



# Instituto Superior de Engenharia

Politécnico de Coimbra

DEPARTAMENTO DE INFORMÁTICA E SISTEMAS

## eHealth – Smart Data Analytics

Relatório de Estágio para a obtenção do grau de Mestre em  
Informática

Especialização em Intelligent Data Analysis

Autor

**João Pedro Costa Antas**

Orientador

**Simão Pedro Mendes Cruz Reis Paredes**

Supervisor na empresa Altice Labs

**Telma Susana Pinto Mota**



INSTITUTO POLITÉCNICO  
DE COIMBRA

INSTITUTO SUPERIOR  
DE ENGENHARIA  
DE COIMBRA

Coimbra, novembro de 2023



## RESUMO

Nos últimos anos, a convergência da tecnologia e da medicina tem desempenhado um papel vital na abordagem das doenças crónicas. A aplicação de técnicas de *eHealth* e *Machine Learning* tem revolucionado o diagnóstico, tratamento e gestão dessas condições de saúde críticas.

No âmbito do estudo piloto da Altice Labs com o Centro Universitário de Lisboa Central sobre telemonitorização de doentes com DPOC e com mazelas prolongadas provocadas pelo COVID-19, surgiram dois objetivos. O primeiro, essencialmente operacional, a implementação de um novo sistema de alertas e notificações para a Doença Pulmonar Obstrutiva Crónica (DPOC) na plataforma SmartAL da empresa e o segundo, de cariz mais exploratório, a classificação de doenças respiratórias através de sons empregando abordagens de *Deep Learning* (DL).

A primeira solução foi implementada e integrada na plataforma de telemonitorização SmartAL, em linguagem Java, e teve posterior validação por parte do profissional de saúde envolvido no piloto da DPOC. Esta solução permite aos cuidadores automatizar certos processos de alerta com base na correlação de informação proveniente de medidas de saúde (e.g. temperatura, frequência cardíaca, etc.) e de questionários preenchidos por utentes que sofrem da DPOC. Anteriormente, esta análise era realizada manualmente e apenas no momento da avaliação presencial de cada doente.

Na classificação dos sons respiratórios foram exploradas e avaliadas diversas técnicas de *Data Augmentation*, diferentes métodos de extração de *features* sonoras e distintas abordagens de DL. O modelo híbrido (ResNet50+LSTM) combinado com as *features Mel Spectrogram* foi o que obteve consistentemente as melhores pontuações, em todas as tarefas, com base na métrica de avaliação considerada (pontuação da *International Conference Biomedical and Health Informatics*). Para além disso, conseguiu desempenhar bem em comparação com os trabalhos relacionados. Contudo, ao considerar a escolha do modelo mais adequado para um ambiente empresarial, esta recaiu sobre a CNN simples agregada às *features MFCC* porque permite custos reduzidos, eficiência energética, escalabilidade, disponibilidade de recursos e simplicidade.

**Palavras-chave:** Doença pulmonar obstrutiva crónica, SmartAL, telemonitorização, *Deep Learning*, classificação

## **ABSTRACT**

In recent years, the convergence of technology and medicine has played a vital role in addressing chronic diseases. The application of eHealth and Machine Learning techniques has revolutionized the diagnosis, treatment, and management of these critical health conditions.

As part of Altice Labs' pilot study with the Central University of Lisbon on the telemonitoring of patients with COPD and lingering effects of COVID-19, two objectives emerged. The first, primarily operational, involved implementing a new alert and notification system for Chronic Obstructive Pulmonary Disease (COPD) on the company's SmartAL platform. The second, more exploratory in nature, focused on the classification of respiratory diseases using sound-based approaches employing Deep Learning (DL).

The first solution was implemented and integrated into the SmartAL telemonitoring platform using Java language and subsequently validated by the healthcare professional involved in the COPD pilot. This solution enables caregivers to automate certain alert processes based on the correlation of information from health measurements (e.g., temperature, heart rate, etc.) and questionnaires filled out by COPD patients. Previously, this analysis was done manually and only during each patient's in-person assessment.

In the classification of respiratory sounds, various techniques of Data Augmentation, different methods of sound feature extraction, and distinct DL approaches were explored and evaluated. The hybrid model (ResNet50+LSTM) combined with Mel Spectrogram features consistently achieved the highest scores in all tasks, based on the considered evaluation metric (International Conference Biomedical and Health Informatics score). Furthermore, it performed well compared to related work. However, when considering the choice of the most suitable model for a business environment, the preference was for the simple CNN combined with MFCC features due to its cost-effectiveness, energy efficiency, scalability, resource availability, and simplicity.

**Keywords:** Chronic Obstructive Pulmonary Disease, SmartAL, telemonitoring, Deep Learning, classification.

## **AGRADECIMENTOS**

A realização deste trabalho não teria sido possível sem a colaboração de várias pessoas. Manifesto aqui o meu sincero agradecimento a todos os envolvidos que contribuíram para a concretização desta dissertação de mestrado.

Da empresa Altice Labs, aos engenheiros Telma Mota, a minha orientadora, Jean Matias, Luís Cortesão e Rodrigo Ferreira e do Instituto Politécnico de Coimbra, ao Prof. Simão Paredes, o meu orientador. A todos, agradeço a orientação, empenho, paciência e sabedoria com que sempre me acompanharam desde o princípio até ao fim do trabalho. Tentaram sempre mostrar qual o melhor percurso a percorrer para alcançar os objetivos finais, tendo estado sempre disponíveis para ajudar e apoiar.

Da Universidade de Coimbra, ao Prof. Paulo Carvalho, que me facultou o conjunto de dados utilizado, e para além disso, acompanhou com interesse o desenvolvimento do trabalho, dando opiniões extremamente valiosas.

A todos os docentes e não docentes do Instituto Superior de Engenharia de Coimbra, que fizeram parte do meu percurso académico, tanto na licenciatura como no mestrado, agradeço por todos os ensinamentos e contributos para o meu crescimento pessoal.

A todos os meus familiares, amigos mais próximos e à Joana, agradeço o apoio e a força que me deram em momentos menos bons, sem eles tudo teria sido mais difícil.

A todos, o meu maior e sincero obrigado.



## ÍNDICE

Resumo .....	1
<i>Abstract</i> .....	ii
Agradecimentos .....	iii
Índice.....	v
Índice de tabelas .....	vii
Índice de figuras.....	ix
Lista de siglas e acrónimos .....	xi
1 Introdução .....	1
1.1 Contexto do Problema.....	2
1.2 Motivação .....	5
1.3 Objetivos .....	5
1.4 Tarefas Principais .....	6
1.5 Estrutura do Documento .....	7
2 Estado da arte.....	9
2.1 Doenças Crónicas.....	9
2.1.1 Doença Pulmonar Obstrutiva Crónica.....	10
2.2 eHealth.....	14
2.2.1 Aposta na eHealth.....	15
2.2.2 Soluções de telemonitorização no mercado nacional .....	17
2.3 Telemonitorização na DPOC .....	21
2.3.1 Estudos sobre a revisão da eficácia da telemonitorização na DPOC..	22
2.3.2 Características de Projetos-piloto de telemonitorização.....	24
2.3.3 Projetos-piloto de telemonitorização em Portugal.....	28
2.4 Machine Learning nas doenças respiratórias.....	30
2.4.1 Modelos de Deep Learning.....	33
2.4.2 Técnicas de <i>Data Augmentation</i> .....	38
2.4.3 Extração de Features.....	41
2.5 Considerações Finais.....	43
3 SmartAL.....	45
3.1 Introdução .....	45
3.2 Principais Funcionalidades .....	45

3.3	Arquitetura .....	46
3.4	Resumo .....	48
4	Módulo 1 – Serviço de Alertas DPOC .....	49
4.1	Tecnologias .....	49
4.1.1	Java versão 8+ e Apache Tomcat.....	49
4.1.2	Visual Studio Code.....	49
4.1.3	TortoiseSVN.....	50
4.2	Implementação .....	50
4.2.1	Metodologia .....	50
4.2.2	Casos de Uso.....	51
4.2.3	Desafio.....	58
4.2.4	Arquitetura do Fluxo .....	59
4.2.5	Fontes de Dados.....	60
4.2.6	Descrição da Implementação.....	63
5	Módulo 2 - Diagnóstico de doenças respiratórias .....	69
5.1	Tecnologias .....	69
5.1.1	Python versão 3.10.10.....	69
5.1.2	Projeto Jupyter e Jupyter Notebook.....	70
5.1.3	Kaggle .....	70
5.2	Implementação .....	70
5.2.1	Conjunto de dados <i>Respiratory Sound Database (RSD)</i> .....	70
5.2.2	Descrição da Implementação.....	71
5.2.3	Resultados .....	81
6	Conclusões e Trabalho Futuro.....	89
6.1	Considerações finais.....	90

## ÍNDICE DE TABELAS

Tabela 1 - Classificação da gravidade da limitação do fluxo aéreo na DPOC (baseado no FEV <sub>1</sub> pós-broncodilatador).....	12
Tabela 2 - Condições de saúde e aspetos positivos das plataformas .....	20
Tabela 3 - Estudos relacionados, incluindo objetivos, algoritmos, features, técnicas utilizadas e resultados obtidos.....	32
Tabela 4 - Caso de uso "Login" (já existente) .....	51
Tabela 5 - Caso de uso "Agenda Tarefa" (já existente).....	52
Tabela 6 - Caso de uso "Regista medida de saúde" (já existente).....	52
Tabela 7 - Caso de uso "Responde a um questionário" (já existente).....	53
Tabela 8 - Caso de uso "Recebe alerta" (já existente) .....	53
Tabela 9 - Caso de uso "Recebe notificação" (já existente) .....	54
Tabela 10 - Caso de uso "Notificação Medições vs. Questionário QCD" (novo)..	54
Tabela 11 - Caso de uso "Alerta 1 – Resultado QCD" (novo).....	55
Tabela 12 - Caso de uso "Vigilância 24 horas" (novo) .....	56
Tabela 13 - Caso de uso "Alerta 2 – Acompanhamento da DPOC" (novo).....	57
Tabela 14 - Caso de uso "Alerta 3 - Estratificação" (novo) .....	58
Tabela 15 - Tabela de condições da fase de estratificação .....	62
Tabela 16 - Distribuição dos conjuntos de treino e teste para o problema SN.....	75
Tabela 17 - Distribuição dos conjuntos de treino e teste para o problema SCN....	75
Tabela 18 - Distribuição dos conjuntos de treino e teste para o problema DR.....	75
Tabela 19 - CNN, todas as técnicas de DA e <i>features</i> MFCC .....	82
Tabela 20 - CNN, todas as técnicas de DA e <i>features</i> Mel Spectrogram .....	83
Tabela 21 - CNN, todas as técnicas de DA e <i>features</i> Spectral Contrast.....	83
Tabela 22 - VGG19 e ResNet50, DA Sound Augmentation e <i>features</i> MFCC .....	83
Tabela 23 - VGG19 e ResNet50, DA Sound Augmentation e <i>features</i> Mel Spectrogram .....	83
Tabela 24 - VGG19 e ResNet50, DA Sound Augmentation e <i>features</i> Spectral Contrast .....	84
Tabela 25 - Modelo híbrido (ResNet50+GRU e ResNet50+LSTM), Sound Augmentation e <i>features</i> Mel Spectrogram .....	84
Tabela 26 - Modelo híbrido (ResNet50+LSTM), Sound Augmentation e <i>features</i> musicais.....	85

Tabela 27 - Modelo híbrido (ResNet50+LSTM), Sound Augmentation e todas as <i>features</i> de timbre ou todas as <i>features</i> musicais e de timbre .....	85
Tabela 28 - Resultados finais comparados com o estado da arte .....	88

## ÍNDICE DE FIGURAS

Figura 1 - Esperança de vida no mundo desde 1950 até 2020 [1].....	2
Figura 2 - Cronograma com as tarefas elaboradas .....	6
Figura 3 - TOP 10 Causas de Morte no Mundo (em Milhões) [13].....	9
Figura 4 - Número de consultas em Telemedicina por ano desde 2013 [24].....	16
Figura 5 – Exemplo da plataforma SmartAL [28].....	17
Figura 6 - Exemplo da aplicação móvel do HC Alert.....	18
Figura 7 - Exemplo da plataforma Plano A [30] .....	18
Figura 8 - Exemplo da aplicação móvel do Telemnit SNS 24 [33].....	19
Figura 9 - Plano de implementação e operacionalização do Programa de Telemonitorização da DPOC na ULSAM [34].....	28
Figura 10 - Arquitetura de uma CNN base e as suas camadas principais .....	34
Figura 11 - Arquitetura de uma VGG19 .....	35
Figura 12 - Arquitetura de uma ResNet50 .....	36
Figura 13 - Arquitetura da LSTM e da GRU [62] .....	38
Figura 14 - Exemplo do funcionamento da técnica SMOTE [63].....	39
Figura 15 - Exemplo do funcionamento da técnica SpecAugment num espectrograma [66] .....	40
Figura 16 - Features MFCC, Mel Spectrogram e Spectral Contrast.....	42
Figura 17 - Features Chroma STFT, Tempogram, Tonnetz.....	42
Figura 18 - Arquitetura SmartAL B2B de Alto Nível.....	46
Figura 19 - Primeiro conjunto de blocos da arquitetura.....	46
Figura 20 - Segundo conjunto de blocos da arquitetura.....	47
Figura 21 - Terceiro conjunto de blocos da arquitetura .....	47
Figura 22 - Quarto conjunto de blocos da arquitetura .....	47
Figura 23 - Metodologia de implementação do Serviço de Alertas DPOC .....	50
Figura 24 - Fluxograma da solução implementada.....	59
Figura 25 - Questionário de Confirmação de Agudização (QCD).....	60
Figura 26 - <i>COPD Assessment Test</i> (CAT).....	61
Figura 27 - Teste de Adesão Terapêutica (TAT).....	61
Figura 28 - Questão sobre a Dispneia (mMRC) e expetoração.....	61

Figura 29 - Declaração das funções do fluxo de medidas e dos questionários.....	63
Figura 30 - Função <i>calculateDataTypeGroupState</i> .....	65
Figura 31 - Função <i>AssociateQCDQuiz</i> .....	66
Figura 32 - Função <i>sendDPOCNotifications</i> .....	66
Figura 33 - Função <i>getLastValue</i> .....	68
Figura 34 - Função <i>getThresholdsValues</i> .....	68
Figura 35 - Balanceamento do conjunto de dados original.....	72
Figura 36 - Balanceamento do problema SN.....	73
Figura 37 - Balanceamento do problema SCN.....	73
Figura 38 - Balanceamento do problema DR.....	73
Figura 39 - Fases de testes implementadas e as suas principais características.....	77
Figura 40 - Arquitetura da CNN implementada.....	78
Figura 41 - Arquitetura das redes neurais convolucionais profundas implementadas .....	79
Figura 42 - Arquitetura do modelo híbrido implementado (ResNet50+LSTM ou GRU).....	80
Figura 43 - Exemplos da concatenação de <i>features</i> para sons respiratórios de uma pessoa saudável.....	81
Figura 44 - Matrizes de confusão do problema SN e SCN.....	86
Figura 45 - Matriz de confusão do problema DR .....	86

