menos um *Ground Truth* para cada sensor. Assim permite-se conhecer o comportamento dos sensores, de modo a ajustar a curva de calibração para o ambiente de operação real. Estes ambientes tendem a gerar novos problemas à sensorização destes sensores. Problemas de sensibilidade cruzada ou mesmo as baixas concentrações, afetam significativamente a leitura do sensor. A técnica de calibração automática aplica-se às redes de sensores. O elevado número de sensores não facilita o processo de calibração. Assim, usam técnicas multi-hop para aplicar a calibração à rede de sensores. Permitindo uma calibração periódica de forma automatizada com a necessidade de pelo menos uma estação de referência.

2.2 Estado de arte

O uso das tecnologias *low-cost* para os mais diversos estudos, tem ganho impacto nos últimos anos. O seu baixo custo permite o desenvolvimento de novos tipos de soluções. Um dos casos que tem vindo a ser estudado é a sua implementação em ambientes urbanos. Diversos estudos tem sido realizados neste tema (Culler et al., 2004; Estrin et al., 2001, 1999), começando a surgir as primeiras soluções para as dificuldades que estes sensores apresentam. A calibração já é um tema que tem vindo a ser estudado nas últimas décadas (Miluzzo et al., 2008). No entanto, só recentemente é que se têm baseado nos sensores *low-cost* e os seus problemas em ambientes urbanos. Estes sensores tem como característica sensorizar concentrações mais elevadas do que se fazem apresentar nos ambientes urbanos. Convertendo em inúmeros problemas quando operam em ambientes urbanos, propícios às concentrações muito mais baixas, (ver figura 2.2).




Figura 2.2: Estratégias de calibração para os problemas dos sensores low-cost

Para os problemas apresentados pelos sensores *low-cost*, ver figura 2.2, é necessário novos paradigmas de calibração. O facto de ser uma plataforma à escala urbana também influencia nas estratégias de calibração. Deve-se tirar partido do que a plataforma oferece para conseguir proporcionar as melhores condições de calibração.

2.2.1 Problemas de calibração dos sensores *low-cost*

Os sensores *low-cost* foram projetados para sensorizar elevados níveis de concentrações. No entanto, quando expostos a ambientes urbanos eles apresentam instabilidades e problemas de sensorização. A figura 2.2 relaciona os problemas com as estratégias solucionais. Estes problemas diferem do tipo de sensor como do meio envolvente. Os sensores digitais tendem a ser mais estáveis. Normalmente dispõem de uma calibração de fábrica, requerendo só um ajuste na sua curva de calibração. O grande desafio está nos sensores analógicos. É comum a sua utilização para a sensorização da qualidade do ar. Estes sensores podem ser do tipo eletroquímico ou resistivo, (ver figuras 2.3 e 2.4. Os sensores eletroquímicos apresentam-se com maior estabilidade em relação ao tipo resistivo. Apesar de umas das características é sofrerem interferências na presença pelas concentrações de ozono (Tavares, 2015), apresenta baixa sensibilidade cruzada perante as outras concentrações existentes. Já os resistivos são conhecidos por sofrerem de sensibilidade cruzada por as mais diversas concentrações (Aleixandre e Gerboles, 2012; Tsujita et al., 2005; Spinelle et al., 2015). Apresentando assim uma maior instabilidade durante as suas leituras.

As baixas concentrações em ambientes urbanos realçam os problemas de sensibilidade cruzada. Grande parte do tempo o sensor opera abaixo do seu limite mínimo de deteção, tendo dificuldade em detetar os diferentes compostos químicos. Outro especto importante que é descrito nos *datasheets* dos sensores é sensibilidade às diferentes variações de temperatura e humidade (Aleixandre e Gerboles, 2012). Foi realizado um estudo ao comportamento dos sensores nas diferentes épocas sazonais que confirmam este problema (De Vito et al., 2008). Os sensores apresentaram




Figura 2.3: Electroquímico




Figura 2.4: Resistivo

diferentes oscilações durante as diferentes épocas. Isto devido às diferentes composições químicas que se fazem sentir durante as diferentes estações. Estas podem afetar de forma variada o comportamento do sensor. Estes sensores também apresentam outros tipos de problemas. O envelhecimento e desgaste que o sensor vem a sofrer ao longo do tempo gera uma deriva nas medições, afastando-o cada vez mais do valor real (Spinelle et al., 2015).

A dificuldade em calibrar estes sensores é detetar todos os fatores interferentes, e tê-los em conta durante a calibração. Eles podem não estar sempre presentes na atmosfera. Por isso requer períodos de tempo muito extensos para se conseguir detetar e corrigir todos estes problemas.

2.2.2 Estratégias de calibração

Existem diversas estratégias já implementadas para calibração dos sensores *low-cost*. No entanto, muitas são idênticas mas nomeadas de maneira diferente. A tabela 2.2 mostra as técnicas de uma forma generalizada para os diferentes tipos de problemas. Esta é a base para combater os problemas apresentados pelos sensores. Para calibração dos sensores *low-cost*, foram desenvolvidas técnicas de auto-calibração. Elas operam sobre redes de sensores, calibrando periodicamente a rede completa. Contudo, este método de calibração é constituído por diferentes estratégias para os diferentes problemas.

Para compreender o comportamento do sensor nestes novos ambientes, é aconselhado aos estudos terem como base dados de ambientes reais. É recomendado o uso de um sensor de alta qualidade para validação dos testes. Assim vamos ao encontro dos problemas reais que os sensores venham a sofrer. Consegue-se assim detetar quais os compostos químicos que interferem na leitura do sensor. Estas interferências vão ajudar a ajustar o modelo de calibração, eliminando grande parte das interferências. São usadas como dependências durante a derivação dos modelos como para a sua calibração.

O uso de algoritmos de *Machine learning* permite que os modelos sejam treinados continuamente, ajustando os modelos de calibração ao sensor. Os modelos comuns para calibração dos sensores *low-cost* são baseados em regressões.

$$\begin{aligned} Y_i &= \beta_0 + \beta_1 x_i + \varepsilon \\ E(Y) &= \beta_0 + \beta_1 x \end{aligned} \quad (2.1)$$

Elas podem ser lineares como a equação 2.1, ou multivariáveis como a equação 2.2. A diferença é que as equações multivariáveis 2.2, suportam as dependências como entrada x_{ij} .

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_n x_{in} + \varepsilon$$

$$E(Y) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (2.2)$$

Os parâmetros das equações 2.1 e 2.2 são representados por β_n , onde n indica o número de parâmetros. A técnica de ajuste dos modelos é feita por parametrização dos algoritmos (Whitehouse e Culler, 2002). Os modelos são treinados periodicamente gerando novos parâmetros β para os algoritmos. O valor esperado é dado por $E(Y)$, onde Y são os dados calibrados e x os dados *raw*.

Para correção dos problemas sazonais, implica o uso de algoritmos mais complexos. No entanto, continuam a basear-se em regressões. Baseia-se em classificar os diferentes grupos de condições atmosféricas já conhecidos, aplicando diferentes parâmetros para as diferentes épocas sazonais ou grupo de concentrações. Este método também é usado para correção das altas variações da temperatura e humidade relativa, parametrizando-a os diferentes conjuntos de valores presentes. É conhecido por técnica de classificação. Ela pode ser árvores de decisão, (ver figura 2.5) ou redes neurais, (ver figura 2.6).




Figura 2.5: Árvore de decisão




Figura 2.6: Redes neurais

As Árvores de decisão como representado na figura 2.5 são composta por algoritmos de decisão nos nós, de cor branco, e por regressões nas folhas representado a cinzento, criando assim uma separação dos dados em diferentes grupos consoante as suas características. Já as Redes Neurais, (ver figura 2.6), cada uma das camadas é composta por uma serie de nós de processamento interligado. Cada nó utiliza uma função de transferência não linear para cálculo do produto interno do vetor de entrada. A camada de entrada recebe a informação e transmite-a para a camada *Hidden* representado a cinzento. Esta camada é responsável pela conversão dos dados, de seguida envia para a próxima camada *Hidden* ou de saída. Esta camada (*Hidden*), incorpora as regreções de calibração para as diferentes classificações. A camada de saída representa os resultados calibrados pela Rede Neuronal.

2.3 Calibração à escala urbana

A densidade de nós disponíveis numa rede de sensores dificulta o processo de calibração. Os métodos de calibração manual em ambientes controlados não é aplicável, devido a fatores já mencionados na secção anterior. No entanto o elevado número de nós, carece o custo da manutenção da plataforma (Whitehouse, 2002; Hasenfratz, 2015; Spinelle et al., 2015). A necessidade de minimizar os custos obriga a novas estratégias de calibração. Estas são desenhadas a pensar nos problemas dos sensores, como na diminuição dos custos.

Existem já várias estratégias de calibração desenvolvidas. Na figura 2.2 pode verificar as técnicas e a sua relação. Elas baseiam-se nos hops da rede de sensores para calibrar a plataforma. Baseados no método multi-hop, usa nós calibrados para calibração dos nós não calibrados (Hasenfratz, 2015; Saukh et al., 2015; Beutel et al., 2011; Aberer et al., 2010), baseando-se pelo menos numa estação *Ground Truth* (Whitehouse, 2002; Hasenfratz, 2015; Spinelle et al., 2015). Os requisitos para o seu funcionamento são a implementação de nós móveis (Miluzzo et al., 2008). Eles movem-se pelos nós fixos a fim de criar o ponto de ligação entre o *Ground Truth*.

Um dos problemas apresentados por esta estratégia é a deteção de contacto entre dois nós (Whitehouse, 2002). Existe uma distância mínima a ser cumprida entre os sensores para se poderem calibrar (Miluzzo et al., 2008). Esta, varia de sensor para sensor dependendo do tipo de composto ou fenómeno que deteta. Assim quanto mais próximos, mais fiáveis são os dados. Várias soluções foram desenvolvidas para o sistema de localização. Elas podem ser feitas com base nos sistemas de GPS, GSM e localização ad-hoc. A vantagem do uso do GPS é o seu relógio atómico. Ele permite a sincronização de todos os nós da rede, eliminando o desvio do relógio existente entre eles (Whitehouse, 2002; Varshavsky et al., 2008). No entanto, o GPS tem de ser complementado com umas das outras opções, de modo a reduzir o erro da posição absoluta presente no GPS. Pode ser complementado com o uso do GSM através do RSSI (Varshavsky et al., 2008) ou por localização ad-hoc (Whitehouse, 2002). Outros problemas aparecem quando o nó móvel não detém nenhum momento estacionário durante o contacto com os nós não calibrados. O tempo de contacto tende a ser curto, no entanto ocorre muitas mais vezes. A vantagem é o uso dos transportes públicos para movimentar estes nós, cobrindo uma maior área das cidades. No entanto, os sensores não estão preparados para sensorizar em movimento. A velocidade a que se desloca como a sua direção interfere nas suas leituras (Moses e Patterson, 2002). Assim, o número de medições com aproveitamento durante um contacto em movimento é mínimo. Para as medições serem validas para calibrar o contacto devem cumprir varias normas. A distância entre os sensores, o período de tempo que se encontra dentro da distância mínima e o uso das medições com o menor número de interferências.