## **LISTA DE SIGLAS E ACRÓNIMOS**

<b>API</b>	<i>Application Programming Interface</i>
<b>AUC</b>	<i>Area Under Curve</i>
<b>CAT</b>	<i>COPD Assessment Test</i>
<b>CNN</b>	<i>Convolutional Neuronal Network</i>
<b>COPD</b>	<i>Chronic Obstructive Pulmonary Disease</i>
<b>DA</b>	<i>Data Augmentation</i>
<b>DL</b>	<i>Deep Learning</i>
<b>DPOC</b>	Doença Pulmonar Obstrutiva Crónica
<b>ECG</b>	Eletrocardiograma
<b>FEV<sub>1</sub></b>	<i>Forced Expiratory Volume in one second</i>
<b>FVC</b>	<i>Forced Vital Capacity</i>
<b>GOLD</b>	<i>Global initiative for obstructive lung disease</i>
<b>ICBHI</b>	<i>International Conference on Biomedical and Health Informatics</i>
<b>ICC</b>	Insuficiência cardíaca congestiva
<b>LTOT</b>	<i>Long-term supplemental oxygen therapy</i>
<b>MHR</b>	<i>Medical Health Record</i>
<b>ML</b>	<i>Machine Learning</i>
<b>mMRC</b>	<i>modified Medical Research Council</i>
<b>OMS</b>	Organização Mundial de Saúde
<b>PaO<sub>2</sub></b>	Pressão parcial de oxigénio no sangue arterial
<b>PaCO<sub>2</sub></b>	Pressão parcial de dióxido de carbono no sangue arterial
<b>QCD</b>	Questionário de Confirmação de Agudização
<b>SaO<sub>2</sub></b>	Nível de saturação do oxigénio no sangue arterial
<b>SFRQ</b>	<i>St. George Respiratory Questionary</i>
<b>SNS</b>	Serviço Nacional de Saúde
<b>STFT</b>	<i>Short-Time Fourier Transform</i>
<b>TAT</b>	Teste de Adesão Terapêutica



## **1 INTRODUÇÃO**

As pessoas em todo o mundo estão a viver mais tempo. Para além disso, a população mundial continua a crescer e a maior parte dos países apresenta um maior número de pessoas idosas [1]. O crescente envelhecimento da população levanta novos e mais exigentes desafios económicos, sociais e clínicos, e as tendências demográficas recentes indicam que o número de pessoas idosas continuará a subir [2].

Atualmente, todos os países enfrentam e continuarão a enfrentar grandes desafios para garantir que os seus sistemas sociais e de saúde estão preparados para lidar com as transições demográficas. Estas transições exigem essencialmente mudança de foco para atender às necessidades médicas da população idosa, e passar a apostar mais na saúde preventiva. É expectável que a necessidade de acompanhamento também continue a aumentar, representando assim uma maior exigência na prestação de cuidados de saúde, principalmente nos cuidados a longo prazo.

Em termos clínicos, o envelhecimento é um fator de risco no desenvolvimento de múltiplas condições incapacitantes e doenças crónicas. Deste modo, o estado de saúde destas pessoas precisa de ser seguido e controlado durante mais tempo, o que gera necessariamente sobrecarga nos sistemas de saúde.

Para aliviar essa carga, e ajudar os idosos e os cidadãos em geral, assim como os profissionais de saúde e as respetivas instituições, é necessário acelerar a transição digital. A evolução científica e tecnológica tem sido expressiva em múltiplas áreas nas últimas décadas, com destaque para a área da saúde, cuja prática médica incorpora já tecnologias que proporcionam aos doentes melhores diagnósticos e tratamentos em boas condições de segurança. Acresce ainda a possibilidade de usar algoritmos inteligentes no processamento dos dados para conferir ainda maior precisão na análise do estado de saúde do doente.

*eHealth* é o termo usado para a prática de cuidados de saúde suportados por Tecnologias da Informação e Comunicação. É muitas vezes sinónimo de telessaúde e telemedicina, termos que representam a prestação de cuidados de saúde de forma remota. Conceptualmente, *eHealth* abrange o conjunto de aplicações que utilizam a Internet (em conjunto com outras tecnologias de informação) para, por um lado, melhorar processos clínicos, tratamentos e fluxo de dados, e por outro, otimizar recursos e reduzir custos. Como tal, utiliza recursos digitais na prestação e coordenação de serviços nos sistemas de saúde [3].

## 1.1 Contexto do Problema

Em muitos países industrializados, a esperança de vida já ultrapassa os 80 anos [4]. Por exemplo na União Europeia, a esperança média de vida foi estimada em 81,3 anos em 2019 (aumento de 0,3 anos em relação a 2018) atingindo os 84 anos para as mulheres e os 78,5 anos para os homens [5].

Segundo dados da *United Nations Population Division*, nos últimos 70 anos, a expectativa de vida no mundo teve um aumento exponencial que passou de aproximadamente 47 anos em 1950 para cerca de 73 anos em 2020, como demonstra a Figura 1. Analisando estes dados, conseguimos perceber que a esperança de vida aumentou aproximadamente 3.74 anos a cada 10 anos, muito por causa dos avanços na medicina e da maior capacidade de acesso a cuidados de saúde, sobretudo nos países “em desenvolvimento”.




Figura 1 - Esperança de vida no mundo desde 1950 até 2020 [1]

Até 2030, uma em cada seis pessoas no mundo terá idade igual ou superior a 60. Nessa altura, o número da população com essa idade aumentará de 1.0 mil milhão em 2020 para 1.4 mil milhões. Até 2050, a população mundial de pessoas com 60 ou mais anos irá duplicar (2.1 mil milhões). Relativamente ao número de pessoas com 80 anos ou mais, deverá triplicar entre 2020 e 2050, atingindo 426 milhões [1]. Embora esta mudança na distribuição da população de um país para as idades mais altas tenha começado em países de elevado rendimento, como por exemplo o Japão onde 30% da população já tem 60 anos ou mais, são agora os países de baixo e médio rendimento que estão a experienciar as maiores mudanças. Por exemplo, em Portugal o índice de envelhecimento atingiu os 182,7 em 2021, tendo aumentado de forma consistente todos os anos desde 1961, em que era de apenas 27,5 [6].

O envelhecimento é também um fator de risco reconhecido no aparecimento de múltiplas doenças, especificamente crónicas. As doenças crónicas são

doenças não contagiosas que progridem lentamente. São, normalmente, de longa duração e resultam da combinação de vários fatores, entre eles características genéticas, envolvência ambiental e estilos de vida. As principais doenças crónicas são do tipo cardiovascular, respiratório, degenerativo (e.g. cancro) e metabólico (e.g. diabetes). Estas doenças são as principais causas de morte no mundo, impactando fortemente populações mais vulneráveis, chegando a matar 41 milhões de pessoas por ano, o que equivale a 74% das mortes globais, sendo que 17 milhões dessas pessoas têm idade inferior a 70 anos [7].

Um relatório recente da Organização Mundial da Saúde (OMS), sublinha os efeitos das doenças crónicas, realçando o facto de a cada dois segundos no mundo, morrer uma pessoa com menos de 70 anos vítima destas doenças. A maioria dos óbitos (86%) ocorre em países com rendas baixas ou médias, e acredita-se que muitas dessas mortes poderiam ser evitadas. O combate aos principais fatores de risco (e.g. consumo de tabaco, consumo de álcool, dietas pouco saudáveis, inatividade física, poluição) pode prevenir ou retardar significativamente o grande número de mortes provocado por estas doenças [8], mas não representa tudo o que se pode fazer neste domínio. Como parte da estratégia global, deve-se também fazer acompanhamento de forma mais continuada e próxima, incentivando o envolvimento dos próprios doentes no tratamento e na mitigação de alguns dos fatores negativos, capacitando-os para melhorarem a sua qualidade de vida.

Contudo, prevenir as consequências das doenças crónicas e de outras limitações exige intervenções atempadas. O reconhecimento precoce de problemas que podem conduzir à incapacitação na execução das atividades da vida diária, deve ser um dos pontos principais de atenção. Em suma, é necessário conjugar esforços e preparar os sistemas de saúde, para serem capazes de fornecer cuidados médicos de alta qualidade a pacientes com doenças crónicas, e em particular atender de forma diligente às necessidades das populações mais envelhecidas.

Atualmente, já não é possível falar de saúde sem considerar o papel da tecnologia. A transformação digital está a ter impacto em todas as áreas relacionadas com a saúde que envolvem, desde unidades hospitalares a farmácias. Todas as instituições já usam plataformas informáticas de apoio no seu dia-a-dia. Para além disso, existem diversas aplicações que permitem personalizar e acompanhar cada doente, desde a fase de prevenção ao tratamento, possibilitando assim melhores cuidados de saúde a custos controlados. A tecnologia assegura, cada vez mais, a sustentabilidade dos sistemas de saúde. Com o apoio da tecnologia, é possível aliviar o sistema e melhorar a perceção do utente sobre os serviços. De forma complementar, permite-se também que médicos, enfermeiros e terapeutas possam dedicar-se aos casos mais urgentes e que necessitam de mais atenção. A tecnologia tem de servir como um apoio, tanto do ponto de vista administrativo como clínico [9].

As novas tecnologias na área da saúde trouxeram inovação na sua prática, até ao ponto de revolucionar as relações entre os doentes e os técnicos da área. Não se trata, hoje, de reinventar a medicina, mas sim de a exercer de uma forma diferente e mais eficaz, de modo a apoiarmo-nos cada vez mais na evolução científica e tecnológica. As novas tecnologias na área da saúde permitem aos utilizadores monitorizar as suas doenças, tomar medidas preventivas e controlar melhor o seu estado de saúde. A utilização da Internet para suportar redes de assistência médica, os dispositivos com sensores incorporados, as aplicações e sistemas de computação em *cloud* que fornecem recursos quase ilimitados para guardar dados e registos digitais de saúde, as plataformas de monitorização remota e saúde móvel, são alguns exemplos práticos de digitalização na área da saúde [10].

A inovação e as tecnologias da informação e comunicação estão já presentes em praticamente todos os aspetos da saúde, tais como exames, interpretação de dados, diagnóstico, tratamento, gestão hospitalar e, até na própria relação entre médicos e doentes com as teleconsultas. As tecnologias têm desempenhado um papel cada vez mais importante no combate à doença, com o objetivo de melhorar os resultados clínicos, reduzindo simultaneamente custos [11].

Neste sentido, uma das inovações tecnológicas mais populares e em forte crescimento é a telemonitorização clínica. A Telemonitorização surgiu da necessidade de proporcionar aos pacientes maior comodidade e autonomia na gestão da sua doença, bem como, aliviar a pressão sobre as unidades hospitalares [12].

Atualmente, os doentes que estão inseridos em programas de telemonitorização fazem medições de sinais biométricos e registam informação sobre o seu estado de saúde diariamente, recebendo depois alertas e recomendações das plataformas e dos profissionais de saúde que os acompanham. Este tipo de serviço permite assim, por um lado, melhorar o nível de atendimento e qualidade de vida do paciente, e por outro, aperfeiçoar o trabalho do profissional de saúde no acompanhamento dos seus doentes, que passa a poder fazê-lo também à distância, facilitando o dia-a-dia de ambos.

Nos últimos anos, o desenvolvimento de soluções de telemonitorização tem sido intenso. Consequentemente, existem vários tipos de dispositivos que podem ser usados para monitorizar parâmetros fisiológicos, comportamentais e ambientais de pacientes com doenças crónicas [10]. No entanto, ainda existem vários desafios na obtenção de sensorização relevante, e na combinação e processamento de dados provenientes de diferentes fontes, tendo como objetivo, fornecer entrada para um sistema de apoio à decisão que forneça informação de forma eficiente para a deteção precoce, previsão e envio de alarmística para médicos e outros profissionais de saúde.

## **1.2 Motivação**

No contexto anteriormente descrito, surge o trabalho proposto pela Altice Labs. Pretende explorar a identificação e resolução de problemas relacionados com a telemonitorização e avaliação clínica de pacientes com doenças crónicas e, dentro deste espectro, especificamente com o tratamento de dados resultantes da recolha de informação de pessoas com problemas respiratórios e que sofrem de doença pulmonar obstrutiva crónica (DPOC).

O trabalho proposto está dividido em dois módulos distintos. Inicialmente, pretende-se analisar e tomar decisões com base em dados provenientes da solução de telemonitorização da Altice Labs. Posteriormente, pretende-se utilizar dados de sons respiratórios para diagnosticar pacientes com DPOC e outras doenças respiratórias.

A área de *eHealth/Assisted Living* tem vindo a crescer com a necessidade de melhorar a qualidade de vida de pessoas que precisam de acompanhamento médico permanente (e.g. doenças crónicas) ou ocasional (e.g. pós-operatório, pandemia). Pretende-se, cada vez mais, acompanhar as pessoas de alguma forma em risco e recolher a informação necessária para poder traçar o seu perfil e atuar atempadamente.

Assim, é necessário recolher o máximo de dados para ter uma visão holística dos doentes monitorizados. Contudo, a informação deve ser correta e de qualidade para dar apoio na tomada de decisão, e deve posteriormente gerar conhecimento e indicadores que possam ajudar os profissionais a servir melhor os seus doentes.

## **1.3 Objetivos**

Numa primeira fase, este projeto pretende analisar informação proveniente de um conjunto de dispositivos pré-selecionados (equipamentos clínicos, *wearables*, APIs) e questionários com a finalidade de criar notificações e alertas relevantes quer para os doentes quer para os cuidadores/médicos.

O primeiro objetivo é assim, essencialmente operacional, e consiste em desenvolver uma nova solução de sistema de alertas e notificações que permita automatizar processos e criar conhecimento em função dos dados recolhidos.

Numa segunda fase, este projeto pretende analisar informação proveniente de um conjunto de amostras de áudio recolhidas independentemente por duas equipas de pesquisa em países distintos, Portugal e Grécia. Estas equipas recolheram dados ao longo de vários anos, com a finalidade de diagnosticar DPOC e outras doenças em pacientes com problemas respiratórios.

O segundo objetivo é assim, de cariz mais exploratório, e consiste em desenvolver um modelo de classificação capaz de diagnosticar doenças respiratórias a partir de sons.

## 1.4 Tarefas Principais

Este trabalho foi desenvolvido ao longo de aproximadamente 10 meses, podendo ser identificadas as tarefas principais:

- Tarefa 1 (T1) – Estudo do domínio de desenvolvimento (e.g. saúde, telemonitorização, DPOC, indicadores);
- Tarefa 2 (T2) – Estado da Arte;
- Tarefa 3 (T3) – Estudo da solução de telemonitorização da Altice Labs (i.e. SmartAL);
- Tarefa 4 (T4) – Desenvolvimento de um novo sistema de alertas e notificações baseado em informação proveniente de medições de sinais vitais e respostas a questionários relacionados com a DPOC;
- Tarefa 5 (T5) – Aplicação de algoritmos de *Machine Learning* em dados de sons respiratórios para diagnóstico de pacientes com doenças respiratórias;
- Tarefa 6 (T6) – Escrita do Relatório Final / Dissertação.

A Figura 2 apresenta um cronograma com a organização das tarefas ao longo do período de desenvolvimento deste trabalho.

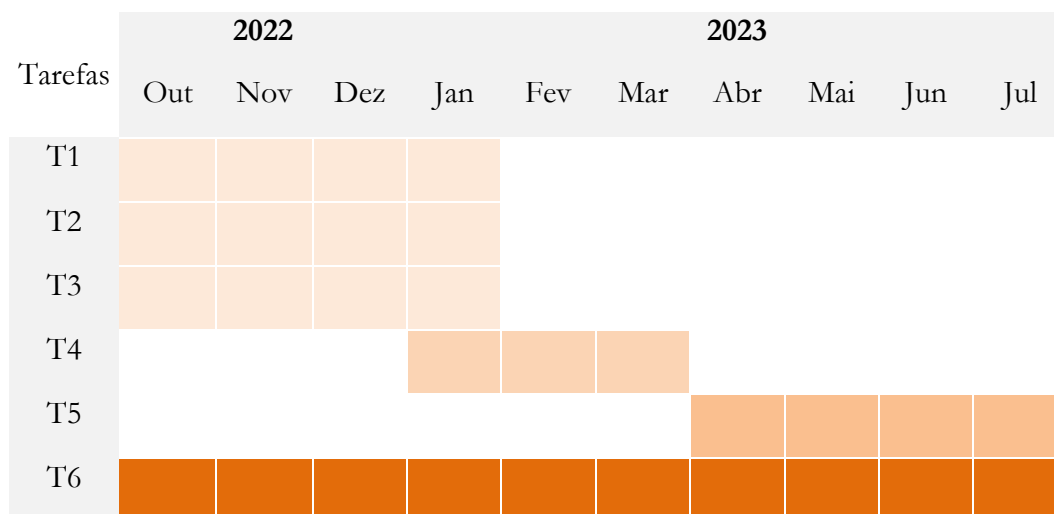


Figura 2 - Cronograma com as tarefas elaboradas

## 1.5 Estrutura do Documento

O documento é constituído por 6 capítulos, sendo os mesmos descritos da seguinte forma:

- Capítulo 2 analisa o estado da arte do trabalho, concentrando-se no tema das doenças crónicas, com especial foco na DPOC. Explora também a aplicação da *eHealth*, que engloba a telemonitorização e o *Machine Learning*, na análise de dados de pacientes com problemas respiratórios.
- Capítulo 3 aborda a plataforma de telemonitorização SmartAL da Altice Labs. Inclui uma pequena introdução à plataforma, as suas principais funcionalidades e a arquitetura de alto nível;
- Capítulo 4 apresenta o desenvolvimento do primeiro módulo do trabalho (fluxo da DPOC), incluindo as tecnologias utilizadas e o processo de implementação da solução. Este capítulo descreve os casos de uso, o desafio associado, a arquitetura da solução, as fontes de dados e, por fim, a implementação.
- Capítulo 5 apresenta o desenvolvimento do segundo módulo do trabalho (diagnóstico de doenças respiratórias), incluindo as tecnologias utilizadas e o processo de implementação dos diferentes modelos. Este capítulo descreve o conjunto de dados, técnicas de *data augmentation*, e métodos de extração de *features* utilizados, assim como a implementação dos modelos e os respetivos resultados.
- Capítulo 6 apresenta as conclusões, trabalho futuro e as lições aprendidas.



## 2 ESTADO DA ARTE

Este capítulo apresenta o estado de arte dos temas mais relevantes à execução deste trabalho, tais como a prevalência das doenças crónicas e o papel de tecnologias como a telemonitorização e *Machine Learning* no acompanhamento, diagnóstico, prevenção e tratamento das mesmas.

### 2.1 Doenças Crónicas

A maioria das doenças crónicas têm na sua origem comportamentos, tais como o tabagismo, a nutrição pobre (incluindo dietas pobres em frutas e vegetais e ricas em sódio e gorduras saturadas), a inatividade física e o consumo excessivo de álcool. Estes comportamentos representam riscos, na medida em que operam perigosas alterações metabólicas no corpo, a saber: pressão arterial alta, excesso de peso/obesidade e níveis elevados de glicose e/ou gordura no sangue [7]. Globalmente, as doenças crónicas têm afetado a saúde e a qualidade de vida da maioria dos cidadãos. Para além disso, têm contribuído de forma decisiva para o aumento dos custos com a saúde.

Em 2019, sete das dez principais causas de morte tiveram como origem doenças crónicas. Estas sete causas representaram 44% do número total de mortes em dez, e o total de doenças crónicas representou 74% das mortes [13]. Na Figura 3, estão representadas as dez principais causas e o respetivo número de mortes para cada uma delas em 2019 (dados da OMS). Leem-se os números da doença isquémica do coração (8.9 milhões de mortes), dos acidentes cardiovasculares cerebrais (6.2 milhões de mortes), da DPOC (3.2 milhões de mortes), do cancro da traqueia, brônquios e pulmão (1.8 milhões de mortes), da alzheimer (1.6 milhões de mortes), da diabetes (1.5 milhões de mortes) e da doença renal (1.3 milhões de mortes). Todas estas doenças crónicas aumentaram em prevalência, incidência e número de mortes, em relação a anos anteriores.




Figura 3 - TOP 10 Causas de Morte no Mundo (em Milhões) [13]

### 2.1.1 Doença Pulmonar Obstrutiva Crónica

A Doença Pulmonar Obstrutiva Crónica foi a terceira principal causa de morte no mundo em 2019, responsável por aproximadamente 6% do total das mortes, ficando apenas atrás da doença isquémica do coração e do acidente vascular cerebral. Segundo a OMS, a DPOC é responsável por 1 em cada 13 mortes por ano no mundo (4.1 milhões de pessoas em média por ano). No entanto, acredita-se que 70% das mortes podiam ter sido evitadas ou retardadas, controlando ou mesmo eliminando alguns dos riscos associados [8].

É uma doença respiratória caracterizada, principalmente, pela limitação do fluxo aéreo, resultante da inflamação e remodelação das vias aéreas, frequentemente associada à destruição do parênquima e desenvolvimento de enfisema [14]. O enfisema, normalmente, refere-se à destruição dos minúsculos sacos de ar no final das vias aéreas nos pulmões. No entanto, em muitos doentes a doença está associada a diversas manifestações sistémicas que podem efetivamente resultar na diminuição da capacidade funcional, agravamento da dispneia, redução da qualidade de vida e aumento da mortalidade [14].

Normalmente, os pacientes com DPOC são ambulatorios, exceto em casos de exacerbação (agravamento súbito do estado de saúde, que ocorre em média de 1 a 4 vezes por ano) que resultam em internamentos [15]. Estes pacientes por norma sobrevivem a vários episódios de exacerbação, porém cada episódio causa declínio funcional acentuado e pode resultar em morte [16].

A presença de exacerbações e comorbidades contribuem fortemente para a gravidade geral da doença. A DPOC pode estar associada a cancro dos pulmões, asma, síndrome da apneia obstrutiva do sono, hipertensão, doença cardiovascular, diabetes, síndrome metabólica, miopatias esqueléticas disfuncionais, osteoporose e transtornos mentais [16].

Segundo a OMS, os sintomas mais comuns da doença desenvolvem-se a partir da meia-idade e manifestam-se sob a forma de falta de ar, dificuldade em respirar, tosse crónica, catarro e cansaço. À medida que a DPOC progride, as pessoas têm mais dificuldade em realizar as suas atividades diárias normais, muitas vezes devido à falta de ar. Durante os surtos, as crises graves podem ser fatais, levando a internamentos de emergência [17].

A DPOC desenvolve-se gradualmente ao longo do tempo, muitas vezes resultante da exposição a vários fatores de risco, tais como: tabaco (por fumo ativo ou passivo), poeiras, fumos, produtos químicos, poluição do ar, combustão de biomassa como a madeira, estrume animal, resíduos de colheitas ou carvão, eventos no início da vida (crescimento deficiente no útero, prematuridade), infeções respiratórias frequentes ou graves na infância que impedem o crescimento pulmonar máximo, asma e ainda condições genéticas raras (*alpha-1 antitrypsin deficiency*) [17].

Sendo crónica, não existe cura para a DPOC. No entanto, o diagnóstico e tratamento atempados são importantes para diminuir a progressão dos sintomas e reduzir os riscos de surtos. O diagnóstico realiza-se através de um exame clínico, a espirometria, que avalia a profundidade com que o paciente respira e a velocidade com que o ar entra e sai dos pulmões. A avaliação deve ser efetuada em qualquer paciente com dispneia, tosse crónica ou produção de escarro. A presença de  $FEV_1/FVC$  pós-broncodilatador  $< 0.70$  confirma a presença de limitação persistente do fluxo aéreo e, conseqüentemente, da DPOC no paciente. Algumas das ações “simples” que ajudam a melhorar a saúde e controlar a DPOC do paciente são: parar de fumar, fazer exercício físico regularmente e ser vacinado contra pneumonia, gripe e COVID-19 [17], [18].

Em pacientes que fumam, a cessação é mandatária. É a única intervenção que definitivamente vai retardar o desenvolvimento da DPOC. Como tratamento anti-inflamatório para pacientes com exacerbações frequentes, normalmente são prescritos corticosteroides inalatórios ou orais por curtos intervalos de tempo. Uma possível terapia adicional é a reabilitação pulmonar, programa que combina treino físico, cessação do tabagismo, aconselhamento nutricional e educação, seguido de exercícios domiciliares [15]. Outra intervenção terapêutica comum consiste na administração de oxigénio em casa, todos os dias pelo menos 15 horas (incluindo as horas de sono) para garantir o máximo benefício. Esta oxigenoterapia de longo prazo (LTOT) melhora as taxas de sobrevivência em pacientes com baixa pressão parcial de oxigénio arterial ( $PaO_2$ ). A LTOT pode melhorar vários aspetos, incluindo qualidade de vida, morbidade cardiovascular, depressão, função cognitiva, capacidade de exercício e frequência de hospitalização [15].

A prevalência da DPOC na população em geral aumenta substancialmente ano após ano, principalmente nos indivíduos com mais de 40 anos; atinge valores acima de 10% e, aumenta consideravelmente com a idade. A realização de estudos rigorosos sobre a prevalência da DPOC é de extrema importância, para se conseguir efetuar novas projeções do impacto desta patologia em cada país [19].

No panorama nacional, a DPOC continua a ter uma expressão relevante na morbidade e conseqüente mortalidade causada por doença respiratória, tendo representado 2,5% em 2018 (com um aumento de 7,9% face a 2017), o que corresponde a 2834 óbitos (8 óbitos diários) [20].

Nos cuidados de saúde primários, o número de utentes com problemas ativos de DPOC aumentou cerca de 152%, entre 2011 e 2019, sendo que em dezembro de 2019 existiam 137.774 utentes codificados com esta patologia, configurando uma prevalência de registo nos cuidados de saúde primários de 1,55% [20].

Num estudo realizado por C. Bárbara et al. sobre a prevalência da DPOC em Lisboa, foi possível constatar que está muito presente nesta região, com uma prevalência estimada de 14,2% em adultos com 40 ou mais anos, sendo assim considerada uma doença comum. Os elevados valores de prevalência da DPOC, associados a uma elevada subdiagnóstico da doença, salientam a importância de apostar na prevenção, lançando campanhas de sensibilização dirigidas não só ao público em geral, mas especialmente aos profissionais de saúde sobre a necessidade de aumentar a utilização de espirometria no âmbito dos cuidados de saúde primários [19].

Na avaliação da DPOC, os objetivos, traduzem-se em determinar o nível de limitação do fluxo aéreo e o seu impacto no estado de saúde do paciente, assim como o risco de futuros eventos (exacerbações, internamentos hospitalares ou morte). Para ser possível atingir estes objetivos, a avaliação deve considerar os seguintes aspetos: a presença e gravidade da anormalidade espirométrica, natureza atual e magnitude dos sintomas do paciente, histórico de exacerbações moderadas e graves, e presença de comorbidades [18].

A espirometria é considerada a forma mais objetiva de medir o nível de limitação do fluxo do ar, sendo que é um teste não invasivo. Este teste mede a força do volume de ar expirado partindo do ponto máximo de inspiração (*forced vital capacity*, FVC) e o volume de ar expirado durante o primeiro segundo (*forced expiratory volume in one second*, FEV<sub>1</sub>). A razão entre as duas medidas tem de ser calculada, sendo que se o resultado for menor que 0.70 (após broncodilatação) confirma-se a existência de uma limitação do fluxo aéreo de caráter persistente [18]. Assim, pode classificar-se a gravidade na limitação do fluxo aéreo em doentes com DPOC do seguinte modo na Tabela 1:

Tabela 1 - Classificação da gravidade da limitação do fluxo aéreo na DPOC (baseado no FEV<sub>1</sub> pós-broncodilatador)

Nível GOLD	Severidade	Percentagem FEV <sub>1</sub>
GOLD 1	Suave	FEV <sub>1</sub> ≥ 80%
GOLD 2	Moderado	50% ≤ FEV <sub>1</sub> < 80%
GOLD 3	Grave	30% ≤ FEV <sub>1</sub> < 50%
GOLD 4	Muito Grave	FEV <sub>1</sub> < 30%

Relativamente à avaliação dos sintomas, devem ser considerados os seguintes questionários: o mMRC (*modified Medical Research Council*) que avalia a intensidade da dispneia numa escala de 0 a 4, o CAT (*COPD Assessment Test*), que mede o impacto da doença na qualidade de vida do indivíduo, e o SFRQ (*St. George Respiratory Questionary*) que embora meça o mesmo que o CAT, é mais complexo na sua utilização para a prática diária [18].

Anteriormente, como a DPOC era caracterizada em grande parte, apenas como uma doença que provoca a falta de ar, uma simples medida para avaliar era suficiente - a de dispneia dada pelo mMRC; apesar de única, relaciona-se bem com outras medidas do estado de saúde e prevê o risco de mortalidade futura.

No entanto, agora é reconhecido que a DPOC afeta os pacientes para além da dispneia. Por esse motivo, recomenda-se uma avaliação mais abrangente dos sintomas, usando questionários como o CAT e o SFRQ [18].

Por fim, para alcançar a compreensão do impacto da DPOC num paciente, é necessário realizar a sua avaliação de forma combinada. Esta avaliação, cruza a classificação espirométrica do paciente, com a avaliação sintomática (mMRC ou CAT) e o historial de exacerbações moderadas e graves (incluindo hospitalizações anteriores). Assim, o grau resultante fornece informação sobre a gravidade da limitação do fluxo aéreo (espirométrico grau 1 a grau 4), enquanto a letra (grupo A a D) fornece informação sobre a carga de sintomas e risco de exacerbação. Ambos devem ser usados para orientar a terapia [18].