2.4 Trabalho relacionado

Diversas soluções têm vindo a ser desenvolvidas no âmbito das *Smart Cities*. A necessidade de alternativas mais baratas para sensorização da qualidade do ar, dá origem a novas soluções.

Diversos projetos tem vindo a aparecer nesta área, alguns deles baseados em plataformas urbanas com um real *deployment*.

O projeto *Opensense* (Aberer et al., 2010), é uma plataforma de monitorização ambiental. Ela dispõe de nós fixos e móveis para sonorização da qualidade do ar, criando assim uma rede de sensores urbanos. Outra plataforma idêntica é a *CitySense* (Bales et al., 2012). Desenhada para incentivar uma serie de investigações com base numa rede de sensores. No entanto, destaca-se por o aproveitamento dos nós para fornecer *Wifi* público e pelo aproveitamento da rede para testes de sistemas distribuídos.

Os métodos de calibração destas plataformas são feitos por diversos protocolos. Eles acabam por integrar-se entre si, afim de conseguir aplicar uma autocalibração à rede de sensores (Miluzzo et al., 2008). As diversas soluções têm como base o mesmo paradigma. O uso de um *Ground Truth* como referência e uma calibração multi-hop é base destes sistemas (Miluzzo et al., 2008; Hasenfratz et al., 2012).

O controlo e gestão da calibração multi-hop é feito por diferentes paradigmas. Existem diversos protocolos para a rede de sensores, desenhados para facilitar a calibração de toda a rede. Eles controlam os contactos entre os nós como a calibração dos sensores de cada nó da rede. O protocolo *Calamari* (Whitehouse, 2002), destina-se principalmente a garantir os requisitos necessários para validação de um contacto. Baseia-se em localização ad-hoc, GPS, GSM, Cricket e AHLoS para validar o contacto entre nós (Varshavsky et al., 2008). Ele compara os diferentes métodos divulgando as vantagens e desvantagens de cada um. Estes métodos são aplicados em sistemas descentralizados, subrecarregando os nós com todo o processamento do processo de calibração.

Para aplicar a calibração existem diversas soluções desenhadas para um funcionamento descentralizado, aplicando a calibração em tempo real durante os contactos. O processo de autocalibração (Miluzzo et al., 2008; Moses e Patterson, 2002) baseia-se na parametrização dos modelos de calibração (Whitehouse e Culler, 2002). Assim, durante os contactos válidos o nó calibrado partilha as suas medições com o nó não calibrado a fim de parametrizar com novos parâmetros os seus modelos. A utilização da parametrização é apresentada de diversas formas. Algumas das técnicas desenvolvidas demonstram resultados bastantes interessantes para uma calibração contínua dos sensores.

O princípio é escolher um nó referência, e calibra todos os seus vizinhos. Estes tornam-se referência calibrando os próximos vizinhos não calibrados. É um processo de interação a partir de um ponto até todos os nós da rede de forma periódica. Outra proposta é os nós não calibrados serem calibrados por todos os nós vizinhos calibrados. Usa a média dos parâmetros gerados por os diferentes nós referência, de forma a criar a curva média. Minimizando o erro esperado ao nó calibrado. Este método também ele parte de um nó de referência inicial. Os nós de referência, por sua vez são calibrados a partir de uma estação de alta qualidade. Estes sensores de alta qualidade permanecem fixos num local estratégico, permitindo um acompanhamento mais detalhado da calibração dos sensores, como o seu uso para calibrar toda a plataforma. A redução do erro provocado pela movimentação dos sensores durante o contacto, passa por eliminar todos os conjuntos não lineares. Considerando o ruído sofrido por os sensores durante o movimento distribuições

Gaussianas ([Whitehouse, 2002](#)).

A geração dos parâmetros de calibração utiliza os dados do nó referência em conjunto com os do nó não calibrado. A forma de utilização dos dados pode variar. A técnica base é usar medições instantâneas do contacto entre os dois nós. Estas medições são as mais recentes para parametrização, ajustando o sensor ao seu nó de referência. Este ajuste para ser o mais adequado depende do tempo de contacto entre os dois nós, como o intervalo entre a última parametrização. Outra proposta é a calibração das medições antigas. Quando um contacto para parametrização ocorre, calibra um intervalo de medições anteriores ao último contacto. Assim corrige parte dos desvios derivados a intervalos longos entre parametrizações. A desvantagem deste método adverte do atraso até o desvio ser corrigido. Uma solução mais complexa é analisar cada valor de concentração individualmente. Assim gera a parametrização da curva média com base nas diferentes curvas de calibração geradas para esse sensor. Isto irá ajudar a compreender onde o sensor sofre mais dificuldades, minimizando o erro individual para cada valor de concentração ([Hasenfratz et al., 2012](#))

Capítulo 3

Estratégia de calibração para a Plataforma Urbansense

Neste capítulo descreve-se a estratégia desenhada para a plataforma Urbansense para automatizar o processo de calibração das suas unidades de sensores. O objetivo principal desta estratégia é permitir um controlo da calibração, como reduzir o maior número de erros de leitura dos sensores, fornecendo medições com o menor erro possível para estudos futuros sobre o comportamento ambiental das cidades. Outro objetivo é fornecer uma fácil integração com os dados da plataforma e os seus algoritmos de calibração para aqueles que a vão utilizar. Para isso vai ser apresentada uma *Framework* de calibração para aplicar a estratégia e a calibração à plataforma.

3.1 Estratégia de calibração

A solução desenhada tem como objetivo evitar a calibração manual de todos os sensores, e permitir uma calibração periódica. A calibração periódica permite minimizar os efeitos de anomalias que o sensor venha a sofrer, sejam elas desgaste, envelhecimento, danos ou interferências. Em parte este processo irá simplificar o processo de calibração, reduzindo os seus custos.




Figura 3.1: Estratégia de calibração proposta a dois hops

A estratégia proposta para calibrar a plataforma Urbansense foi uma solução multi-hop, proporcionando melhores condições para uma calibração periódica. Permite assim uma redução gradual dos erros de leitura, acompanhando o seu envelhecimento e desgaste ao longo do tempo. Esta estratégia requer no mínimo uma estação de alta qualidade para calibração de toda a rede de sensores. Como representado na figura 3.1, foi implementado uma solução de calibração a dois hops, sofrendo um baixo erro cumulativo devido ao número reduzido de hops. Esta implementação requer no mínimo uma estação de sensores de alta qualidade para validação da calibração dos sensores *low-cost*.

Para implementação desta estratégia, é necessário classificar os tipos de *Deployment* das DCUs, que permita identificar o seu tipo de operação perante a plataforma. Os tipos de operação são:

- **Active DCU:** DCU activa em operação em ambiente urbano.
- **Reference DCU:** DCU destinada a calibrar e avaliar pela primeira vez a DCU ativa.
- **Mobile DCU:** DCU destinada a recalibrar a DCU ativa periodicamente. Ela encontra-se equipada com um recetor de GPS para deteção do contacto.
- **Ground Truth Reference:** Sensores de alta qualidade para validação da calibração dos sensores *low-cost*.

Os sensores de alta qualidade, *Ground Truth* são também designados por *Ground Truth Reference*. Estes foram integrados na plataforma como se fossem mais uma unidade da rede de sensores, sendo o nó de referência base para calibração. Assim para calibrar as *Active DCUs* que integram a plataforma Urbansense, designou-se o tipo *Mobile DCU Reference* como tipo de operação para as DCUs que vão fazer o ponto de ligação entre as unidades *Ground Truth* do tipo *Ground Truth Reference* e as unidades em operação na plataforma *Active DCUs*, (ver figura 3.1). Agora com os requisitos básicos estabelecidos, podemos apresentar a estratégia de calibração a dois hops.

$$y = g(f(x)) \quad (3.1)$$

Começamos por apresentar o segundo hop este irá representar o modelo (*Ground Truth - DCU*), função $g(x)$. Para cada contacto entre *Ground Truth Reference* e *Mobile DCU Reference* existe um modelo de calibração $g(x)$ para cada sensor. O cenário para este hop deve permanecer sempre ativo em ambientes urbanos. Ele permitirá um melhor ajuste da calibração dos sensores a estes ambientes. A recalibração de todos os modelos é necessária. Ajudará a reduzir os erros presentes nas leituras dos sensores, acompanhando os problemas que possa vir a sofrer. São estes modelos que irão ditar a qualidade que a plataforma irá ter ao nível das medições recolhidas.

O primeiro hop destina-se a corrigir a discrepância de medidas existente entre sensores de duas DCUs, neste caso entre *Mobile DCU Reference* e as *Active DCUs*, ambas unidades *low-cost* e exatamente iguais e localizadas no mesmo ponto. Designado como modelo (*DCU - DCU*)

dado pela função $f(x)$, ajusta as medições à unidade de *Mobile DCU Reference* para aplicação do modelo (*Ground Truth - DCU*) respetivo, dado por $g(x)$. Assim o modelo de calibração a dois hops é dado pela equação 3.1, onde x são os dados *raw* e y os dados calibrados.




Figura 3.2: Momentos de calibração do segundo hop

O primeiro hop dispõem de dois momentos de calibração diferentes, ver figura 3.2. O primeiro ocorre na mesma localização onde se encontra instalado a *Reference DCU* e a unidade de *Ground Truth Reference*, durante um período mínimo de uma semana. Ele irá gerar os primeiros modelos de calibração para ambos os hops, permitindo assim uma primeira avaliação dos modelos com o *Ground Truth*. Esta avaliação destina-se a revelar parte dos problemas presentes nos sensores.

O segundo momento irá ocorrer entre a *Mobile DCU*, mas desta vez na localização onde se encontra em operação a *Active DCU* pelo mesmo período mínimo de uma semana. Destina-se à recalibração das unidades em funcionamento.

Assim, para um contacto ocorrer entre as unidades *Mobile DCU Reference* e *Active DCUs*, deve garantir a distância mínima entre sensores, (ver figura 3.4), durante o mesmo período de tempo, (ver figura 3.3).




Figura 3.3: Validação do período de contacto na mesma localização

A validação da localização, só é necessária para o segundo momento de calibração. Este momento é detetado quando cumprida a distância mínima r entre as unidades *Mobile DCU* e *Active DCU* para cada sensor, (ver figura 3.4 e equação 3.2). O primeiro momento ocorre sempre na presença do *Ground Truth*, e é sempre supervisionada por um especialista. Este controla a sua instalação e distância perante as outras unidades presentes, garantindo o melhor cenário para o




Figura 3.4: Detecção do contacto por coordenadas GPS

desenvolvimento de estudos sobre a plataforma *low-cost*.

$$D = |A - B| \leq r \quad (3.2)$$

A distância de contacto é validada por a distância entre duas coordenadas GPS, equação 3.3. A latitude é dado por φ e a longitude por λ . O $\Delta\varphi$ é obtido por $\Delta\varphi = (\varphi_2 - \varphi_1)$ e $\Delta\lambda$ por $\Delta\lambda = (\lambda_2 - \lambda_1)$. R é igual ao valor do raio da terra.

$$D = R \sqrt{(\Delta\varphi)^2 + (\cos(\frac{\varphi_2 + \varphi_1}{2}) \Delta\lambda)^2} \quad (3.3)$$

Garantir uma calibração periódica de toda a plataforma, irá garantir a correção de erros de leitura por parte dos sensores *low-cost*. Assim pode-se monitorizar e estudar as anomalias como os diferentes comportamentos dos sensores, aplicando substituição sempre que uma unidade se torne incapaz de cumprir com o seu objetivo. Para sensores *low-cost*, é aconselhável uma recalibração de 3 em 3 meses para todos os sensores instalados. Com tudo, quanto mais velho for um sensor mais regular deve ser esta intervenção.

3.1.1 Calibração com o Ground Truth

A calibração com o *Ground Truth*, segundo hop, é a que vai ter o maior impacto na correção dos erros de sensorização dos sensores. Deste modo deve ser escolhido um cenário apropriado, para a obter modelos de calibração mais ajustados à realidade de operação. O conhecimento prévio das dificuldades presentes em calibrar sensores *low-cost* para ambientes urbanos, ajuda-nos a obter uma melhor curva de calibração para o cenário real. A calibração deste hop tende a necessitar de um estudo mais aprofundando, de modo a entender o seu comportamento para o cenário onde irá operar. Assim é possível ajustar os modelos às necessidades presentes.

Os requisitos para a calibração do segundo hop, onde é derivado o modelo (*Ground Truth - DCU*), é usar um cenário real. O objetivo é evitar o recurso dispendioso a câmaras de atmosfera controlada para sua calibração. O cenário deve ser idêntico ao que as unidades irão operar durante

o seu período de vida. Também deve ser propício a grande variações das concentrações, assim ajudará a melhorar os resultados. Outro aspeto importante é detetar sensibilidades cruzadas entre sensores. Estas interferências cruzadas podem ajudar a obter um modelo mais ajustado se as usarmos como dependências no treino dos modelos de calibração. Com tudo, alguns sensores apresentam maiores dificuldades nestes tipos de ambiente. Se a calibração de um dado sensor em ambiente real não for satisfatória (baixa correlação ou correlação cruzada elevada), deve-se recorrer a ambientes controlados como um laboratório. A ideia é tentar determinar exatamente o que interfere com o sensor e se realmente é adequado para este tipo de concentrações. Caso contrário deverá proceder-se à sua substituição.

Foram efetuados estudos preliminares para avaliar o funcionamento do sensor e a sua adequação às concentrações em ambientes urbanos. Numa primeira análise, foi comparado diretamente com o sensor de alta qualidade com uma correlação de *Spearman*, avaliando a prestação dos sensores *low-cost* num ambiente urbano. Os resultados obtidos neste teste estão descritos na tabela 4.1, capítulo 4.

Os modelos de calibração para este tipo de sensores, tendem a ser mais complexo, usando as concentrações interferentes para ajuste do modelo de calibração, equação 2.2 onde x_j representa os atributos dependentes e j o número de dependências como *input*. O objetivo é o modelo treinado ter em conta as distorções provocadas ao sinal de leitura de modo a reduzir o erro de calibração.

3.1.2 Calibração do primeiro hop

Este hop de calibração tem o propósito calibrar as unidades *Active DCUs* tendo por referência uma unidade *Mobile DCU Reference* (calibração DCU-DCU). Para isso é necessário verificar a correlação entre sensores *low-cost* iguais disponíveis na plataforma. O resultado encontra-se na tabela 4.2. Pode-se verificar que existe uma elevada correlação entre a maioria. No caso do sensor de *CO*, ele apresenta uma baixa correlação. Estudos foram realizados para compreender a causa deste problema, capítulo 4.

Os modelos de calibração destinados a este hop tendem a ser mais simples. No entanto, nada garante que no futuro seja necessário recorrer a algoritmos mais complexos. Dado que o sensor de referência e o sensor a ser calibrado são iguais (i.e, mesmo tipo, mesmo fabricante, mesma referência), espera-se que a calibração se traduza por regressões lineares simples, ver equação 2.1. No entanto não se descarta a hipótese de se precisar de modelos mais complexos, por exemplo, em quando existir degradação de um sensor devido ao seu envelhecimento.

O erro de calibração obtido neste primeiro hop, é cumulativo ao erro do segundo hop, incrementado o erro de calibração ao sensor ativo.

Caso o contacto entre *Mobile DCU Reference* e *Active DCUs* aconteça em movimento por parte de uma das unidades, deve-se garantir a distância mínima entre os sensores como mencionado anteriormente, como também a velocidade e direção do vento. Estes são fatores que influenciam as leituras dos sensores (Tavares, 2015). Por isso recomenda-se o uso dos dados dos por intervalos de tempo em que ambas unidades estão paradas. Assim proporcionará modelos mais consistentes.

3.2 Framework de calibração

A *framework* de calibração proposta para a plataforma Urbansense, opera no *Backoffice* de modo centralizado na camada de processamento, (ver figura 1.1). Assim libertará processamento das DCUs e poupará a sua memória, como mostra a figura 1.4. O objetivo desta *framework* é garantir que todos os dados gerados pelos sensores da plataforma sejam calibrados no menor espaço de tempo, após a sua chegada ao servidor de *cloud*. Outro aspeto importante é disponibilizar uma fácil integração dos modelos de calibração e uma fácil manutenção. A *framework* deverá ser capaz de gerir os diferentes algoritmos de calibração, como a aplicar a parametrização aos modelos dos diferentes sensores e nós corretamente (Whitehouse e Culler, 2002). Assim garantirá calibração da plataforma de uma maneira simples para quem vai estudar e calibrar estes sensores e as suas medições.




Figura 3.5: Integração da *framework* de calibração na plataforma Urbansense

Para integração da *framework* de calibração foi preciso adaptar a plataforma Urbansense. A figura 3.5 mostra a nova arquitetura do *Backoffice* já com a integração da *framework* de calibração. Esta nova implementação não interferiu na arquitetura já existente, apenas acrescentou novos módulos. O armazenamento dos dados calibrados e dos modelos de calibração ficam separados da base de dados que dispõe dos dados brutos. Assim garante-se uma separação dos módulos já existentes e a calibração. A arquitetura proposta permite que a calibração possa ser efetuada em nós/máquinas das restantes plataformas. Esta nova base de dados armazena não só os dados calibrados como todas as configurações e modelos de calibração para calibrar a plataforma. É uma das peças importantes da plataforma. Contem a informação dos contactos entre os diferentes nós da calibração multi-hop, como os seus respetivos modelos e parâmetros de calibração para cada sensor. A estrutura desta nova base de dados encontra-se representada na figura 3.6.




Figura 3.6: Base de dados de calibração

A tabela **Functions** é onde se encontram os algoritmos/funções de calibração. Retém a informação necessária para a sua operação, permitindo diferentes parametrizações. Os modelos actualmente disponíveis para calibração já integrados na *framework* são: regressão linear simples, ver equação 2.1 e multivariável, equação 2.2. Eles podem ser descontinuados quando substituídos por novos, ficando um historial guardado na base de dados. No entanto devido ao seu uso intensivo foram integrados na arquitetura interna da *framework*, assim otimiza a sua utilização recorrendo muito menos a processos externos para sua execução. As funções têm como entrada os parâmetros dos diferentes modelos, eles estão armazenados na tabela **Hop 1 e Hop 2**, com os seus respetivos atributos dependentes nas tabelas **Dependências 1 & 2**. O registo de todos contactos de calibração multi-hop é feito na tabela **Contacts**. Disponibiliza informação do seu intervalo de tempo e duração. Com esta informação a *framework* consegue obter os dados referentes aos contactos para estudo e criação dos modelos de calibração, Figura no anexo A.2. Todos os contactos devem estar indexados com os respetivos modelos de calibração para ambos os hops, ou pelo menos um de cada contacto existente. De modo a relacionar esta informação criou-se uma **Multi-hop Viewer** (ver anexo A, figura A.3). Apresenta só os contactos válidos mais recentes e os seus respetivos modelos e parâmetros. A tabela **Default sensors** é uma vista das tabelas dos diferentes sensores onde se armazena os seus dados calibrados. Para criação desta base de dados foi preciso garantir certas relações com a base de dados principal, onde se armazena os dados *Raw*. A indexação dos dados à base de dados principal é feita pelas tabelas: **Deployment, Node, sensor e location**. Elas são chaves externas na nova base de dados na tabela **Foreign keys**. Esta tabela permite a sincronização dos dados de ambas as base de dados. Implementação no Anexo A, figura A.1.

A *framework* dispõe de duas metodologias de calibração, a *Stream Calibration* para calibração em tempo real dos dados recém-chegados, e a *Fault Calibration* que ocorre uma vez por dia para correção de falhas ocorridas pelo processo de *Stream Calibration* (ver anexo B, figura B.1). Para detetar a chegada das medições ao *Backoffice* foi desenvolvido um mecanismo de notificações. Para isso foi modificado o módulo *Data Server*, (ver figura 3.5), de modo a conectar-se ao serviço disponibilizado por a *framework* para receber as notificações das novas medições. Foi estabelecido um protocolo de comunicação entre dois sistemas, este utiliza comunicações TCP/IP para envio das notificações, (ver figura 3.7 e anexo B.2), e para correção das falhas ocorridas pelo processo de *Stream Calibration*, dispõe de um mecanismo de correção de falhas, (ver anexo B, figura B.2).




Figura 3.7: Mensagem de notificações para a calibração em tempo real

A *framework* tem o papel de servidor deste meio de comunicação, e cada DCU conecta-se como cliente através do *Data Server* à *framework*, notificando-a dos seus novos dados recolhidos,

através da mensagem apresentada na figura 3.7. A notificação indica à *framework* qual a DCU, o sensor e o seu *timestamp* necessário para a *framework* aplicar a calibração a este valor. A perda de pacotes durante o envio dos dados ou mesmo no sistema de notificações implica que esse valor não tenha sido calibrado. No entanto também há a probabilidade de não estarem disponíveis todas as condições para a sua calibração. A *Fault Calibration* vem corrigir estes problemas, calibrando as falhas das últimas 24 horas de funcionamento, (ver anexo B, figura B.1).