O FEV<sub>1</sub> é um parâmetro chave no cálculo da previsão clínica a nível populacional, tal como a mortalidade e as hospitalizações, ou levando em consideração terapias não farmacológicas, a redução de volume ou o transplante pulmonar. No entanto, é importante notar que a nível individual do paciente, o FEV<sub>1</sub> perde precisão e, por isso, não pode ser usado sozinho para determinar todas as opções terapêuticas [18].

Em algumas circunstâncias, como por exemplo durante a hospitalização ou numa urgência, a capacidade de avaliar os pacientes com base nos sintomas e no histórico de exacerbações independentemente do valor espirométrico, permite aos médicos iniciar um plano de tratamento baseado apenas no esquema ABCD. Esta abordagem de avaliação reconhece as limitações do FEV<sub>1</sub> no suporte à tomada de decisão relativa ao tratamento individualizado do paciente, e destaca a importância dos sintomas e dos riscos de exacerbação na orientação de terapias na DPOC. Por exemplo, considerando 2 pacientes, ambos com FEV<sub>1</sub> < 30% e score 18 no CAT, mas o paciente 1 teve 0 exacerbações no ano passado enquanto o paciente 2 teve 3. Ambos seriam classificados como GOLD grau 4, no esquema de classificação da gravidade da limitação do fluxo aéreo em DPOC. No entanto, na avaliação combinada, o segundo paciente seria classificado como GOLD grau 4, grupo D, por causa do número superior de exacerbações.

Dada a relevância da DPOC na sociedade e impacto que tem na vida das pessoas, as soluções a desenvolver neste trabalho pretendem analisar e ajudar a resolver alguns dos seus problemas. O primeiro módulo a desenvolver permitirá ao SmartAL (produto de telemonitorização da Altice Labs) ter um sistema de alertas exclusivo para pacientes com DPOC, facilitando a vida aos doentes e profissionais de saúde. Já o segundo módulo, pretende ajudar a diagnosticar a doença, entre outras, através de sons respiratórios, o que poderá ser uma mais-valia para o SmartAL no futuro.

## 2.2 eHealth

eHealth permite a gestão da saúde e bem-estar de doentes e pessoas em risco de forma digital. Fá-lo através de equipas de apoio que trabalham em ambientes de cuidados que se pretendem flexíveis, integrados, interoperáveis e digitalmente habilitados com ferramentas, tecnologias e serviços digitais que melhorem a prestação de cuidados [3].

O conceito de eHealth abrange toda a prática médica realizada à distância, independentemente da ferramenta utilizada para a concretizar. Envolve uma ampla gama de serviços, tecnologias e acessórios, tais como videoconferência, dispositivos clínicos (oxímetro), *wearables* (dispositivos tecnológicos que podem ser usados como acessórios ou vestidos), plataformas e aplicações, armazenamento e encaminhamento de dados, *streaming* de *media*, redes de comunicação terrestre e sem fios, etc. [21].

A *eHealth*<sup>1</sup> subdivide-se nos seguintes ramos [22]:

- **Telemonitorização:** acompanhamento remoto de pacientes recorrendo à utilização de equipamentos para registar dados vitais (e outros) e enviá-los continuamente para centros de análise, interpretação e alerta. Serve para acompanhar e controlar o estado de saúde de pacientes com doenças crónicas, idosos, de risco ou grávidas. (e.g., o SmartAL<sup>2</sup> - solução de telemonitorização da Altice Labs).
- **Teleconsulta:** consulta realizada à distância através de videoconferência, que permite a interação e partilha de informação entre o profissional de saúde e o paciente (ou entre vários profissionais de saúde), com registo obrigatório no processo clínico do paciente. As características técnicas dos sistemas de teleconsulta disponíveis atualmente no mercado permitem a transmissão rápida de imagens de alta qualidade, com pouca ou nenhuma perda de definição. (e.g., Medigraf<sup>3</sup> - solução de teleconsulta hospitalar da Altice Labs).
- **Teleducação:** fornecimento de fontes de informação online sob a forma de material educacional de fácil acesso no computador. (e.g., Formare<sup>4</sup>).
- **Telediagnóstico:** uso de tecnologias da informação e comunicação que permitam a avaliação de exames médicos à distância e garantam maior acesso da população a diferentes exames de saúde. Por exemplo, imagens estáticas de raio X, eletrocardiogramas (e.g., Medigraf).

---

<sup>1</sup> , “Saúde Digital”, ou telemedicina

<sup>2</sup> <https://www.alticelabs.com/products/ehealth-smart-assisted-living/>

<sup>3</sup> <https://www.alticelabs.com/products/ehealth-telemedicine/>

<sup>4</sup> <https://www.alticelabs.com/site/formare/>

- **Telecirurgia:** utilização de robôs e técnicas computacionais avançadas para realizar vários tipos de operações cirúrgicas à distância. Neste contexto, o cirurgião tem a possibilidade de controlar o robô remotamente com uma percepção completa da operação que está a realizar.

A telemedicina pode ser utilizada com múltiplos propósitos, entre os quais, diminuir a procura existente nos hospitais e serviços de saúde, promover a educação para a saúde, reduzir os custos dos cuidados, medir e avaliar a adesão aos tratamentos, identificar rapidamente o agravamento da doença, expandir a acessibilidade dos serviços de saúde aos pacientes, oferecer a consulta e troca de informação entre diferentes estabelecimentos de saúde. Em suma, é um conceito amplo que envolve diagnóstico, tratamento, monitorização, educação e prevenção [21].

### **2.2.1 Aposta na eHealth**

Nos últimos anos, os sistemas de saúde de muitos países foram o centro das atenções pelas suas fragilidades, falta de investimento, e principalmente, pela necessidade de transformação para agilizar processos e gerar dados para tomar decisões eficazes frente a ameaças de saúde, tais como as que surgiram como a pandemia da COVID-19. Estes problemas afetaram todo o mundo e nunca o tema da saúde tinha estado sob tanta reflexão, discussão, e atenção por parte de tantas pessoas e entidades. Por causa disso, grandes centros de pesquisa, governos, organizações multilaterais, a comunidade médica, empresas farmacêuticas e a sociedade em geral sentiram que havia muito a melhorar [23].

A pandemia expôs problemas, mas também impulsionou a transformação digital, a pesquisa e o desenvolvimento de novos mecanismos para o bom funcionamento das unidades de saúde. Contribuiu para o uso alargado da telemedicina, com especial foco na teleconsulta e na telemonitorização, aumentando assim a utilização de soluções digitais de operação remota. Como prova disso, a Figura 4, mostra o número de consultas realizadas em telemedicina em Portugal [24]. Analisando esta figura, é possível observar o impacto da pandemia no ano de 2021, onde o número de teleconsultas teve um aumento de quase 2 milhões em relação ao ano anterior (2020), sendo as principais justificações, a sobrecarga das unidades hospitalares e o medo de contágio. É importante realçar também o facto que em 2022 o número de teleconsultas, apesar de menor do que em 2021, continuou consideravelmente alto em relação a anos anteriores, demonstrando assim que a telemedicina veio para ficar.

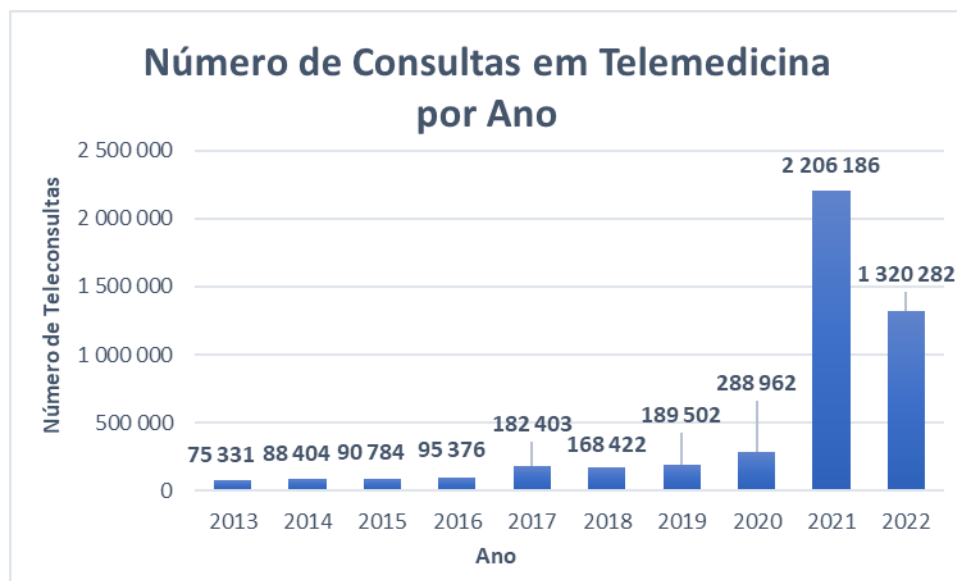


Figura 4 - Número de consultas em Telemedicina por ano desde 2013 [24]

Nos Estados Unidos da América estima-se que mais de 60% de todas as instituições de saúde e 40 a 50% de todos os hospitais usam atualmente alguma forma de telessaúde [11]. Num estudo local sobre pacientes com ICC (Insuficiência Cardíaca Congestiva) de alto risco, a telessaúde permitiu poupar entre 2,832 e 5,499 dólares por paciente por ano, em comparação com os cuidados habituais/tradicionais [25]. Relativamente a pacientes com DPOC, um estudo sobre este tipo de doentes na Alemanha demonstrou que a telessaúde permitiu poupar 895€ por paciente por ano [26]. Estes resultados vão de encontro a um dos principais objetivos da telessaúde, a redução de custos.

Como já referido, a telessaúde consiste essencialmente na utilização de tecnologias de informação e comunicação para apoiar cuidados de saúde clínicos à distância. No entanto, pode também ser usada como meio remoto de prestação de serviços de formação e capacitação de pacientes e profissionais, sobre temas relacionados com a doença, a saúde pública ou a administração na área da saúde. Frequentemente, o termo é utilizado como um sinónimo da telemedicina, mas na realidade não o é, uma vez que a telessaúde inclui serviços médicos não clínicos e a telemedicina fornece apenas serviços clínicos. A telemedicina é, portanto, um braço da telessaúde. A telessaúde é mais abrangente, e é composta por subáreas que integram a promoção da saúde como um todo, tais como a teleeducação, as redes de administração e gestão em saúde, a telemedicina e a interação entre profissionais de diferentes setores da saúde [27].

## 2.2.2 Soluções de telemonitorização no mercado nacional

A telessaúde tem vindo a ser reconhecida internacionalmente como uma das práticas tecnológicas mais relevantes para fazer face a grandes desafios na área da saúde e prestação de cuidados. Assim, surgem em Portugal, tal como noutros países, múltiplas iniciativas de novos modelos e soluções assentes no conceito da telessaúde, como é o caso da telemonitorização.

Atualmente, já existem algumas soluções de telemonitorização no mercado nacional que procuram contribuir para uma melhor gestão das doenças crónicas, promovendo a autonomia e participação dos doentes, a prevenção e a promoção de estilos de vida mais saudáveis, das quais são exemplo:

- SmartAL [28]: solução de monitorização da saúde à distância da Altice Labs. Permite acompanhar, em tempo real, doentes crónicos, seniores e pessoas em convalescença, pós-operatório ou em qualquer outro estado de fragilidade clínica. Possibilita a telemonitorização de sinais vitais, videoconsulta e o suporte de outras atividades relacionadas com a saúde e o bem-estar. No próximo capítulo, esta solução será analisada com mais detalhe, uma vez que é sobre ela que este trabalho incide.

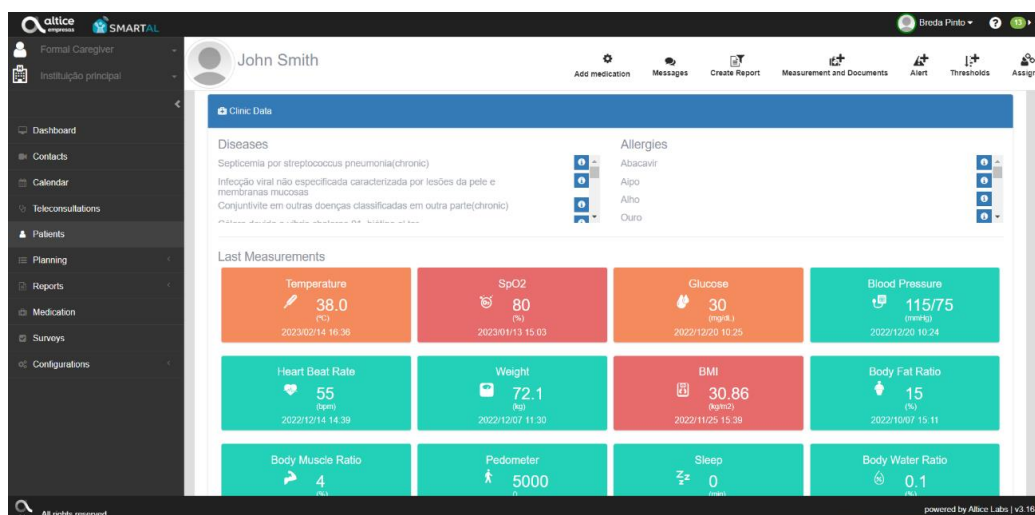


Figura 5 – Exemplo da plataforma SmartAL [28]

- HCAAlert [29]: solução de saúde digital da Hope Care desenvolvida em parceria com prestadores de serviços de saúde que permite acompanhar doentes crónicos em casa. À semelhança do SmartAL, é um sistema de telemonitorização em *cloud* que recebe dados de saúde de diferentes fornecedores e gera alarmes sempre que necessário. O HCAAlert cria alertas para o utilizador, chamando a atenção para as situações críticas, de acordo com o programa de saúde e/ou regras previamente definidas. Este sistema também oferece o serviço de videoconsulta que permite aos profissionais de saúde acompanhar remotamente os seus clientes.

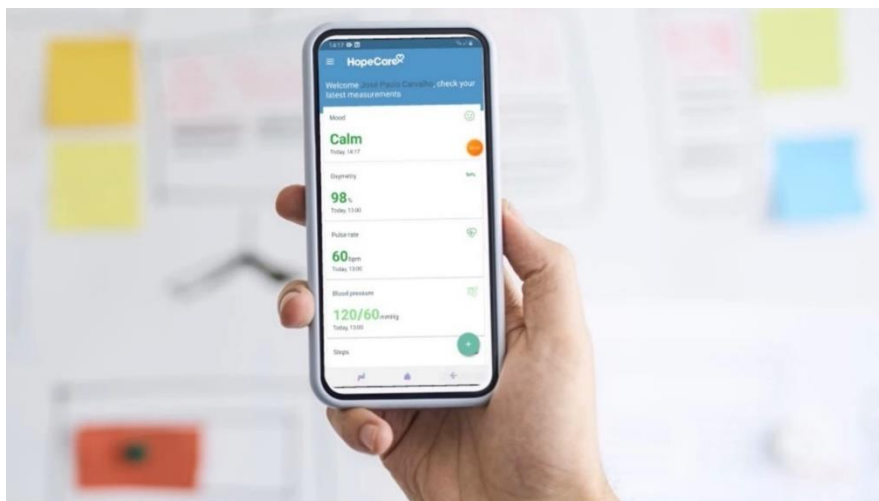


Figura 6 - Exemplo da aplicação móvel do HC Alert

- Plano-A [30]: solução de telemonitorização que, tal como as anteriores, ajuda médicos a acompanhar remotamente doentes crónicos (da Genesis Studio). Permite que os próprios utentes façam medições dos sinais biométricos e o registo de informação sobre o seu estado de saúde, recebendo depois os alertas e recomendações dos profissionais de saúde que os acompanham. Facilita a gestão e acompanhamento de cada utente, apresentando os dados de saúde relevantes, incluindo informação preditiva gerada por Inteligência Artificial.