A *framework* dispõe de uma *interface web* para manutenção dos modelos de calibração, como é acompanhado por um ficheiro de configuração que deve ser previamente configurado antes do seu funcionamento B.1. Este ficheiro permite configurar a conexão às duas base de dados, a dos dados *raw* e a dos calibrados. O servidor do serviço de notificações também é configurado aqui. Para agendar a hora do funcionamento periódico da *Fault Calibration* deve-se recorrer também a este ficheiro. O mesmo para cativar os sensores a serem calibrados e o atraso que as dependências podem ter para ser usadas na sua calibração.

3.3 Integração dos modelos de calibração

Para integração dos modelos de calibração com a *framework* é necessário estabelecer algumas normas/padrões. A figura 3.8 mostra a arquitetura da integração dos modelos com a *framework*. Ela pode ser feita para três diferentes níveis de operação, o nível 2 e 3 diretamente relacionados com a estratégia a dois hops e o nível 1 para pré-processamento de dados se necessário. Assim garante-se o controlo dos diferentes hops e respetivos modelos, por parte do utilizador como da *framework*.




Figura 3.8: Arquitectura da integração dos modelos de calibração

Os modelos são constituídos por uma função ou algoritmo e pelos seus parâmetros, sendo a *framework* responsável pela sua aplicação. Estas funções/algoritmos terão que estar implementadas em programas executáveis configuráveis com os diferentes parâmetros. Os parâmetros estão destinados a cada hop, eles devem cumprir o formato requerido pelo algoritmo. Os algoritmos também devem suportar *Datasets* como *input* e *output*, para receber os dados *raw* e retornar os dados calibrados para a *framework*. Veja o exemplo na figura 3.9a de um modelo de calibração.




Figura 3.9: Support calibration models

No entanto a *framework* também está projetada para gerar a parametrização dos novos contactos automaticamente, com tudo o processo ainda está em desenvolvimento. Há uma necessidade dos primeiros modelos serem acompanhados durante a sua criação por um profissional, eliminando os erros existentes obtendo uma operação mais estável. Quando este passo estiver estabelecido, pode-se introduzir as funções de treino na *framework*, contudo deve-se manter o acompanhamento e a avaliação dos parâmetros gerados. Exemplo de um modelo de treino na figura (3.9b).

3.3.1 Requisitos

Deve ser cumprido um conjunto de requisitos para garantir o correto funcionamento de todo o processo de calibração. Os diferentes tipos de modelos de calibração devem estar implementados num programa executável, compatível com sistemas Linux. Eles podem ser desenvolvidos em qualquer linguagem compatível, no entanto deverá ser compilado antes de ser integrado na *framework*. A *framework* também tem suporte para linguagens *scripting*. O executável deverá suportar no mínimo dois argumentos na sua chamada, o primeiro para input dos dados *raw* e o segundo como output dos dados calibrados. No entanto pode suportar mais argumentos para configuração do algoritmo, estes devem ser especificados durante a sua integração. A *framework* dá suporte a dois formatos de dados CSV ou JSON, deverá optar por um deles. A *framework* dá suporte a três tipos de operação por parte dos modelos para os diferentes níveis da figura 3.8, eles são:

- **Preprocessing:** Algoritmos de pré-processamento dos dados para o nível 1;
- **Predict:** Modelos de calibração para os níveis 2 e 3;
- **Training:** Algoritmos de treino para os níveis 2 e 3.

No entanto só se encontra em funcionamento o tipo *Predict* para calibração da plataforma. Os outros encontram-se em desenvolvimento, dependendo dos requisitos que venham apresentar pelo sensor durante a primeira calibração. Os parâmetros destinados aos diferentes algoritmos existentes na plataforma devem cumprir com o formato estabelecido pelo algoritmo. A ordem de inserção destes parâmetros deve ser a mesma da execução, no caso da equação 2.1 a ordem deve ser (β_0, β_1) . Todos os parâmetros devem ser identificados com um ID que relaciona à unidade

a quem pertence estes parâmetros, ela pode ser *Mobile DCU Reference* para o modelo (*Ground Truth - DCU*), ou *Active DCU* para o modelo (*DCU - DCU*). A parametrização de cada hop tem a disponibilidade de configurar a operação do algoritmo usando argumentos durante a sua chamada de execução.

3.3.2 Instalação

Para facilitar o processo de integração dos modelos de calibração com a *framework*, foi desenvolvida uma *interface web* que permite a gestão dos diferentes modelos existentes como a inserção de novos. Existe uma ordem de inserção estabelecida que deve ser cumprida, de modo a satisfazer as dependências de todos os módulos. Para introdução de um modelo de calibração de um sensor de uma *Active DCU*, deve-se verificar se os algoritmos pretendidos já se encontram desenvolvidos e integrados na plataforma, Caso contrário deverá prosseguir com o seu desenvolvimento e instalação através da página da web, na área de administração da *framework* de calibração. Um exemplo encontra-se no anexo C.1, igual ao que irá encontrar na plataforma online. A descrição dos diferentes campos do formulário é a seguinte:

1. Ficheiro executável;
2. Descrição do algoritmo;
3. Formato dos dados de *Input / Output*;
4. Se está em operação permanente, ou se executa só quando necessário;
5. Tipo de operação e de modelo;
6. Numero de dependências suportadas;
7. Constantes do algoritmo;
8. Argumentos de configuração separado por vírgulas, caso necessário.

Após a inserção dos algoritmos, pode-se então prosseguir com a integração dos parâmetros para os diferentes hops e sensores. Primeiro começa-se por inserir o modelo (*Ground Truth - DCU*), relativo ao segundo hop, ver figura 3.8. Só depois poderá inserir os parâmetros relativos ao primeiro hop, devido a estes estarem interligados. Então, caso não exista nenhum modelo (*Ground Truth - DCU*) para seleccionar durante a inserção do modelo (*DCU - DCU*) terá de o fazer em primeiro lugar. O formulário de inserção da parametrização são iguais para ambos os hops, os seus campos são:

1. ID do modelo (*Ground Truth - DCU*), pode seleccionar ou introduzir um novo escolhendo (*New...*);
2. ID do algoritmo matemático a quem se destina a parametrização;

3. Sensor respetivo;
4. Parâmetros da função de calibração separado por vírgulas;
5. Data da descontinuação do modelo, quando descontinuado;
6. Argumentos para configuração do algoritmo, caso necessário;
7. Métricas estatísticas CORR, MAE e RMSE;
8. Respetivo *deployment ID* da unidade a quem pertence a calibração *Active/Reference/Mobile DCU*;

O número 1 deste formulário representa o modelo (*Ground Truth - DCU*), deve ser sempre seleccionado um existente, caso contrário devera escolher a opção (*New...*).

Assim permitimos o funcionamento e controlo da *framework* da calibração de toda a plataforma, permitindo recalibração com a introdução de modelos mais atualizados.

Capítulo 4

Resultados

Os resultados obtidos pelos diferentes testes realizados ao longo desta dissertação vem descritos neste capítulo. Inicialmente, foram feitos estudos aos sensores *low-cost* que equipam a plataforma, de modo a avaliar a sua correlação. Seguidamente, procedeu-se a uma avaliação da sua qualidade de sensorização verificando a sua correlação com sensores *Ground Truth* em ambientes urbanos, de modo a compreender o seu comportamento perante este tipo de ambientes. Por último apresentamos os resultados dos modelos de calibração preliminares para os diferentes hops, usando um cenário real instalado numa das zonas da cidade. Estes modelos foram implementados para prova de conceito do funcionamento da *framework*.

4.1 Avaliação dos sensores

A avaliação dos sensores *low-cost* passa por várias fases. Inicialmente verificou-se a sua qualidade comparando-os com o Ground Truth, detectando os diversos problemas que os sensores apresentam através de diversos estudos. Foram realizados testes entre sensores iguais, de modo a avaliar a sua correlação. Eles também ajudaram a analisar alguns problemas apresentados pelos sensores. Os testes tiveram como base o uso de ambientes urbanos na cidade do Porto.

4.1.1 Qualidade dos sensores *low-cost*

Uma primeira análise a ser realizada foi avaliar a qualidade dos sensores em ambientes urbanos. Este estudo teve lugar na Praça Velasquez durante um período de 75 dias. Foi avaliada a correlação de cada sensor com o *Ground Truth*, os resultados encontram-se na tabela 4.1.

Como se pode visualizar na tabela 4.1, os sensores de temperatura e humidade apresentam um valor de correlação muito alto, perto de 90%. Um valor alto de correlação indica que os sensores tem um comportamento semelhante, o que é um indicador positivo. Demonstram uma boa qualidade de sensorização para ambientes urbanos por parte de estes sensores. O uso de regressões lineares simples, (ver equação 2.1), para estes dois sensores, será o suficiente para a sua calibração. Eles não demonstraram dependência por parte de outros fatores ambientais durante os estudos realizados. No entanto como mencionado no artigo da Urbansense (Luis Rojo et al.,

Sensor	Correlation	Samples
Ozone	0.69	58809
Nitrogen dioxide	0.32	58712
Carbon monoxide	0.05	8641
Carbon monoxide*	0.55	8641
Temperature	0.88	25773
Humidity	0.87	23977

Tabela 4.1: Correlação de spearman com o Ground Truth

2016), em contacto com ambientes propícios a elevados níveis de humidade relativa, como em zonas marítimas, têm tendência a danificar-se mais rápido do que em zonas mais afastadas do mar. Contudo, os que se encontram instalados dentro da cidade do Porto sobreviveram a um ano de funcionamento sem apresentar grandes preocupações.

Já os sensores de gases demonstraram algumas deficiências de sensorização em ambientes urbanos como se pode ver pela baixa correlação obtida com o *Ground Truth*. Como descrito no capítulo 2, estes sensores sofrem de distintos problemas. As baixas correlações necessitam de estudos mais aprofundados, de modo a detetar quais os problemas existentes nestes sensores. Os sensores mais delicados são os de gases. As suas baixas correlações podem estar diretamente relacionadas com a sensibilidade cruzada ou a sua incapacidade de deteção das baixas concentrações que se encontram na atmosfera urbana.

4.1.2 Sensibilidade cruzada dos sensores *low-cost*

Um dos principais fatores de distúrbio apresentados pelos sensores de gases usados foi problemas de sensibilidade cruzada. Deve-se à reação química que usa para deteção do composto que se quer medir, tende a reagir com outros compostos químicos presentes na atmosfera. Analisou-se a correlação entre os diferentes sensores de qualidade do ar, temperatura e humidade, afim de entender quais os fatores interferentes, (ver figura 4.1). Para este estudo foi utilizada uma DCU que teve o maior tempo de funcionamento sem anomalias, instalada na cidade do Porto. Com um período de 4 meses e com 1358764 amostras gerou-se a matriz de correlação entre os sensores *low-cost*, (ver figura 4.1). Pode-se verificar na diagonal da matriz a distribuição de cada sensor. No triângulo superior apresenta a correlação e no inferior a regressão.




Figura 4.1: Matriz de sensibilidade cruzada dos sensores *low-cost* disponíveis na plataforma Urbansense num período de seis meses

O sensor de CO apresenta alguma correlação com a temperatura, (é esperado que tal aconteça). Como descrito no seu *Datasheet*, sofre ligeiras alterações com diferentes variações de temperatura. Também já é um problema descrito no capítulo 2, onde são apresentados os problemas já conhecidos. O sensor de NO_2 e de O_3 também apresentando uma pequena correlação com a temperatura, acima dos 10%. Estes valores refletem-se mais durante um estudo realizado no cenário de calibração na Praça Velásquez, durante um período de 75 dias. Pode verificar na figura 4.2.




Figura 4.2: Matriz de correlação de sensibilidade cruzada entre os sensores HQ e *low-cost* em ambiente urbano

No entanto o sensor de CO como se pode ver na tabela 4.1 e nas matrizes de correlação 4.2 e 4.1 apresentam correlações praticamente nulas. Isto é devido às concentrações permanecerem a maioria do tempo abaixo do limite de detecção de 5 ppm, (ver figura 4.4). Por esse motivo, e como podemos observar na 4.3, as leituras do sensor de CO apresentam bastante ruído. Foi aplicado um filtro passa baixo do tipo (*Blackman*) ao sinal obtido por o sensor de CO. O resultado foi positivo: a eliminação do ruído como mostra a figura 4.3, fez com que houvesse melhoria da correlação para 55% com o *Ground Truth*.




Figura 4.3: Aplicação de um filtro passa baixo ao sinal de CO

Também se pode verificar uma elevada correlação entre o sensor de NO_2 e O_3 . Este é um caso preocupante, tendo sido necessário perceber se os sensores eram realmente de NO_2 e O_3 , ou se existiu alguma troca durante o seu fabrico ou montagem. Outra possibilidade é o sensor ser muito sensível às concentrações de O_3 .

4.1.3 Análise ao sensor de NO_2

Tem havido vários casos em que os sensores de NO_2 apresentam uma correlação elevada com o sensor de O_3 . Achamos que o NO_2 é o portador do problema, devido ao sensor de O_3 apresentar melhores resultados com o *Ground Truth* na tabela 4.1. Analisou-se este acontecimento a todas as unidades disponíveis na Urbansense. Os resultados estão na tabela do anexo D.1. Pode-se verificar uma grande instabilidade por parte do sensor de NO_2 , apresentando valores da correlação muito baixos nas suas medições.

Colocamos a hipótese de o sensor de NO_2 realmente ser demasiado reativo a diferentes concentrações. Utilizamos o mesmo cenário urbano para realizar mais estudos a estes sensores por um período de 1 mês. Verificou-se a correlação entre estes dois sensores e os seus respetivos sensores de alta qualidade, (ver figura 4.5).




Figura 4.4: Baixas concentrações de CO em ambiente urbano durante o período de teste

Podemos concluir que o problema provém do sensor de NO_2 , ele apresenta uma correlação nula com o *Ground Truth* e uma grande com o sensor O_3 de alta qualidade. Isto demonstra que o sensor pode estar trocado, (os sensores de NO_2 e de O_3 têm aspeto semelhante, não sendo possível distingui-los pela sua aparência), ou então, ser muito sensível às concentrações de Ozono. Resultados semelhantes foram obtidos durante um estudo realizado pela Universidade de Aveiro, utilizando sensores iguais aos aqui estudados (WG1). Os resultados da matriz de correlação obtida encontram-se no anexo D.1, podemos verificar que se deparam com o mesmo problema.

Ao verificarmos as concentrações reais de NO_2 durante o período de teste, (ver figura 4.6), detetou-se que grande parte das concentrações estão abaixo do limite de deteção de 0.05 ppm. Este é um fator propício para sofrer maiores interferências por terceiros.

Para concluirmos a causa do problema do sensor recorremos a testes em laboratório com um ambiente controlado. Como se pode verificar na figura 4.7, o sensor demonstra um comportamento muito idêntico com o de alta qualidade. No entanto o sensor de O_3 , também presente neste teste, manteve-se estático concluindo assim que os sensores são realmente de O_3 e NO_2 . A correlação obtida neste teste para o sensor de NO_2 com o seu *Ground Truth* foi de 24%, abaixo do esperado. Contudo é bastante compreensível devido ao facto de teste possuir apenas 23 observações com um intervalo de tempo de 1 minuto, o mínimo que o *Ground Truth* suportava.

Podemos assim concluir que este sensor devido às concentrações mais elevadas de O_3 e as baixas de NO_2 presentes, não consegue detetar as concentrações de NO_2 . Este sensor devido a isso deixa-se afetar significativamente pelas concentrações de O_3 . Não é um sensor aconselhável para estes tipos de plataformas e propósitos.




Figura 4.5: Correlação, distribuição e linearidade do O_3 e NO_2

4.1.4 Coerência dos sensores *low-cost*

Para avaliarmos a correlação dos sensores entre si, usamos duas unidades iguais, durante o mesmo período de 75 dias no mesmo cenário urbano. No entanto o número de amostras é relativamente baixo devido a algumas falhas apresentadas pelas DCUs. Pode-se verificar na tabela 4.2 as correlações obtidos entre sensores iguais.

Sensor	Correlation	Samples
Ozone	0.99	21001
Nitrogen dioxide	0.95	20127
Carbon monoxide	0.20	30128
Carbon monoxide*	0.77	9128
Temperature	0.97	15027
Humidity	0.96	14541

Tabela 4.2: Correlação spearman entre sensores *low-cost* iguais

Os resultados obtidos durante os testes, tabela 4.2, são bastantes positivos. Todos os sensores demonstram uma alta correlação entre si, até mesmo o de CO quando aplicado o filtro passa baixo. Apesar das concentrações serem muito baixas, muitas vezes abaixo do limite mínimo de detecção por parte destes sensores, apresentam uma boa correlação entre si. Podemos esperar erros muito baixos por parte dos modelos do primeiro hop. Assim implicará um pequeno erro à qualidade da calibração multi-hop. No entanto sabemos que estes resultados conseguem ser melhorados.




Figura 4.6: Baixas concentrações de NO_2 em ambiente urbano durante o período de teste

Estes estudos são preliminares, dedicados a compreender melhor os sensores com que estamos a trabalhar.

4.2 Calibração com o *Ground Truth* - segundo hop

Os resultados dos modelos gerados para os diferentes sensores partem dos estudos anteriormente descritos. Os resultados dos diferentes modelos são apresentados a seguir.

4.2.1 Derivação dos modelos do segundo hop

Para se perceber quais as concentrações que afetam estes sensores, gerou-se uma matriz de correlação entre os principais sensores disponíveis na plataforma. De modo a entender melhor o seu comportamento, (ver figura 4.1). O elevado valor de correlação entre os diferentes sensores de gases, indicam o grau de sensibilidade cruzada existente entre esses sensores. No entanto é possível verificar que esses sensores também apresentam alguma correlação com a temperatura e humidade, como descrito no *datasheet* destes sensores. Assim para um melhor ajuste das curvas de calibração é conveniente usar estes atributos correlacionados como *Input* durante o treino dos modelos.

Os modelos estudados para prova de conceito da *framework* de calibração, partiram do mesmo cenário real que os testes anteriores, criado na cidade do Porto. O cenário foi criado de forma a conseguir reproduzir a calibração multi-hop. Para isso, esta dispõe de sensores de alta qualidade





Figura 4.7: Teste em laboratório do sensor de NO_2

para Temperatura, Humidade, Ozono, Monóxido de Carbono e Dióxido de Nitrogénio. Também estão presentes várias DCUs para desempenharem o papel de *Mobile / Reference DCU* e *Active DCU* o requisitado pela estratégia de calibração estabelecida, (ver figura 3.1). Os dados utilizados para o estudo dos modelos são relativos ao período entre 11 de Maio a 5 de Julho de 2016, com uma frequência de amostragem de um minuto. Foi criada uma matriz de correlação de sensibilidade cruzada entre os sensores *low-cost* e os de alta qualidade, (ver figura 4.2). O intuito é perceber como se mantém o comportamento dos sensores, face aos problemas apresentados. Podemos verificar que o sensor de Temperatura e Humidade mantém uma alta correlação com o *Ground Truth*, 87% para a Humidade e 89% para a Temperatura. No entanto, entre os sensores de Humidade e Temperatura tanto os *low-cost* como os *Ground Truth* apresentam uma correlação negativa muito alta, mostrando um padrão de funcionamento entre os *low-cost* e os *Ground Truth*. Isto demonstra a qualidade que estes sensores dispõem, e a importância que terá para os modelos dos sensores de gases.

Durante os testes realizados na praça Velázquez, verificou-se as sensibilidades cruzadas dos sensores comparando com os respetivos sensores de alta qualidade, (ver figura 4.2). O primeiro estudo realizado (ver figura 4.1), apenas apresenta os sensores *low-cost* disponíveis na plataforma. Neste teste, o sensor de NO_2 continua a apresentar uma correlação altíssima com o O_3 de 93%. As concentrações presentes de NO_2 continuam muito baixas durante o período de teste, afetando a leitura do sensor. No entanto demonstrou um aumento em relação com o *Ground Truth*, com 31% de correlação. O sensor de O_3 obteve a pior prestação de todos os testes realizados, com 24% de

correlação com o *Ground Truth*. Poderá estar relacionado com a época do ano e com os diferentes padrões de concentrações apresentados.

Figura 4.8: Distribuição das concentrações presentes durante os dois testes



As figuras 4.8, mostram a distribuição das concentrações presentes durante os dois testes realizados. Pode-se verificar uma diferença relevante nas concentrações de temperatura e humidade. Como conhecido, estes fatores tem grande impacto na sensibilidade dos sensores de gases. Também apresenta problemas de interferência por parte dos compostos de NO_2 e para diferentes níveis de temperatura. O CO no entanto continua muito distante do seu propósito (ver figura 4.2). Não apresenta correlação com o *Ground Truth*, contudo sofre interferências de Temperatura, Humidade e de O_3 . A sua correlação nula é devido às concentrações de CO permanecerem abaixo de 5 ppm, limite mínimo de deteção do sensor, medindo imenso ruído. Na figura 4.4 encontra a variação de CO que se verificou durante o experimento. No entanto, é possível obter informação útil no meio desse ruído, como descrito nos estudos realizados a este sensor.

Todos estes estudos realizados, permite-nos adquirir conhecimento sobre o funcionamento dos sensores *low-cost*. Eles foram importantes para a criação dos modelos de calibração. A tabela 4.3 apresenta os resultados para os diferentes modelos treinados para calibração dos sensores.