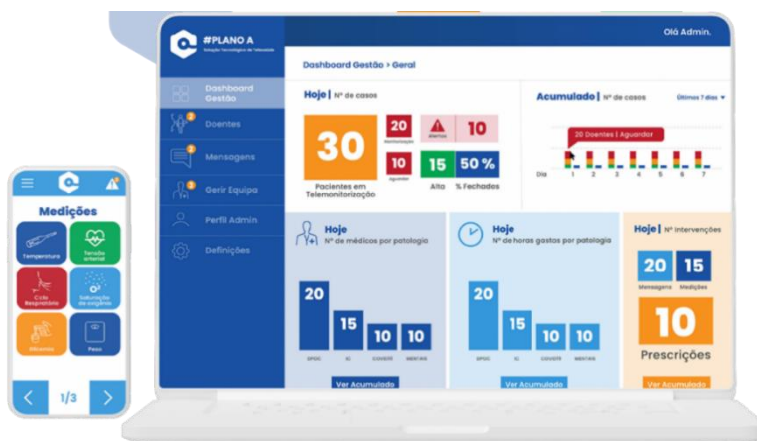


Figura 7 - Exemplo da plataforma Plano A [30]

- VitalMobile Health [31]: solução de telessaúde da VitalMobile. Disponibiliza comunicação direta e remota entre o doente e a equipa de profissionais de saúde, garantindo a sua vigilância clínica em tempo real, bem como a monitorização de parâmetros biológicos. Permite o acesso a alarmes, respostas do doente, histórico de leituras, gestão de dados do domicílio, informação do doente, relatórios, estatísticas e ao registo atual dos biodados relevantes para a estabilidade do doente. Utilizado com sucesso no Projeto-piloto de telemonitorização de doentes com DPOC na Unidade Local de Saúde do Alto Minho (ULSAM).
- Linde Saúde [32]: solução de telessaúde da Linde. Permite a recolha de dados e sinais vitais dos doentes através de um telemóvel. Os dados são posteriormente analisados pela equipa do Centro de Gestão Clínica em articulação com o médico assistente e encaminhados para o hospital de referência, o que permite fazer o acompanhamento individual adequado de cada doente e identificar precocemente as exacerbações das respetivas patologias. Trabalham em parceria com a Hope Care<sup>5</sup>.
- Telemonit SNS 24 [33]: Plataforma de telemonitorização SNS, que permite aos profissionais de saúde realizarem intervenções à distância, de forma proativa e personalizada, com base na informação recebida. Nesta aplicação, os utentes podem aceder ao seu plano pessoal de monitorização clínica, registar sinais vitais ou outras medições biométricas e responder a questionários de autoavaliação.

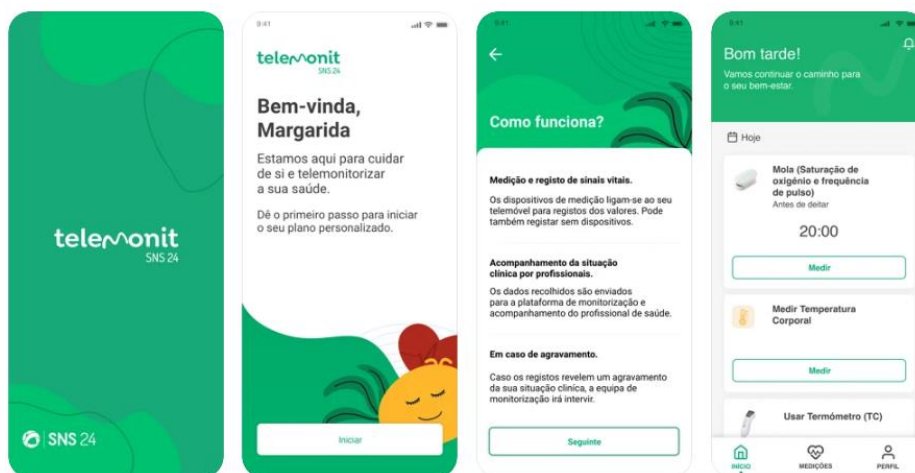


Figura 8 - Exemplo da aplicação móvel do Telemonit SNS 24 [33]

<sup>5</sup> <https://hope-care.pt/>

Tabela 2 - Condições de saúde e aspetos positivos das plataformas

Plataforma	Condições de Saúde	Aspetos positivos
SmartAL [28]	ICC	Aplicações mobile e web; Agenda de tarefas e sistema de alertas; Contacto utente-médico (videoconsulta ou chat).
HC Alert [29]	Obesidade, Hipertensão, Atividade, ICC, Diabetes, Sono, DPOC, Pré-eclampsia	Aplicações móvel e web; Sistema de alertas; Serviços de assistência de emergência; <i>Business Intelligence Dashboards</i> .
Plano A [30]	ICC, DPOC, Depressão e Sono, Covid-19	Aplicações móvel e web; Rede <i>blockchain</i> ; <i>Data Warehouse</i> e implementação técnica dos modelos descritivos, prescritivos e preditivos para as doenças em análise.
VitalMobile Health [31]	DPOC, ICC, Cancro, Hipertensão, Diabetes, Covid-19	Aplicação móvel; Contacto utente-médico (videoconsulta ou chat); Resultados comprovados: 90% satisfação utilizadores; Mais de 60% redução de urgências; 65% redução de internamentos; 70% redução de custos de internamento.
Linde Saúde [32]	ICC, DPOC, Pós-enfarte agudo do miocárdio, Ventilação não invasiva	Aplicação móvel e web; Serviço de apoio técnico 24 horas; Serviço de assistência de emergência.
Telemonit SNS 24 [33]	ICC, DPOC, Recuperação pós-Covid-19	Aplicação móvel; Agenda de tarefas; Acesso a qualquer utente gratuitamente após indicação do profissional de saúde na sequência de episódios como: consulta, alta de internamento ou episódio de urgência

Como se pode ver pela tabela, os diferentes produtos de telemonitorização apresentam um conjunto comum de serviços (e.g. teleconsulta, monitorização de sinais vitais e alertas), mas apresentam também algumas especificidades conforme as doenças ou condições que mais trabalham. Estes, são fatores de diferenciação que podem permitir às respetivas empresas conquistar posições mais favoráveis no mercado. Neste sentido, no desenvolvimento deste trabalho decidiu-se rentabilizar o conhecimento já adquirido em pilotos na área da DPOC, e implementar, integrar e validar novas lógicas de serviço relacionadas à doença capazes de enriquecer a plataforma de telemonitorização da Altice Labs.

## **2.3 Telemonitorização na DPOC**

O objetivo mais importante de qualquer sistema de alerta ou notificação, como é na sua génese qualquer plataforma de telemonitorização, é detetar, e se possível prever, eventos comuns de risco de vida, para se poderem adotar tratamentos eficazes atempadamente.

Os sistemas de telemonitorização oferecem a oportunidade aos profissionais de saúde de acompanhar e gerir remotamente os seus doentes crónicos, como é o caso do crescente número de doentes com DPOC. Contudo, convém referir que a telemonitorização por si só, não consegue resolver todos os problemas, nem prestar cuidados de saúde de forma holística ao doente. É necessário contar sempre com os profissionais de saúde para acompanhar tanto remota como presencialmente os doentes, interpretar de forma adequada os dados obtidos e agir em conformidade [15].

Em Portugal, o programa de Telemonitorização de Doentes com DPOC pretende obter mais valias na área da saúde, através da sua integração nos Cuidados de Saúde Primários e nos Cuidados de Saúde Hospitalares, recorrendo a uma abordagem centrada no doente e ao estabelecimento de parcerias comunitárias [34].

Podem-se enumerar os principais objetivos do programa da Telemonitorização da DPOC em Portugal, (e no mundo em geral), da seguinte forma [34]:

- Elevar a qualidade dos serviços de saúde prestados aos cidadãos, fazendo com que se sintam acompanhados de forma contínua;
- Melhorar a qualidade de vida tanto dos doentes, como dos cuidadores;
- Reduzir a utilização dos serviços de saúde por via da deteção atempada de sintomas de agudização, de modo a prevenir admissões hospitalares, com redução consequente dos custos e melhoria do prognóstico dos doentes;
- Reduzir o número de episódios de internamento por degradação do estado de saúde do doente;
- Reduzir o número de episódios de deslocamento ao serviço de urgência de doentes;
- Seguir de forma proativa e contínua flutuações das condições de cada doente, através de um acompanhamento constante e uma reação atempada que adie o máximo de tempo possível, o agravamento da síndrome;
- Contribuir para o conceito de Saúde de Proximidade, garantindo a facilidade de acesso do doente ao prestador de cuidados de saúde;

- Contribuir para a Literacia em Saúde, particularmente na população envelhecida, promovendo o papel ativo do doente na gestão da sua doença;
- Dignificar o papel do médico, promovendo a abordagem conjunta e completa dos doentes, através da comunicação direta entre profissionais de saúde e da uniformização de procedimentos médicos;
- Promover a evolução e aprendizagem contínua e em equipa entre profissionais de saúde.

Apesar dos já reconhecidos benefícios da aplicação da telemonitorização em doentes com DPOC, esta ainda não é de uso comum devido à falta de evidências convincentes a longo prazo. Porém, existe investigação em curso sobre novas tecnologias e métodos de telemonitorização que apresentam resultados encorajadores, como por exemplo a oscilometria respiratória e a aplicação de algoritmos de *Machine Learning* que permitem que os tratamentos sejam personalizados e que se detetem precocemente exacerbações na DPOC [21].

### **2.3.1 Estudos sobre a revisão da eficácia da telemonitorização na DPOC**

Existem vários trabalhos publicados baseados em ensaios clínicos que analisam a eficácia da telemonitorização em doentes com DPOC. No entanto, muitas das evidências recolhidas por estes trabalhos não permitem tirar conclusões definitivas.

Em 2012, na revisão de McLean et al. [12], os autores avaliaram 10 estudos envolvendo ensaios clínicos, comparando intervenções de telemonitorização, com intervenções de controlo em pessoas com diagnóstico clínico de DPOC. Os principais parâmetros de análise foram a qualidade de vida e o risco de visita às urgências, hospitalização e morte. Os autores concluíram que a telemonitorização não melhorou significativamente a qualidade de vida, nem diminuiu o risco de morte. No entanto, constataram uma redução significativa nas visitas às urgências e hospitalizações, apesar de reconhecerem que precisavam de analisar mais estudos para fortalecer esta ideia.

Por outro lado, no trabalho de C. Kruse et al. [35], os autores afirmaram que a alta variabilidade entre os artigos analisados e as diferentes formas de prestação de serviços de telemonitorização geraram resultados contraditórios na revisão literária dos mesmos. 13 dos 29 estudos reconheceram melhorias nos resultados com a telemonitorização, enquanto que 11 dos 29 não indicaram francas melhorias. Algumas dessas melhorias incluíram a menor necessidade de visitas aos hospitais, melhor gestão da doença e reforço da relação paciente-profissional. Por fim, enfatizaram que pesquisas futuras devem padronizar os serviços de telemonitorização para facilitar a sua avaliação.

Mais recentemente, em 2020 e 2021, nos estudos [36], [37] e [38], os autores identificaram a dificuldade em quantificar os benefícios da telemonitorização e realçaram a necessidade de se realizarem mais estudos. Ainda assim, não encontraram quaisquer danos ou prejuízos para os pacientes com DPOC que foram monitorizados. Nestas análises, o número de exacerbações, melhoria da qualidade de vida e da capacidade de exercício físico, e redução dos sintomas de desconforto respiratório ou de mortes não foi influenciado significativamente quando utilizada telemonitorização, comparativamente aos cuidados clínicos habituais. No entanto, foi possível constatar alguns aspetos positivos no uso da telemonitorização, tais como a redução considerável do risco de reinternamento hospitalar, e conseqüentemente, o número de reinternamentos [38], a redução do número de visitas às urgências devido a exacerbações graves [37] e maior satisfação do paciente e dos profissionais de saúde [36], [37].

Ainda em 2021, E. Metting et al. [39] consideraram a telemonitorização eficaz, viável e segura, em comparação com os cuidados habituais para pacientes com DPOC; citando: “A telemonitorização pode melhorar vários resultados clínicos em pacientes com DPOC, incluindo a necessidade de hospitalização, tempo de hospitalização, número de visitas, qualidade de vida e número de exacerbações. Adicionar um elemento educacional à intervenção de telemonitorização parece aumentar a perspectiva positiva”.

Por fim, em 2022, F. Nagase et al. [40] reforçaram que existe uma quantidade considerável de evidências a favor da eficácia da telemonitorização. No entanto, referem que essas evidências precisam de ser interpretadas com cautela, devido à heterogeneidade dos ambientes de atendimento, e por vezes à baixa qualidade das mesmas. Os autores consideraram a telemonitorização segura, mas afirmaram que não parece melhorar a qualidade de vida e a função pulmonar, reduzir a depressão e a ansiedade, nem mesmo a utilização de recursos de saúde. Relativamente a aspetos positivos, reforçaram que a telemonitorização reduziu os internamentos hospitalares relacionadas à DPOC e aumentou a satisfação dos pacientes e dos profissionais, consideravelmente.

Os estudos identificados são diversificados, em termos de métodos de análise, bases de dados exploratórias (e.g., Medline Embase, B-on, Web of Science, PubMed, Cochrane Library, etc.) e métricas de avaliação (e.g., qualidade de vida, número de exacerbações, internamentos hospitalares, visitas às urgências, mortes etc.). No entanto, as conclusões finais são relativamente semelhantes, assegurando a falta de evidências suficientes para afirmar a eficácia do uso da telemonitorização na DPOC, mas assinalando alguns aspetos positivos/benefícios da utilização da mesma. Todos referem que são necessários mais estudos baseados em ensaios clínicos para comprovar a eficácia da telemonitorização a longo prazo, contudo os resultados já analisados são encorajadores, sobretudo no que diz respeito à redução de exacerbações e internamentos, e aumento da satisfação dos doentes.

No desenvolvimento deste trabalho vão ser implementados e integrados no SmartAL novos módulos de análise de dados de doentes com DPOC. Um dos módulos pretende precisamente aumentar a satisfação de ambos, doentes e profissionais, fornecendo-lhes alertas mais detalhados, enquanto o outro, mais experimental, pretende contribuir para melhor diagnosticar as doenças respiratórias e em particular a DPOC. A intenção é, posteriormente, utilizar e validar estes novos módulos em projetos piloto da Altice Labs com unidades hospitalares.

### **2.3.2 Características de Projetos-piloto de telemonitorização**

Dado o âmbito deste trabalho, dos estudos apresentados anteriormente, foram explorados em mais detalhe os ensaios clínicos que em função da utilização de certos dispositivos e tecnologias, avaliaram resultados e possíveis indicadores focados na deteção e classificação de exacerbações. Nesta secção, descrevem-se os dispositivos de medição mais comuns, assim como as métricas e indicadores mais usados nesses estudos.

#### *2.3.2.1 Dispositivos e tecnologias de telemonitorização para pacientes com DPOC*

A telemonitorização de pacientes é apoiada pela pesquisa e desenvolvimento da tecnologia de sensorização. Atualmente, existem vários sensores e ferramentas capazes de monitorizar atividades físicas e medir parâmetros fisiológicos e bioquímicos [15]. A lista que se segue indica os mais comuns.

- **Espirómetro:** mede os volumes de ar inspirado e expirado pelos pulmões para avaliar a função pulmonar de um paciente. Comparam-se com valores de referência de uma população de pacientes ou com medições anteriores do mesmo paciente. A presença de limitação do fluxo aéreo é reconhecida pela redução da relação FEV<sub>1</sub>/FVC. É utilizada principalmente no diagnóstico da DPOC e avaliação da sua gravidade, progressão e prognóstico.
- **Oxímetro de pulso:** faz a medição contínua da saturação de oxigénio periférico (SpO<sub>2</sub>). O princípio de funcionamento tem como base a emissão de dois comprimentos de onda diferentes de um lado do corpo, usando um par de pequenos díodos emissores de luz, e medir a quantidade de luz que passa pelo corpo com um fotodíodo colocado do outro lado do corpo.
- **Eletrocardiograma portátil:** regista a atividade do coração com base nos seus sinais elétricos, ou seja, capta as diferenças do potencial elétrico gerado pelo músculo cardíaco, através de eléctrodos colocados em determinadas partes do corpo. Usado para despistar problemas cardiovasculares.

- Termómetro: mede a temperatura ou variações de temperatura corporal. A função corporal normal depende de uma temperatura relativamente constante. Uma temperatura corporal superior a 38,5 °C é um dos parâmetros que pode indicar uma exacerbação grave.
- Balança: mede a massa de um corpo em kg. Tanto a obesidade quanto a perda de massa corporal são comuns em pacientes com DPOC.
- Pedómetro: dispositivo que conta o número de passos. A partir do número de passos contados, é possível estimar não só a distância percorrida, mas também a energia gasta. Pacientes com DPOC têm frequentemente níveis baixos de atividade física, algo que necessitam exercitar.
- Questionários de autoavaliação de sintomas: questionários que podem ser fornecidos ao paciente diariamente para avaliar o seu estado de saúde e bem-estar. Podem incluir campos como a frequência de tosse, produção de escarro, falta de ar (dispneia), dor, sentimentos gerais (e.g. ansiedade, depressão), avaliação da atividade física e outras perguntas. Alguns destes questionários serão analisados com mais detalhe durante a fase de implementação.

No desenvolvimento deste trabalho, vão ser utilizados dados provenientes dos seguintes instrumentos: oxímetro de pulso, termómetro, balança e questionários de autoavaliação de sintomas, mais concretamente, os questionários QCD, CAT e TAT.

#### *2.3.2.2 Pilotos DPOC*

Os estudos piloto servem normalmente para avaliar a potencial viabilidade, segurança e eficácia de uma nova intervenção, antes de ser implementada em maior escala. No caso dos trabalhos revistos na subsecção 2.3.1, os estudos piloto serviram para avaliar a eficácia da telemonitorização em pacientes com DPOC. Na sua avaliação, foram utilizadas métricas que tentaram quantificar o impacto da telemonitorização nestes doentes, quando comparados com os habituais grupos de controlo. A ideia é perceber se as novas soluções apresentam de facto melhores resultados. As métricas mais utilizadas nos estudos piloto foram as seguintes:

- Visitas às urgências;
- Visitas ao médico;
- Exacerbações;
- Tempo até à primeira exacerbação;
- Mortalidade;
- Capacidade de exercício e níveis de atividade;

- Qualidade de vida relacionada com a saúde;
- Admissões hospitalares;
- Tempo até à primeira admissão;
- Internamentos hospitalares;
- Duração das hospitalizações;
- Função pulmonar e outros sintomas;
- Saúde mental;
- Experiência do paciente;
- Experiência do profissional de saúde;
- Segurança;
- Autoeficácia;
- Tratamentos e medicações;
- Condições mórbidas;
- Custos;
- Eficácia dos custos.

No desenvolvimento deste trabalho, este tipo de métricas foi explorado, mas não utilizado diretamente nos novos módulos, por falta de dados associados. Contudo, o reconhecimento da sua importância tem relevância para a Altice Labs. Procurar no futuro recolher dados junto das unidades hospitalares vai permitir executar estudos mais aprofundados sobre a DPOC e atuar mais na área da prevenção.

#### *2.3.2.3 Indicadores*

A aplicação mais eficaz de novas soluções de telemonitorização depende muito da avaliação de indicadores que consigam detetar e classificar exacerbações. A escolha de medições que podem estar de alguma forma relacionadas com episódios de exacerbação, permite naturalmente a sua deteção mais eficiente, e consequentemente, melhor gestão e controlo da doença.

Neste contexto, identificam-se os seguintes sinais e sintomas que podem levar a exacerbações graves na DPOC [15]:

- Mudança na frequência da tosse;
- Mudança na produção e aparência do escarro (expetoração);
- Aumento da dispneia em repouso;
- Sibilância e Crepitação exagerada;

- Incapacidade de dizer frases completas;
- Edema no tornozelo;
- Pioria da cianose;
- Uso de músculos acessórios;
- Perda de atenção;
- Temperatura  $> 38.5^{\circ}\text{C}$ ;
- Frequência respiratória  $> 25/\text{min}$ ;
- Frequência cardíaca  $> 110/\text{min}$ ;
- PEF (*Peak expiratory flow*)  $< 100 \text{ l}/\text{min}$ ;

E os seguintes sinais e sintomas que podem levar à ocorrência de eventos de risco de vida [15]:

- Paragem respiratória ou cardíaca;
- Confusão ou coma;
- $\text{PaO}_2 < 6.7 \text{ kPA}$  (50 mmHg);
- $\text{PaCO}_2 \geq 9.3 \text{ kPA}$  (70 mmHg);
- $\text{pH} < 7.3$ ;

Existem parâmetros de avaliação das exacerbações graves da DPOC que são normalmente medidos em ambiente hospitalar. Contudo, atualmente podem também ser coletados em ambientes domésticos, através de espirômetros, medidores de oxigenação e dispositivos portáteis de ECG [15]:

- $\text{FEV}_1 < 1 \text{ l}$ ;
- $\text{PaO}_2 < 8 \text{ kPA}$ ;
- $\text{SaO}_2 < 90\%$ ;
- $\text{PaCO}_2 \geq 6 \text{ kPA}$ ;
- Anomalias no eletrocardiograma.

Neste trabalho, não se avançou em termos de implementação para a avaliação detalhada de muitos destes parâmetros por falta de dados, mas atuou-se a outro nível. Analisaram-se dados de  $\text{SpO}_2$  e de outros sinais vitais complementares (e.g., temperatura, frequência cardíaca, glicose e pressão arterial), assim como de indicadores extraídos de questionários de autoavaliação de sintomas para a DPOC (e.g., mudanças na frequência da tosse, expectoração, dispneia e perda de atenção). Cruzando estes dados foi possível desenvolver regras que despoletaram novos alertas que ajudam diariamente os profissionais a prevenir exacerbações. Por outro lado, usando uma base de dados de sons respiratórios

foi possível experimentar algoritmos capazes de analisar sibilação e crepitação que apoiam no diagnóstico da DPOC e de outras doenças respiratórias.

### 2.3.3 Projetos-piloto de telemonitorização em Portugal

Em Portugal, já decorreram e continuam a decorrer pilotos de telemonitorização de doentes com DPOC em centros hospitalares, tais como, na Unidade Local de Saúde do Alto Minho (ULSAM), no Hospital de Santarém (HDS) e no Hospital Professor Doutor Fernando Fonseca (HFF).

O Projeto-piloto de telemonitorização de pacientes com DPOC na ULSAM [34], realizado entre abril de 2014 e fevereiro de 2017, foi financiado pela Administração Central do Sistema de Saúde (ACSS). Participaram neste projeto 24 doentes com critérios de inclusão rigorosos; tinham idade superior ou igual a 40 anos, diagnóstico de DPOC GOLD com classe funcional C e D, registo de pelo menos 2 episódios de urgência ou 1 episódio de internamento no ano anterior e cessação tabágica há pelo menos 6 meses.

Este projeto foi constituído por uma equipa multidisciplinar que integrou pessoas de gestão (coordenação do projeto), enfermagem (6 enfermeiros), medicina (médico responsável pelo Serviço de Pneumologia) e técnicas (fornecedor da solução). A sua implementação e operacionalização foi realizada em 13 etapas. Na Figura 9, é possível observar o plano passo-a-passo. Como dispositivos de medição, utilizaram-se tensiómetros, oxímetros, termómetros e pedómetros. No telemóvel, instalou-se uma aplicação de telemonitorização que serviu para registo dos dados e para aceder aos sistemas de informação da unidade hospitalar.

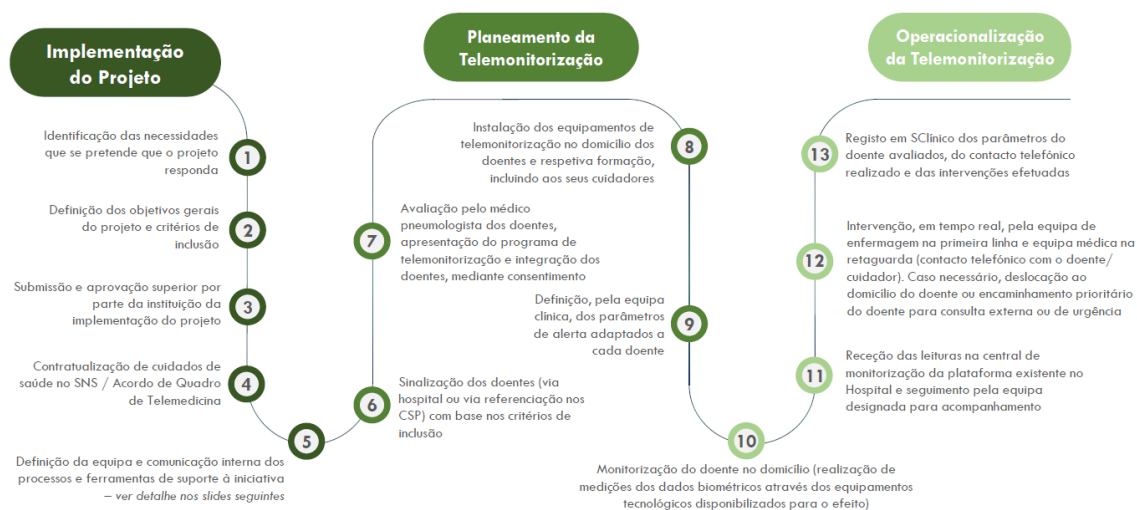


Figura 9 - Plano de implementação e operacionalização do Programa de Telemonitorização da DPOC na ULSAM [34]

O balanço na prestação do serviço foi extremamente positivo. Ao fim de 12 meses, este projeto constatou os seguintes factos [41]:

- Redução de idas ao Serviço de Urgência de cerca de 50%;
- Redução dos internamentos superior a 70%;
- Intervenções médicas menores do que as previstas, tendo a equipa de enfermagem resolvido a maior parte das intervenções necessárias;
- Grau de satisfação positivo de doentes e familiares.
  - 94.6% consideram que o projeto beneficiou a família;
  - 94.6% consideram que o projeto diminuiu os níveis de ansiedade;
  - 96.4% consideram que o projeto ajudou a lidar melhor com os sintomas e a compreender a doença.

Em 2021, tanto o Serviço de Pneumologia do HDS [42] como o Serviço de Pneumologia do HFF [43] arrancaram com projetos-piloto de telemonitorização na área da DPOC. Para além de ajudar os doentes, o grande objetivo destes programas era tentar combater as elevadas taxas de internamento/reinternamento, os deslocamentos desnecessários aos hospitais e, conseqüentemente, reduzir os custos associados. Ambos começaram com um número reduzido de doentes, 5 e 8, respetivamente, mas com previsão de crescer, tendo a seleção inicial sido feita com base na gravidade dos casos (doentes com mais idas às urgências e maior número de internamentos). Ainda não existem dados sobre os resultados/desfechos concretos destes projetos, ou pelo menos ainda não são do conhecimento público. No entanto, o diretor de Serviço do HFF referiu que acredita na solução adotada e que a telemonitorização deveria ser prioritária em todos os serviços de pneumologia [43].

Projetos-piloto de telemonitorização têm grande potencial, e é importante que os hospitais, em conjunto com empresas e outras entidades, comecem a realizar mais experiências nesse sentido, nem que sejam de pequena dimensão. De acordo com o pneumologista Gustavo Reis do HDS, estes programas não só ajudam os doentes, como também contribuem para combater as elevadas taxas de internamento e reinternamento e, conseqüentemente, os custos associados. Segundo ele, “doentes com 8, 9 internamentos por ano, representam em muitos casos, uma permanência em ambiente hospitalar de 2 meses” [42]. Para se conseguir diminuir este tipo de situações, deve-se continuar a apostar na digitalização dos serviços e na sua prestação remota. Neste contexto, a telemonitorização é sem dúvida uma mais-valia.

A Altice Labs também tem alguns pilotos em curso com instituições hospitalares; um com o CHULC (Centro Hospitalar de Lisboa Central) que começou há cerca de dois anos com a telemonitorização de doentes com traumas respiratórios pós-covid e que tem vindo a ser alargado a doentes com

DPOC; outro, mais recentemente, só com doentes DPOC do Centro Hospitalar Universitário de São João (CHUSJ) que depois será reproduzido no Centro Hospitalar de Lisboa Ocidental (CHLO) e no Centro Hospitalar Universitário de Coimbra (CHUC).

No âmbito deste trabalho, contamos com a colaboração de profissionais de saúde envolvidos no piloto do CHULC. Eles ajudaram a definir, as prioridades, as métricas e as regras a aplicar no desenvolvimento do módulo 1. Os detalhes de implementação são apresentados no capítulo 4.

## 2.4 Machine Learning nas doenças respiratórias

A auscultação pulmonar com estetoscópio é o método de diagnóstico tradicional e mais popular, empregado por especialistas e clínicos gerais para identificar anormalidades no sistema respiratório. Embora existam outras estratégias, esta continua vital para os médicos, devido à sua simplicidade e baixo custo. Porém, com a forte evolução da Inteligência Artificial e sua aplicação na área da saúde, começam a surgir soluções automatizadas e com maior precisão no diagnóstico [44].