Sensor	Model	Dependencies	Corr	MAE	RAE
Temp. (°C)	LR	-	0.87	0.89	40%
	MLR	Humid.	0.96	0.56	27.34%
	REPTree	Humid.	0.85	0.88	39%
Humid. (%)	MLP	-	0.96	4.90	43.64%
	MLR	Temp. O_3	0.94	5.23	47%
	LR	-	0.95	2.27	28.57%
O_3 (mg/m ³)	REPTree	Temp. Humid.	0.95	0.0018	25.54%
	MLP	Temp. Humid.	0.90	0.0027	39%
	MLR	Temp. Humid.	0.93	0.0035	44.17%
CO (mg/m ³)	MLP	Temp. Humid. O_3	0.69	0.22	93.8%
	MLR	Temp. Humid. O_3	0.63	0.16	70%

Tabela 4.3: Avaliação dos modelos de calibração do segundo hop

Numa forma geral os resultados dos modelos são bastante positivos. Para a Temperatura o erro do modelo (*Ground Truth* - *DCU*) não chega a 1C, já a humidade apresenta um erro aproximado de 2% de humidade relativa com o uso de uma regressão. O sensor de O_3 apesar dos últimos resultados obtidos, demonstrou-se capaz de obter um modelo de calibração bastante ajustado, apresentando uma correlação de aproximadamente 95% e com um erro de $0.0018mg/m^3$. Como se pode verificar, o sensor de CO com a aplicação de um filtro passa baixa para eliminar o ruído sofrido, fez com que melhore-se a sua correlação com o *Ground Truth* para aproximadamente 60%. Analisando a tabela ??, onde-se apresenta o limiar legislado (*ccd*) para as diferentes concentrações, só o sensor de CO apresenta um erro superior a este valor. O sensor de NO_2 ficou de fora deste teste, devido a apresentar grandes correlações com o de O_3 .

4.3 Calibração do primeiro hop

Numa estratégia de calibração multi-hop, deve-se ter em atenção ao erro acumulado, ele é diretamente proporcional ao número de hops. Neste caso só dispomos de dois hops, que se traduz num baixo erro acumulado esperado. Este hop tende a sofrer de menos problemas do que o segundo hop, no entanto alguns testes foram realizados para validação da estratégia.

4.3.1 Derivação do modelo (*DCU* - *DCU*)

O modelo (*DCU* - *DCU*), permite ajustar as *Active DCUs* às de referência. Estas já dispõem de modelos de calibração para cada sensor com o *Ground Truth*. Os resultados obtidos dos modelos treinados para este hop encontra-se na tabela 4.4.

Sensors	Model	Corr	MAE	RAE	Samples
Temp. (°C)	LR	0.96	0.53	24.96%	55866
Humid. (%)	LR	0.99	1.11	6.86%	46343
O_3 (Volts)	LR	0.99	0.02	5.16%	51424
NO_2 (Volts)	LR	0.99	0.03	7.09%	56189
CO (volts)	LR	0.24	0.0011	98.34%	56191
CO filter (Volts)	LR	0.79	0.0014	306.44%	56191

Tabela 4.4: Avaliação dos modelos do primeiro hop

Todos os modelos treinados são regressões lineares simples, (ver equação 2.1). Este hop não apresentou por enquanto nenhum tipo de interferência sofridas por outros compostos. Elas são corrigidas nos modelos do segundo hop. Os gráficos das regressões dos diferentes modelos encontram-se na figura 4.9. Conseguimos verificar a correlação entre eles, que correspondem aos resultados obtidos na tabela 4.4. O maior erro continua a pertencer ao sensor de CO. O seu modelo (LR) 2.1 dispõe de um coeficiente angular¹ a tender para zero. Quer dizer que as variáveis não são correlacionadas. Para uma regressão linear perfeita e positiva o coeficiente de correlação deve ser igual a 1 com um ângulo de 45 °.

4.4 Calibração multi-hop

Foi aplicado a estratégia multi-hop, (ver figura 3.1), com os modelos previamente treinados. Os modelos aplicados estão representados na tabela 4.3 a cor vermelha para o segundo hop, e os da tabela 4.4 para o primeiro hop. Foram calibrados três dos sensores disponíveis na plataforma, Temperatura, Humidade e Ozono apresentados como os sensores mais estáveis, e com a disponibilidade dos diferentes meios para realizar a calibração.

Sensors	Corr	MAE	Instances
O_3 (mg/m^3)	0.89	0.0043	29509
Temperature (°C)	0.88	1.08	57237
Humidity (%)	0.94	4.27	51171

Tabela 4.5: Avaliação da calibração multi-hop


A tabela 4.5 mostra os resultados da implementação da estratégia multi-hop da figura 3.1. Utilizando o cenário Praça Velasquez, equipado com diversas DCUs e sensores de alta qualidade, simulamos a estratégia multi-hop calibrando-a com a *framework* implementada. Mesmo usando modelos preliminares, sem um estudo muito detalhado foi possível obter resultados positivos. Os gráficos 4.10, resultantes dos resultados da tabela 4.5 demonstram a qualidade dos modelos gerados. Todos mantêm uma boa relação com o *Ground Truth*, conseguindo uma boa aproximação da realidade.

Sensor	Limiar legislado		
	mg/m^3	ppm	ppb
O_3	0.12	0.057	56.8
NO_2	0.09	0.05	50
CO	10	8.11	8110

Tabela 4.6: Valores limiares mínimos legislados

¹Declive da reta que representa a regressão linear.


Figura 4.9: Primeiro hop, respectivo ao modelo ($DCU - DCU$) baseado em regressão linear



Verificando o perfil do O_3 da figura 4.10, ele não atinge valores acima de $0.030\text{mg}/\text{m}^3$. Este valor encontra-se muito abaixo do máximo limiar legislado de $0.12\text{mg}/\text{m}^3$, (ver tabela ??, (ccd)). O erro do modelo multi-hop do sensor de O_3 é 3% do limiar legislado, conseguindo facilmente detetar concentrações abaixo desse valor. Ele mostra capaz de sensorizar as baixas concentrações em ambientes urbanos.

A estratégia mostrou-se capaz de superar o problema de calibração da plataforma, no entanto os modelos devem ser criados com maior detalhe para todos os sensores.

Figura 4.10: Calibração com a estratégia multi-hop desenhada, utilizando a *framework* de calibração para integração dos modelos treinados



Capítulo 5

Conclusões

Neste trabalho foi feita uma avaliação global aos sensores que equipam a plataforma Urban-sense, de modo a desenhar a estratégia de calibração mais adequada para a plataforma. Este projeto permitiu adquirir conhecimentos importantes sobre o funcionamento destes sensores em ambientes urbanos, tendo-se conseguido identificar os seus problemas.

As unidades de sensorização desenvolvidas (DCUs), de uma forma geral, cumprem os objetivos de sensorização em ambientes urbanos. A sua capacidade de deteção de diferentes compostos presentes na atmosfera das cidades a partir de sensores *low-cost*, é relevante para projetos futuros. Os sensores digitais presentes nas DCUs demonstraram ser mais fiáveis do que os sensores analógicos dado que são disponibilizados com uma calibração de fábrica. No entanto esta calibração (que tipicamente lineariza o output do sensor) nem sempre é suficiente, sendo necessário uma calibração posterior. O sensor de NO_2 não é adequado para ambientes urbanos, dado que é demasiado sensível às concentrações de O_3 . O sensor de O_3 demonstra ser adequado para operar em ambientes urbanos. O sensor de CO apresentou medições muito ruidosas devido às baixas concentrações observadas. Contudo é possível obter alguma informação útil, embora pouco precisa devido ao ruído. Por isso, o é recomendável a substituição dos sensores de NO_2 e CO .

A arquitectura da *Framework* de calibração automatiza grande parte do processo de calibração. A estratégia de calibração multi-hop implementada na plataforma mostrou ser adequada para a calibração dos sensores. Esta estratégia permite uma deteção eficaz de cada contacto entre unidades (movéis e fixas) para efectuar a recolha de dados a serem utilizados para treino dos modelos de calibração. A calibração dos dados em si é efectuada centralmente, no servidor Backoffice da plataforma, ao contrário de outras soluções que calibram os dados directamente nas unidades de sensorização. É aplicada uma calibração *Streaming* à medida que os dados chegam ao servidor central.

5.1 Trabalho futuro

Para trabalho futuro é necessário incorporar na plataforma módulos para treino e avaliação dos modelos de calibração. Pretende-se também concluir a implementação da *interface web* de gestão

da plataforma de calibração.

É necessário acompanhar o funcionamento dos processos de calibração, de modo a detetar possíveis problemas que surjam. Iremos, também, proceder a testes de desempenho da plataforma para grandes fluxos de dados de sensorização.

Outro aspecto a focar no futuro é a realização de estudos mais aprofundados aos sensores de qualidade do ar, de forma a melhorar a qualidade das medições. Finalmente, procederemos ao estudo de outros sensores das unidades de sensorização (e.g., luminosidade, ruído, partículas) que não foram abordados neste trabalho.

Anexo A

Base de dados de calibração

Listing A.1: Integração da base de dados.

```
1 REATE SERVER foreign_server
2     FOREIGN DATA WRAPPER postgres_fdw
3     OPTIONS (host 'localhost', port '5432', dbname 'urbansense');
4
5 CREATE FOREIGN TABLE deployment_ft (
6     deployment_id serial NOT NULL,
7     description text,
8     node_id integer NOT NULL,
9     type_id integer NOT NULL,
10    location_id integer,
11    dep_start timestamp without time zone NOT NULL,
12    dep_end timestamp without time zone
13 )
14     SERVER foreign_server
15     OPTIONS (schema_name 'public', table_name 'deployment');
16
17 CREATE FOREIGN TABLE node_ft (
18     node_id serial NOT NULL
19 )
20     SERVER foreign_server
21     OPTIONS (schema_name 'public', table_name 'node');
22
23 CREATE FOREIGN TABLE location_ft (
24     location_id serial NOT NULL,
25     description text NOT NULL
26 )
27     SERVER foreign_server
28     OPTIONS (schema_name 'public', table_name 'location');
```

Listing A.2: Detecção e inserção do momento de contacto.

```
1 INSERT INTO contact (node_id, refnode_id, location_id, date_start, date_end, status)
2 (SELECT act.node_id as active_node,
```


Anexo B

Arquitetura da *Framework*

Listing B.1: Configuração da *Framework*.

```
#####
# \textit{Framework} configurations
#
# Notification trigger server #
#####
serverport      9999

#####
# RAW DB #
# Database configurations #
#####
r.hostaddr      [IP address]
r.port          [Port]
r.username      [Username]
r.password      [Password]
r.database      [Database name]

#####
# CALIBRATION DB #
# Database configurations #
#####
c.hostaddr      [IP address]
c.port          [Port]
c.username      [Username]
c.password      [Password]
c.database      [Database name]

#####
# To Calibrate the Failures: #
# Running time daily [time] #
#####
time           18:56:00

#####
# To Calibrate: #
#####
# Enable or disable the fields
$O_3$
no2
co
temperature
humidity
# particles
# luminosity
# noise
# perceptitation
# anemometer
# windwave
# solarradiation

#####
# Dependencies interval (SECONDS) #
#####
$O_3$_int       1200
no2_int         1200
co_int          1200
temperature_int 1200
humidity_int     1200
particles_int    1200
luminosity_int   1200
noise_int        1200
perceptitation_int 1200
windspeed_int    1200
winddirection_int 1200
solarradiation_int 1200
```