Ultimamente, abordagens baseadas em *Machine Learning* e *Deep Learning* têm desempenhado um papel importante na disponibilização de soluções que permitem responder a alguns desafios clínicos pertinentes. A partir de grandes volumes de dados é possível detetar padrões e suportar o diagnóstico de novos casos, assim como melhorar a precisão preditiva na deteção precoce de doenças [45]. Para tal, contribuem, entre outros, dados geográficos, clínicos, relatórios, imagens e, em particular análise neste trabalho, sons.

Os sons pulmonares são de particular importância para o reconhecimento de doenças respiratórias específicas e para a avaliação das suas características crónicas e não crónicas. Contudo, identificar diferenças subtis entre algumas classes de sons pulmonares adventícios (e.g., sibilos, roncos, crepitações, etc.) pode ser uma tarefa árdua, até mesmo para um profissional, uma vez que pode introduzir subjetividade na interpretação diagnóstica [44].

Para ultrapassar este problema, algoritmos de Inteligência Artificial podem acrescentar valor na interpretação automática de doenças respiratórias a partir de sons pulmonares, especialmente em regiões menos desenvolvidas ou periféricas, onde a disponibilidade de especialistas é limitada.

Neste contexto, novos desenvolvimentos foram realizados nos últimos tempos, apresentando resultados promissores no diagnóstico de doenças respiratórias e classificação de sons adventícios. Na Tabela 3 estão representados alguns trabalhos relacionados, bem como o respetivo objetivo, técnicas e *features* utilizadas, e por fim os resultados obtidos em cada um deles.

Para além destes trabalhos, outros dois [46] e [47] foram considerados como exemplo para tentar compensar o desbalanceamento da base de dados utilizada no âmbito deste projeto. Estes estudos realizaram a classificação de doenças respiratórias, e obtiveram excelentes resultados com *data augmentation*. Contudo, os autores utilizaram dados aumentados no conjunto de teste. Isto, não é uma boa prática, uma vez que para garantir uma avaliação justa e realista do desempenho dos modelos em *Machine Learning* é recomendada a utilização de dados aumentados, apenas no conjunto de treino. Alguns efeitos adversos da referida prática são: a divulgação acidental de informações (para o conjunto de teste dada a semelhança das amostras reais e aumentadas), superestimação do desempenho do modelo (avaliação excessivamente otimista) ou validação cruzada inadequada.

Inspirado nos trabalhos relacionados, o segundo módulo a ser desenvolvido no âmbito desta dissertação pretende aplicar modelos de *Deep Learning* sobre dados de sons respiratórios, mais concretamente sobre o conjunto de dados do desafio *ICBHI 2017 Challenge* [48], já anotados para o diagnóstico de doenças respiratórias.

Tabela 3 - Estudos relacionados, incluindo objetivos, algoritmos, features, técnicas utilizadas e resultados obtidos.

Estudo	Objetivo	Algoritmo(s), features e técnicas	Problema e Resultados
Aykanat et al. (2017) [49]	Desenvolveram um método não invasivo de classificação de sons respiratórios que são registados por um estetoscópio eletrónico e software de gravação de áudio que usa ML/DL.	CNN e SVM; MFCC e STFT.	Saudável, Não Saudável (SN) – accuracy: CNN: 0.86; SVM: 0.86
Perna (2018) [50]	Aplicação de DL sobre dados de sons respiratórios para deteção de doenças crónicas e não crónicas.	CNN e C-RNN; MFCC; data augmentation (smote e rus).	(SN) – accuracy: 0.83; recall: 0.83; f1-score: 0.88 Saudável, Crónico, Não Crónico (SCN) – accuracy: 0.82; recall: 0.82; f1-score: 0.84
Perna e Tagarelli (2019) [51]	Modelação de uma RNN para suporte clínico na deteção de doenças respiratórias.	RNN (LSTM, GRU, BiLSTM, BiGRU); MFCC.	(SN) – ICBHI score: 0.91 (SCN) – ICBHI score: 0.90
Pham et al. (2020) [52]	Aplicação de DL sobre dados de sons respiratórios para deteção de doenças crónicas.	CNN-MoE; Gamatone spectrogram (GAM); data augmentation (MixUp); 5-fold cross validation.	(SN) – sensitivity: 0.99; specificity: 0.83; ICBHI score: 0.91 (SCN) – sensitivity: 0.96; specificity: 0.83; ICBHI score: 0.90
Altan et al. (2020) [53]	Comparar vários algoritmos de ML e DL para o diagnóstico precoce da DPOC usando sons pulmonares multicanais.	DBN (Deep Belief Network) constituída por RBMs (Restricted Boltzmann Machines); kNN; DT; SVM; Hilbert-Huang Transform (HTT); 5-fold cross validation.	(SN) – DBN – accuracy: 0.93; sensitivity: 0.91; specificity: 0.96; AUCROC: 0.97.
Paraschiv e Rotaru (2020) [54]	Apresentaram um método baseado em <i>wearables</i> para classificar doenças respiratórias	CNN; MFCC	Doenças respiratórias (DR) 6 classes - accuracy: 91%
Srivastava et al. (2021) [45]	Aplicação de DL sobre dados de sons respiratórios para deteção de DPOC.	CNN; MFCC, Mel-Spectrogram, Chroma STFT, Chroma CQT, Chroma CENS; data augmentation (Loudness, mask, shift e speed); 10-fold cross validation	(DPOC/Sem DPOC) – MFCC: sensitivity: 0.93; specificity: 0.93; ICBHI score: 0.93
Nguyen e Pernkopf (2022) [55]	Utilizaram modelos ResNet101 pré-treinados para a classificação de sons pulmonares e doenças respiratórias	ResNet101; Logmel spectrogram; CoTuning-Stochastic Normalization	(SN) – ICBHI score: 0.936 (SCN) – ICBHI score: 0.916

## 2.4.1 Modelos de Deep Learning

*Deep Learning* é o ramo de *Machine Learning* onde os modelos computacionais aprendem a realizar tarefas utilizando diretamente dados de imagens, textos ou sons. Estes modelos podem atingir alta precisão, excedendo o desempenho humano.

O termo “deep” refere-se ao número de camadas “ocultas” numa rede neuronal. Normalmente, as redes neuronais tradicionais contêm 2 ou 3 camadas “ocultas”. No entanto, as redes neuronais profundas podem conter até 150 camadas. Estes modelos são treinados com grandes conjuntos de dados anotados e arquiteturas de redes que aprendem *features* diretamente dos dados, sem a necessidade da sua extração manual [56]. Existem redes neuronais discretas (de classificação), cujo objetivo é encontrar fronteiras de decisão que permitam encontrar padrões ou classes, e contínuas (de regressão) que se usam para encontrar a equação que descreve a relação entre duas ou mais variáveis.

Nesta subsecção estão representados os modelos de *Deep Learning* implementados neste trabalho. Os detalhes de implementação encontram-se descritos no capítulo 5.

### 2.4.1.1 Rede Neuronal Convolutiva (CNN)

As redes neuronais convolucionais (*CNN*) representam uma das arquiteturas de *Deep Learning* mais populares e mais usadas na classificação. São do tipo *feed-forward*, em que o padrão de conectividade entre os neurónios é inspirado na organização do córtex visual animal. As *CNN* são particularmente úteis para encontrar padrões em imagens e reconhecer objetos. Para além disso, podem ser bastante eficazes para classificar dados de áudio, sinal e séries temporais.

As *CNNs* são baseadas no termo ‘convolução’ que é uma operação matemática realizada entre 2 variáveis para produzir uma terceira. A entrada para uma camada convolutiva é uma imagem representada por altura x largura x número de canais (e.g., imagem RGB tem 3 canais). Neste trabalho, reutilizou-se este tipo de entrada para os dados de áudio. O pré-processamento dos dados será detalhado, posteriormente, na Descrição da Implementação, secção 5.2.2.

Na Figura 10, é possível observar a arquitetura de uma rede neuronal convolutiva e as suas camadas principais.

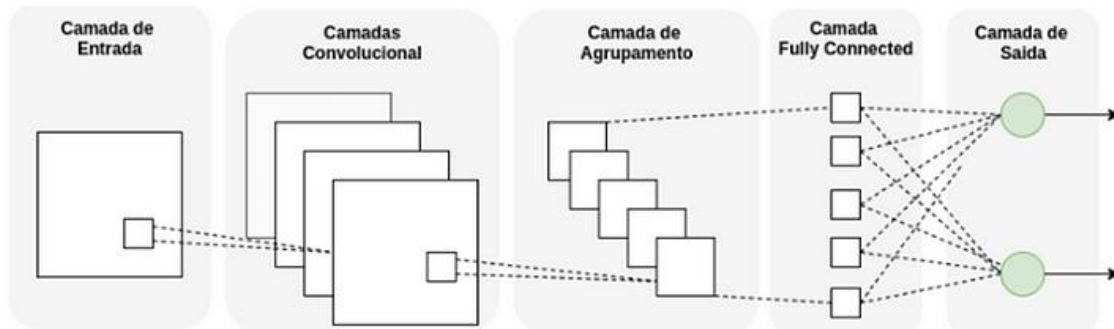


Figura 10 - Arquitetura de uma CNN base e as suas camadas principais

Uma estrutura típica de CNN é composta por múltiplas camadas que são capazes de aprender, de forma adaptativa, a hierarquia espacial dos dados, extraindo padrões de alto e baixo nível. As camadas ocultas mais comuns são as convolucionais, de agrupamento, de *batch normalization*, de *dropout*, *flatten* e camadas densas. Estas camadas servem para o seguinte [44]:

- Camada convolucional: contém os principais elementos estruturais de uma CNN que extraem as *features* dos dados de entrada. Para isso, aplicam conjuntos de filtros, também conhecidos como *kernels* (resposta ao impulso do filtro), cujos valores são aprendidos durante o treino. O resultado das convoluções da camada de entrada através dos *kernels* gera *feature maps* (ou ativação) de maior abstração à medida que avançamos para camadas mais profundas, identificando as características mais discriminativas para a tarefa em questão (classificação ou regressão);
- Camada de agrupamento: reduz a complexidade computacional da rede. Diminui o tamanho do mapa de recursos convolvidos com o intuito de reduzir os custos computacionais. Realiza-se para diminuir as conexões entre as camadas e operar independentemente em cada mapa de recursos;
- Camada de *batch normalization*: normaliza as ativações (saídas) de cada camada da rede, podendo assim tornar o treino mais estável e acelerar a convergência;
- Camada de *dropout*: combate o *overfitting*, desativando alguns dos neurónios. Ajuda a melhorar a generalização do modelo;
- Camada *flatten*: converte os dados multidimensionais provenientes das camadas convolucionais ou de agrupamento num vetor unidimensional;
- Camada densa: mapeia as ativações agregadas de todas as camadas anteriores numa distribuição de probabilidade de classe, criando conexões ponderadas entre elas. Serve para conectar os neurónios entre duas camadas diferentes. As camadas densas são normalmente colocadas antes da camada de saída e formam as últimas camadas de uma arquitetura CNN.

### 2.4.1.2 VGG19

A VGGNet, abreviação de *Visual Geometry Group Network*, é a arquitetura de rede neuronal convolucional proposta por Karen Simonyan e Andrew Zisserman em 2014. O trabalho destes autores propôs uma nova arquitetura CNN profunda para realizar tarefas de reconhecimento de imagem. A principal contribuição da VGGNet foi demonstrar que o aumento da profundidade da rede neuronal é uma estratégia eficaz para melhorar o desempenho em tarefas de visão computacional. Os autores propuseram várias arquiteturas com diferentes profundidades, utilizando camadas convolucionais muito pequenas (3x3) em toda a rede, permitindo que ela fosse mais profunda do que as arquiteturas anteriores [57]. Esta rede alcançou um marco importante no campo da visão computacional e serviu como base para o desenvolvimento de outras redes neurais profundas (e.g. ResNet).

A VGG19 [58] é uma CNN com 19 camadas de profundidade onde é possível carregar uma versão pré-treinada da rede neuronal. Foi treinada em mais de 1M de imagens da base de dados ImageNet [59]. Em consequência, a rede neuronal aprendeu representações ricas em características (*features*) para uma ampla gama de imagens. Esta rede utiliza um tamanho de entrada de imagem de 224 por 224. Consegue classificar imagens em 1000 categorias de objetos (e.g., diferentes animais, teclado, rato, etc.).

Na Figura 11 está representado um exemplo da arquitetura da VGG19 para o ImageNet. Esta arquitetura possui 16 camadas de convolução 3x3, agrupadas em 5 blocos. Após cada bloco, existe uma camada de agrupamento (*Max Pooling*) que diminui o tamanho da imagem de entrada e aumenta o número de filtros da camada de convolução. As dimensões das últimas duas camadas densas no bloco 6 são de 4096 canais, completamente interligados à última de 1000, sendo este o número de classes do problema de classificação em questão.

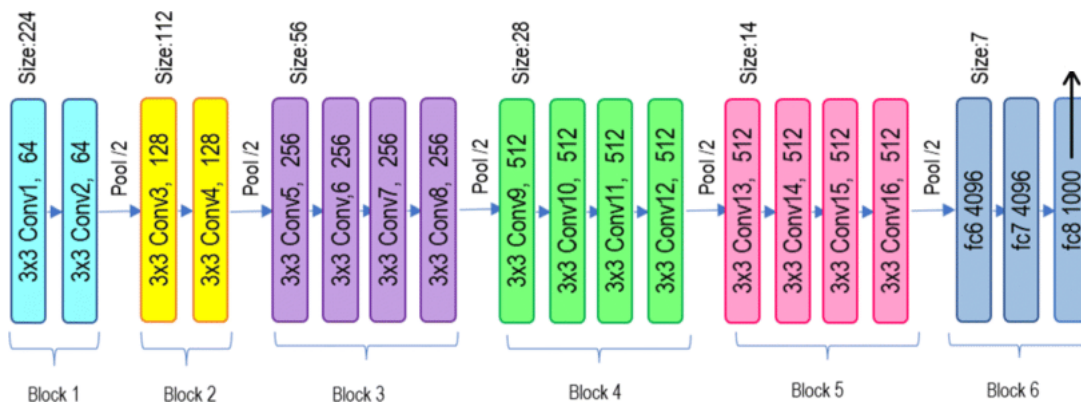


Figura 11 - Arquitetura de uma VGG19

### 2.4.1.3 ResNet50

A ResNet, abreviação de *Residual Network*, é a arquitetura de rede neuronal convolucional proposta por He Kaiming et al. em 2015. O trabalho destes autores propôs uma nova arquitetura para os problemas de classificação de imagens.