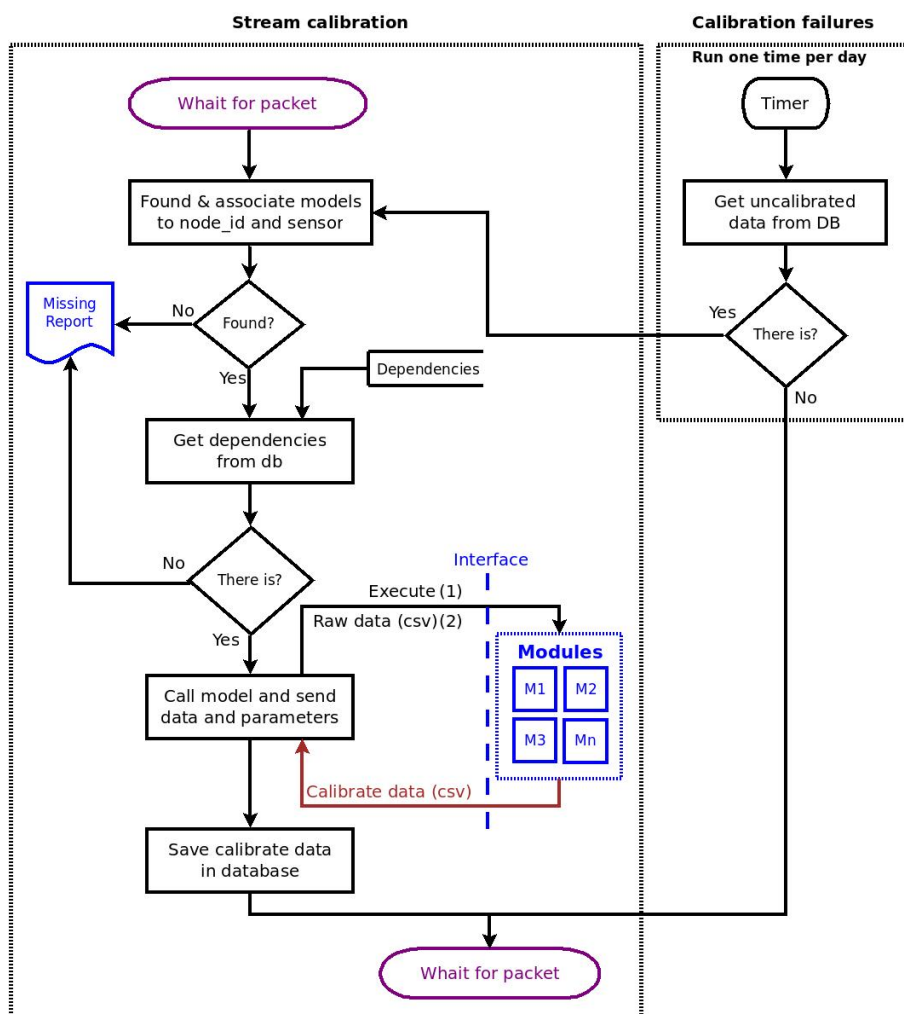


Figura B.1: Metodologia de calibração

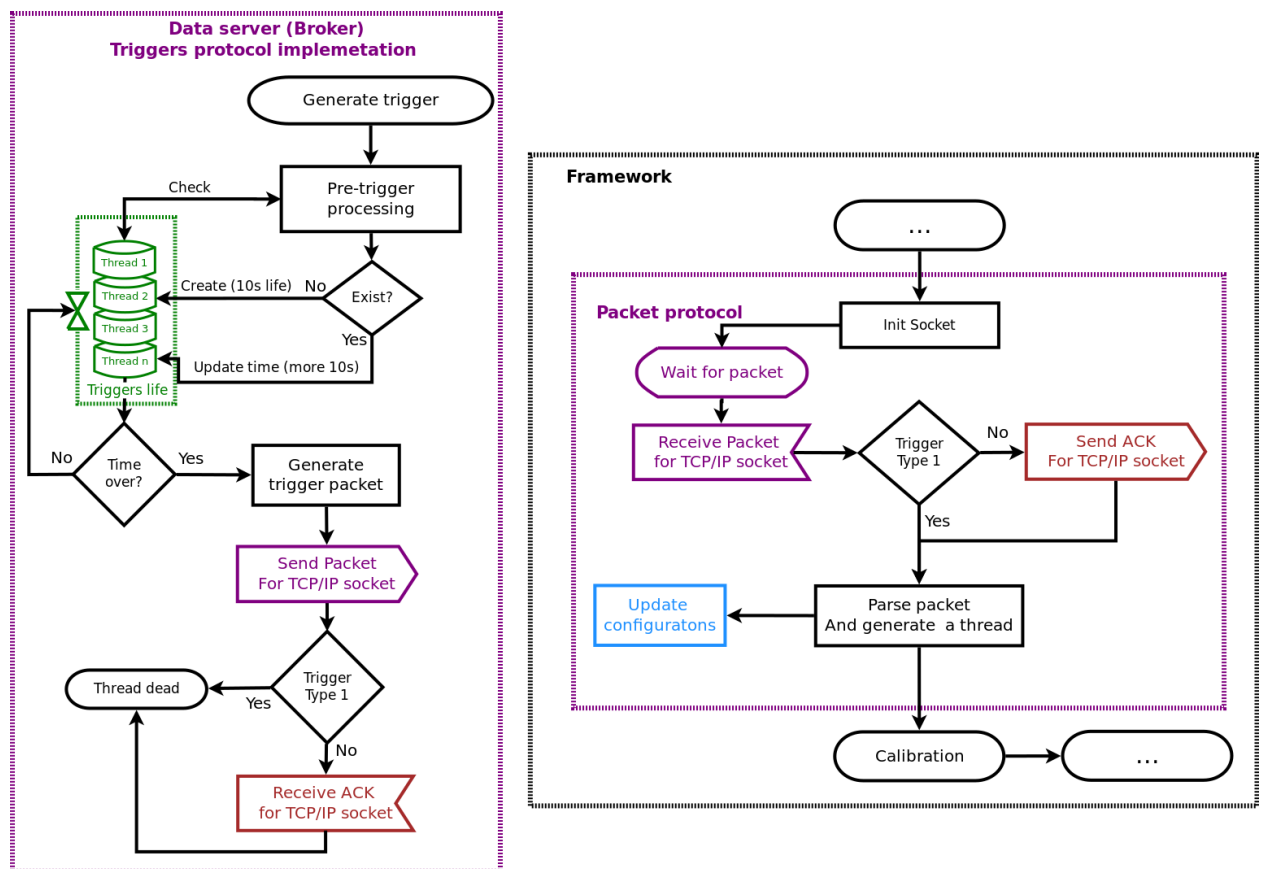


Figura B.2: Protocolo de notificação (Cliente/Servidor)

Anexo C

Integração dos modelos

Urbansense **BETA** Logged in as: yroj

1 File: No file selected.

2 Description:

3 Data format: ☐ CSV ☐ JSON

4 Run type: ☐ Active ☐ Non active

5 Function type: ☐ Evaluate ☐ Statistics ☐ Preprocessing ☐ Predict ☐ Training

6 Dependencies:

7 Parameters:

8 Arguments:

Figura C.1: Inserção do algoritmo de calibração

Urbansense **BETA** Logged in as: tlourenco ▾

1 **Select hop1 or create a new one:**

New... ▾

2 **Function** Linear Regression JSON ▾

3 **Sensor** temperature ▾

4 **Parameters**

Date end

5

6 **Argc**

7 **Quality**

8 **Deployment** FEUP I322 Shannon : Teste no lab do rpi (camara) da rua das flores ▾

Submit

Figura C.2: Inerção da parametrização

Anexo D

Resultados

Micro-sensors													Reference measurements							Meteorological parameters						
CO	O ₃	O ₃	NO ₂	CO	O ₃	CO	NO ₂	SO ₂	NO	NO ₂	NOx	O ₃	PM10	CO	Benzene	Temp	RH	Rad	WV	WD	Prec.					
KOHens	KOHens	KOHens	KOHens	KOHens	KOHens	KOHens	KOHens	ppb	ppb	ppb	ppb	ppb	µg/m ³	ppm	µg/m ³	°C	%	W/m ²	m/s	h	mm					
1,00	-0,03	0,13	0,03	0,71	-0,14	0,91	0,30	-0,26	-0,22	-0,15	-0,20	-0,31	-0,01	-0,04	-0,03	-0,60	0,27	-0,24	-0,01	-0,13	0,12					
-0,03	1,00	0,32	-0,02	0,12	0,84	0,22	-0,12	0,06	-0,43	-0,73	-0,61	0,90	-0,31	-0,74	-0,68	0,32	-0,29	0,11	0,45	0,24	0,10					
0,13	0,32	1,00	0,20	0,19	0,50	0,22	0,05	-0,08	-0,17	-0,20	-0,20	0,18	0,02	-0,14	0,03	-0,33	-0,39	0,04	-0,18	0,05	-0,23					
0,03	-0,02	0,20	1,00	-0,22	0,31	-0,12	0,66	-0,09	-0,03	0,07	0,01	-0,04	0,06	-0,04	0,14	-0,26	-0,15	0,11	-0,32	-0,08	-0,22					
0,71	0,12	0,19	-0,22	1,00	0,02	0,87	0,02	-0,36	-0,27	-0,32	-0,31	-0,20	-0,16	-0,11	-0,20	-0,34	0,31	-0,32	0,00	-0,03	0,13					
-0,14	0,84	0,30	0,31	0,02	1,00	0,06	0,02	0,00	-0,49	-0,71	-0,64	0,83	-0,33	-0,77	-0,67	0,25	-0,27	0,12	0,21	0,20	-0,04					
0,91	0,22	0,22	-0,12	0,87	0,06	1,00	0,16	-0,28	-0,38	-0,38	-0,40	-0,10	-0,19	-0,24	-0,27	-0,49	0,32	-0,32	0,11	-0,05	0,13					
0,30	-0,12	0,05	0,66	0,02	0,02	0,16	1,00	-0,24	0,10	0,25	0,18	-0,24	0,33	0,19	0,25	-0,31	0,16	-0,22	-0,10	-0,21	-0,05					
-0,26	0,06	-0,08	-0,09	-0,36	0,00	-0,28	-0,24	1,00	-0,04	-0,06	-0,05	0,19	-0,13	-0,13	-0,03	0,34	-0,29	0,47	0,18	0,04	0,05					
-0,22	-0,43	-0,17	-0,03	-0,27	-0,49	-0,38	0,10	-0,04	1,00	0,78	0,94	-0,38	0,33	0,76	0,68	-0,01	-0,03	0,01	-0,13	-0,21	-0,05					
-0,15	-0,73	-0,20	0,07	-0,32	-0,71	-0,38	0,25	-0,06	0,78	1,00	0,94	-0,67	0,69	0,87	0,80	-0,12	0,09	-0,05	-0,23	-0,33	-0,13					
-0,20	-0,61	-0,20	0,01	-0,31	-0,64	-0,40	0,18	-0,05	0,94	0,94	1,00	-0,35	0,66	0,86	0,79	-0,07	0,03	-0,02	-0,19	-0,32	-0,09					
-0,31	0,90	0,18	-0,04	-0,20	0,83	-0,10	-0,24	0,19	-0,38	-0,67	-0,35	1,00	-0,31	-0,74	-0,69	0,34	-0,42	0,24	0,41	0,39	0,08					
-0,01	-0,31	0,02	0,06	-0,16	-0,35	-0,19	0,33	-0,15	0,35	0,69	0,66	-0,31	1,00	0,76	0,79	-0,33	0,00	-0,24	-0,31	-0,19	-0,07					
-0,04	-0,74	-0,14	-0,04	-0,11	-0,77	-0,24	0,19	-0,13	0,76	0,87	0,86	-0,74	0,76	1,00	0,89	-0,31	0,23	-0,21	-0,31	-0,43	-0,06					
-0,03	-0,68	0,03	0,14	-0,20	-0,67	-0,27	0,25	-0,05	0,68	0,80	0,79	-0,69	0,79	0,89	1,00	-0,42	-0,01	-0,07	-0,47	-0,30	-0,16					
-0,60	0,32	-0,35	-0,26	-0,34	0,23	-0,49	-0,31	0,34	-0,01	-0,12	-0,07	0,34	-0,33	-0,31	-0,42	1,00	-0,20	0,43	0,63	-0,09	0,13					
0,27	-0,29	-0,39	-0,15	0,31	-0,27	0,32	0,16	-0,29	-0,03	0,09	0,03	-0,42	0,00	0,23	-0,01	-0,20	1,00	-0,68	0,11	-0,31	0,29					
-0,24	0,11	0,04	0,11	-0,32	0,12	-0,32	-0,22	0,47	0,01	-0,05	-0,02	0,24	-0,24	-0,21	-0,07	0,43	-0,68	1,00	0,17	-0,01	-0,12					
-0,01	0,45	-0,18	-0,32	0,00	0,21	0,11	-0,10	0,18	-0,13	-0,23	-0,19	0,41	-0,31	-0,31	-0,47	0,63	0,11	0,17	1,00	-0,24	0,33					
-0,13	0,24	0,05	-0,08	-0,03	0,20	-0,05	-0,21	0,04	-0,21	-0,33	-0,32	0,39	-0,19	-0,43	-0,50	-0,09	-0,31	-0,01	-0,24	1,00	-0,09					
0,12	0,10	-0,23	-0,22	0,13	-0,04	0,13	-0,05	0,05	-0,05	-0,13	-0,09	0,08	-0,07	-0,06	-0,16	0,13	0,29	-0,12	0,33	-0,09	1,00					

Figura D.1: Analise externa das influências dos sensores *low-cost* a outras concentrações através da sensibilidade cruzada e correlação

Tabela D.1: Análize da correlação entre todas as DCUs entre os sensores NO_2 e O_3

Deployment	Location	Correlation
		NO_2 Raw VS O_3 Raw
32761	Praça velasquez	0.83697
35859	Praça velasquez	0.92514
37983	Praça velasquez	0.9208
42832	Praça velasquez	0.9446
22470	Trindade	0.58079
21934	FEUP P1	0.0095
21406	Fundaço Serralves	0.7703
19114	H.S.João	0.50238
18146	Campo Alegre	0.4917
16981	Casa da Musica	0.7338
16080	Estádio do dragão	0.8372
13753	Aliados	0.6318
11804	Bolhão	0.8171
11619	Rua das Flores	0.8369
11436	Campo 24 de agosto	0.4225
9220	Av. França	0.7188
9063	Praça Galiza	0.585
8908	D. Manuel II	0.775
3269	Combatentes	0.601
2489	Praça do marques	0.821

Referências

- Future Cities center of competence for future cities. <http://futurecities.up.pt/site/>. Accessed: 2016-07-13.
- New sensing technologies and modelling for air pollution monitoring. http://www.eunetair.it/cost/meetings/Aveiro/01-PRESENTATIONS/02-AVEIRO_Day_02/T08_TD1105_WGs-Meeting_AVEIRO_GINJA.pdf. Accessed: 2016-07-13.
- Comissão de coordenação e desenvolvimento regional de lisboa e vale do tejo. www.ccdr-lvt.pt/pt/regulamentacao---qualidade-ar/8083.htm. Accessed: 2016-09-13.
- Karl Aberer, Saket Sathe, Dipanjan Chakraborty, Alcherio Martinoli, Guillermo Barrenetxea, Boi Faltings e Lothar Thiele. Opensense: open community driven sensing of environment. In *Proceedings of the ACM SIGSPATIAL International Workshop on GeoStreaming*, páginas 39–42. ACM, 2010.
- Manuel Aleixandre e Michel Gerboles. Review of small commercial sensors for indicative monitoring of ambient gas. *Chem. Eng. Trans*, 30, 2012.
- Elizabeth Bales, Nima Nikzad, Nichole Quick, Celal Ziftci, Kevin Patrick e William Griswold. Citisense: Mobile air quality sensing for individuals and communities design and deployment of the citisense mobile air-quality system. In *2012 6th International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth) and Workshops*, páginas 155–158. IEEE, 2012.
- Jan Beutel, Bernhard Buchli, Federico Ferrari, Matthias Keller e Marco Zimmerling. X-sense: Sensing in extreme environments. In *2011 Design, Automation & Test in Europe*, páginas 1–6. IEEE, 2011.
- David Culler, Deborah Estrin e Mani Srivastava. Guest editors’ introduction: Overview of sensor networks. *Computer*, 37(8):41–49, 2004.
- S De Vito, E Massera, M Piga, L Martinotto e G Di Francia. On field calibration of an electronic nose for benzene estimation in an urban pollution monitoring scenario. *Sensors and Actuators B: Chemical*, 129(2):750–757, 2008.
- Deborah Estrin, Ramesh Govindan, John Heidemann e Satish Kumar. Next century challenges: Scalable coordination in sensor networks. In *Proceedings of the 5th annual ACM/IEEE international conference on Mobile computing and networking*, páginas 263–270. ACM, 1999.
- Deborah Estrin, Lewis Girod, Greg Pottie e Mani Srivastava. Instrumenting the world with wireless sensor networks. In *Acoustics, Speech, and Signal Processing, 2001. Proceedings.(ICASSP’01). 2001 IEEE International Conference on*, volume 4, páginas 2033–2036. IEEE, 2001.

- David Hasenfratz. *Enabling Large-Scale Urban Air Quality Monitoring with Mobile Sensor Nodes*. tese de doutoramento, Diss., Eidgenössische Technische Hochschule ETH Zürich, Nr. 22481, 2015.
- David Hasenfratz, Olga Saukh e Lothar Thiele. On-the-fly calibration of *low-cost* gas sensors. In *European Conference on Wireless Sensor Networks*, páginas 228–244. Springer, 2012.
- Prashant Kumar, Lidia Morawska, Claudio Martani, George Biskos, Marina Neophytou, Silvana Di Sabatino, Margaret Bell, Leslie Norford e Rex Britter. The rise of *low-cost* sensing for managing air pollution in cities. *Environment international*, 75:199–205, 2015.
- Yunior Luis Rojo, Pedro Miguel Santos, Tiago Lourenco, Carlos Penichet, Tania Calçada e Ana C Aguiar. UrbanSense: an urban-scale sensing platform for the internet of things. In *2016 IEEE International Smart Cities Conference (ISC2) (ISC2 2016)*, Trento, Italy, Setembro 2016.
- Rui Meireles, Mate Boban, Peter Steenkiste, Ozan Tonguz e Joao Barros. Experimental study on the impact of vehicular obstructions in vanets. In *Vehicular Networking Conference (VNC), 2010 IEEE*, páginas 338–345. IEEE, 2010.
- Emiliano Miluzzo, Nicholas D Lane, Andrew T Campbell e Reza Olfati-Saber. Calibree: A self-calibration system for mobile sensor networks. In *International Conference on Distributed Computing in Sensor Systems*, páginas 314–331. Springer, 2008.
- Randolph L Moses e Robert Patterson. Self-calibration of sensor networks. In *AeroSense 2002*, páginas 108–119. International Society for Optics and Photonics, 2002.
- R Piedrahita, Y Xiang, N Masson, J Ortega, A Collier, Y Jiang, K Li, RP Dick, Q Lv, M Hannigan et al. The next generation of *low-cost* personal air quality sensors for quantitative exposure monitoring. *Atmospheric Measurement Techniques*, 7(10):3325–3336, 2014.
- Olga Saukh, David Hasenfratz e Lothar Thiele. Reducing multi-hop calibration errors in large-scale mobile sensor networks. In *Proceedings of the 14th International Conference on Information Processing in Sensor Networks*, páginas 274–285. ACM, 2015.
- Laurent Spinelle, Michel Gerboles, Maria Gabriella Villani, Manuel Aleixandre e Fausto Bonavita. Field calibration of a cluster of *low-cost* available sensors for air quality monitoring. part a: Ozone and nitrogen dioxide. *Sensors and Actuators B: Chemical*, 215:249–257, 2015.
- Melissa Tavares. Avaliação de sensores de baixo custo, e de metodos de referência para monitorização da qualidade do ar. *Universidade de Aveiro*, 2015.
- Wataru Tsujita, Akihito Yoshino, Hiroshi Ishida e Toyosaka Moriizumi. Gas sensor network for air-pollution monitoring. *Sensors and Actuators B: Chemical*, 110(2):304–311, 2005.
- Alex Varshavsky, Denis Pankratov, John Krumm e Eyal De Lara. Calibree: Calibration-free localization using relative distance estimations. In *International Conference on Pervasive Computing*, páginas 146–161. Springer, 2008.
- Kamin Whitehouse. The design of calamari: an ad-hoc localization system for sensor networks. *University of California at Berkeley*, 2002.
- Kamin Whitehouse e David Culler. Calibration as parameter estimation in sensor networks. In *Proceedings of the 1st ACM international workshop on Wireless sensor networks and applications*, páginas 59–67. ACM, 2002.