A principal contribuição da ResNet foi abordar o problema do “*vanishing gradient*”. Este problema decorre de um fenómeno que acontece durante o treino de redes neuronais profundas, onde os gradientes usados para atualizar a rede tornam-se extremamente pequenos ou “desaparecem”, à medida que são retropropagados das camadas de saída para as camadas anteriores. Para combater este fenómeno, a ResNet permite introduzir blocos residuais que fazem com que as redes neuronais aprendam com os “resíduos” para saltar camadas, em vez de depender estritamente do encadeamento das camadas. Este conceito revolucionou a forma como as redes profundas são projetadas e treinadas, permitindo a construção de arquiteturas mais profundas e eficientes. Assim, com a ResNet, as redes neuronais podem ser treinadas com sucesso em profundidades de até centenas de camadas, sem enfrentar problemas degradantes de desempenho ou dificuldades de otimização [60].

A ResNet50 [61] é uma CNN com 50 camadas de profundidade onde, tal como na VGG19, é possível carregar uma versão pré-treinada da rede neuronal. Também esta foi treinada em mais de 1M de imagens da base de dados ImageNet [59] e como resultado, aprendeu representações ricas em características (*features*) para uma ampla gama de imagens. Esta rede também utiliza um tamanho de entrada de imagem de 224 por 224.

Na Figura 12, está representado um exemplo da arquitetura da ResNet50 para o ImageNet. Esta arquitetura está dividida em 6 partes e é constituída, no total, por 49 camadas de convolução (1 camada de convolução 7x7, 32 camadas de convolução 1x1 e 16 camadas de convolução 3x3), 2 camadas de agrupamento (*Max Pooling* e *Average Pooling*) e 1 camada densa.

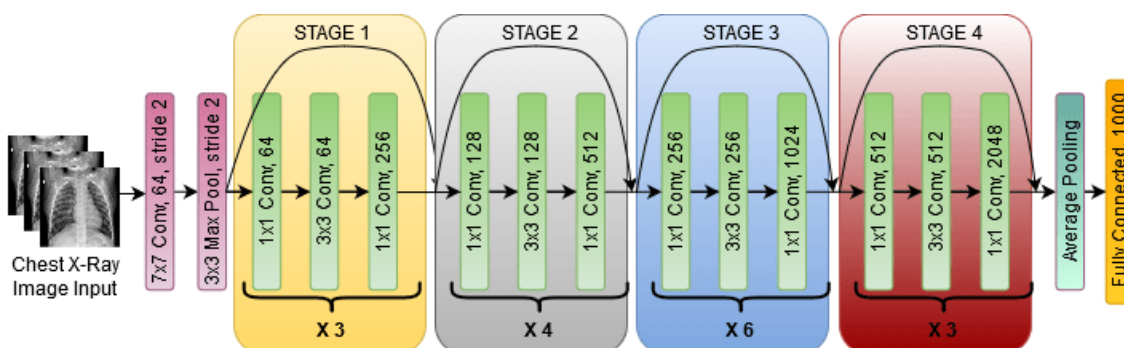


Figura 12 - Arquitetura de uma ResNet50

#### 2.4.1.4 Redes Neurais Recorrentes (LSTM e GRU)

LSTM, abreviação de *Long Short-Term Memory*, e GRU, abreviação de *Gated Recurrent Unit*, são dois tipos de rede neuronal recorrente (RNN) distintas. A ideia básica por detrás das RNNs é permitir que uma rede se lembre de dados anteriores com o objetivo de desenvolver melhores modelos, explorando a progressão de informação sequencial. A principal característica distintiva das RNNs é que a saída depende da entrada atual, bem como das amostras processadas anteriormente. Por outras palavras, as RNNs podem reter informações sobre o passado, permitindo-lhes descobrir correlações temporais entre eventos que estão distantes entre si nos dados [51].

A LSTM foi introduzida por Sepp Hochreiter and Jürgen Schmidhuber em 1997 e visa resolver o problema do “*vanishing gradient*”. Este problema ocorre por vezes nas redes neuronais recorrentes tradicionais quando certas camadas ocultas começam a piorar a classificação em vez de melhorar porque não conseguem encontrar os pesos nem os *bias* certos, o que faz com a velocidade de aprendizagem das diferentes camadas seja instável e muito variável. Para combater este problema, a LSTM ignora dados/informações inúteis na rede. Quando novas informações chegam, a rede determina quais são as que devem ser ignoradas e quais são as que devem ser lembradas [51].

A base das LSTMs é o *cell state* que representa a memória de longo prazo, e é responsável por armazenar informações importantes e relevantes ao longo do tempo. O *cell state* é passado da entrada para a saída de uma célula. Assim, permite que a informação flua ao longo de toda a cadeia através de três *gates*, com apenas pequenas ações lineares. Os três *gates* são denominados: *forget gate*, *input gate* e *output gate*. Estes *gates* funcionam como filtros e controlam o fluxo de informação, determinando qual deve ser mantida ou desconsiderada [62]. Na Figura 13 está representada a arquitetura de uma rede neuronal recorrente LSTM, incluindo os seus *gates*.

Relativamente à GRU, foi introduzida por Cho et al. em 2014 e, tal como a LSTM, visa resolver o problema de “*vanishing gradient*” que ocorre nas redes neuronais recorrentes tradicionais. Contudo, a diferença para a LSTM é que a GRU utiliza menos um gate e não possui memória interna separada, ou seja, *cell state*. Assim, a GRU apenas mantém um *hidden state* em memória, resultando numa arquitetura mais simples [51].

A GRU é composta por uma única célula recorrente e utiliza dois *gates* para fazer o controlo do fluxo de informação, o *reset gate* e o *update gate*. Resumindo, estes são utilizados para controlar a quantidade de informação que é mantida no *hidden state* anterior e a quantidade de informação da entrada atual que é incorporada no novo *hidden state*, a cada passo de tempo [62]. Na Figura 13 está também representada a arquitetura de uma rede neuronal recorrente GRU, incluindo os seus *gates*.

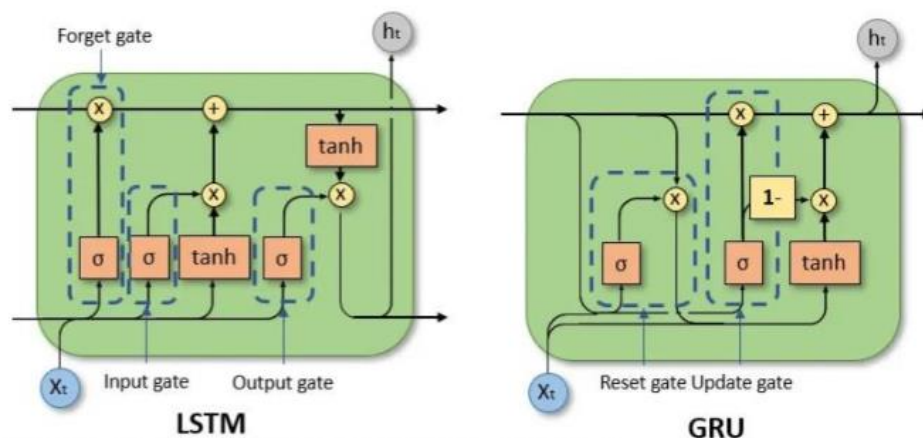


Figura 13 - Arquitetura da LSTM e da GRU [62]

A seleção e aplicação das arquiteturas de *Deep Learning* aqui apresentadas estão, posteriormente, detalhadas na secção 5.2.2 Descrição da Implementação.

## 2.4.2 Técnicas de *Data Augmentation*

*Data Augmentation* é uma técnica que pode ser utilizada para aumentar artificialmente o número de dados no conjunto de treino. O aumento é realizado através da criação de cópias modificadas dos exemplos reais. O uso de *Data Augmentation* é uma boa prática para evitar *overfitting*, erro de modelagem que ocorre quando uma função está muito alinhada com um conjunto limitado de dados. É útil quando o conjunto de dados inicial é muito pequeno para treinar e se pretende melhorar o desempenho do modelo.

No geral, esta técnica é frequentemente usada na construção de modelos de *Machine Learning* e *Deep Learning*. Existem vários tipos de dados que podem ser aumentados (texto, imagem, áudio, entre outros), bem como diferentes estratégias de implementação.

Todas as técnicas apresentadas nesta secção foram aplicadas no desenvolvimento do módulo 2 com o objetivo de avaliar qual delas apresentava melhores resultados. Os detalhes de implementação encontram-se descritos na secção 5.2.2.

### 2.4.2.1 SMOTE (*Synthetic Minority Oversampling Technique*)

O SMOTE é uma técnica de *Data Augmentation* para lidar com dados desequilibrados. Tipicamente, nestes conjuntos de dados, o número de instâncias pertencentes a uma determinada classe ou classes é significativamente menor (classe minoritária) do que o número de instâncias pertencentes a outra classe ou classes (classe majoritária). Esta técnica foi desenhada para resolver esse problema, aumentando a classe minoritária, através da criação de novos exemplos a partir dos exemplos já existentes.

Para criar uma amostra sintética, o SMOTE seleciona uma instância da classe minoritária e, em seguida, uma ou mais instâncias próximas da sua vizinhança. Posteriormente, cria uma nova instância selecionando aleatoriamente um dos vizinhos e calculando a diferença entre os valores de recursos das duas instâncias. O SMOTE multiplica essa diferença por um número aleatório entre 0 e 1 e adiciona o resultado aos valores de recurso da instância minoritária original para criar uma nova instância sintética. Na Figura 14, é possível observar um exemplo do funcionamento do SMOTE [63].




Figura 14 - Exemplo do funcionamento da técnica SMOTE [63]

#### 2.4.2.2 Class Weights

Os modelos base são configurados para tratar as classes com igual importância, mas quando temos um conjunto de dados não balanceado isso não acontece. O desequilíbrio de classes ocorre quando o número de amostras de uma classe supera significativamente o da outra, levando a previsões tendenciosas. Então, é possível utilizar pesos ou *Class Weights* para modificar a importância dada a cada classe e compensar o modelo.

Pesos diferentes permitem ter em consideração a distribuição desbalanceada das amostras em cada classe e ajustar o algoritmo de treino. A técnica em causa, atribui normalmente pesos mais elevados à classe minoritária, permitindo ao modelo prestar mais atenção aos seus padrões e reduzir o viés em relação à classe majoritária.

#### 2.4.2.3 Sound Augmentation

*Sound Augmentation*, como o próprio nome indica, é a técnica usada na aumento de dados sonoros. O aumento é feito através da geração de dados sonoros sintéticos com modificações realizadas diretamente nos sons [64]. Neste trabalho, as modificações efetuadas passaram pela injeção de ruído, alteração do tempo, alteração do *pitch* e alteração da velocidade. Para implementar estas modificações foi utilizada a biblioteca Librosa.

Librosa [65] é uma biblioteca Python de código aberto usada na análise e processamento de som. Esta biblioteca é amplamente utilizada em música, o mesmo será dizer, em processamento de sinais de áudio e análise de áudio.

Detalhando cada uma das abordagens:

- Injeção de ruído: adição de um valor aleatório aos dados;
- Alteração do tempo: processo de modificação da duração de um sinal de áudio sem alterar a sua frequência;
- Alteração do *pitch*: processo de modificação da frequência de um sinal de áudio sem alterar a sua duração de reprodução;
- Alteração da velocidade: combinação entre a alteração do tempo e a alteração do *pitch*, ou seja, processo de modificação da duração e frequência de um sinal de áudio.

#### 2.4.2.4 SpecAugment (Spectrogram Augmentation)

Tradicionalmente, para se realizar *data augmentation* em áudios são aplicadas modificações diretamente à forma de onda do som. Mas, Park et al. [66] apresenta uma abordagem diferente que consiste em manipular o espectrograma. No *SpecAugment*, o aumento dos dados é tratado como um problema visual e não de áudio. Em vez de se alterar a forma da onda do som (e.g., *Sound Augmentation*), aplica-se uma política de aumento, diretamente no espectrograma do áudio (representação visual do espectro de frequências de um sinal conforme a sua variação no tempo). É um método simples, computacionalmente barato de aplicar e não requer dados adicionais [66].

As estratégias consistem no mascaramento da frequência e/ou do tempo. Na primeira, são implementadas bandas horizontais nos espectrogramas enquanto que na segunda são implementadas bandas verticais. Na Figura 15, é possível observar um exemplo da utilização do *SpecAugment*.

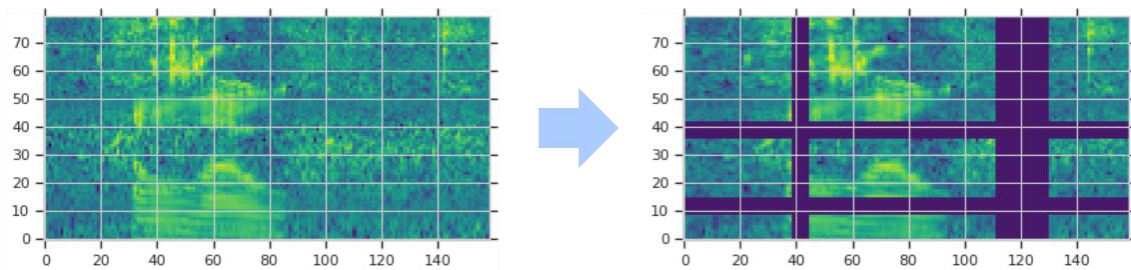


Figura 15 - Exemplo do funcionamento da técnica SpecAugment num espectrograma [66]

### 2.4.3 Extração de Features

Nesta subsecção, estão definidos tipos de extração de *features* para sons. Todas as *features* consideradas foram extraídas utilizando a biblioteca Librosa.

Esta biblioteca oferece uma interface simples e eficiente para a extração de *features* áudio, permitindo assim que programadores e investigadores recolham informação relevante de sinais de áudio para realizar certas tarefas, tais como a classificação, o reconhecimento de fala, a separação de fontes, etc. Para além disso, possui funcionalidades de manipulação e conversão de áudio (e.g. carregamento de arquivos de áudio em diversos formatos, resampling).

Observando e definindo, resumidamente, cada uma das *features* extraídas com o Librosa temos [65]:

- Mel-Frequency Cepstral Coefficients (MFCC): representação de um conjunto de coeficientes usados na análise e processamento de sinais áudio. Capturam informações importantes sobre a distribuição espectral de um sinal áudio numa escala percetual de frequência - a escala mel que é utilizada para imitar a maneira como o aparelho auditivo humano interpreta o espetro das frequências. A *features* são extraídas em etapas, usando técnicas tais como *windowing*, transformada de Fourier de curta duração (STFT), banco de filtros de mel, logaritmo das energias de cada filtro de mel e a Transformada Discreta de Cosseno (DCT). Exemplo de uma pessoa saudável: Figura 16a.
- Mel Spectrogram: representação visual do espetro de frequência de um sinal de áudio, no qual as frequências são mapeadas para uma escala de mel, em vez de uma escala linear como no espetrograma tradicional. Exemplo de uma pessoa saudável: Figura 16b.
- Spectral Contrast: representação da variação de energia entre as frequências dominantes (picos) e as frequências circundantes (vales), no espetro de potência. Útil para extrair informações relevantes sobre o conteúdo espectral do sinal de áudio. Exemplo de uma pessoa saudável: Figura 16c.

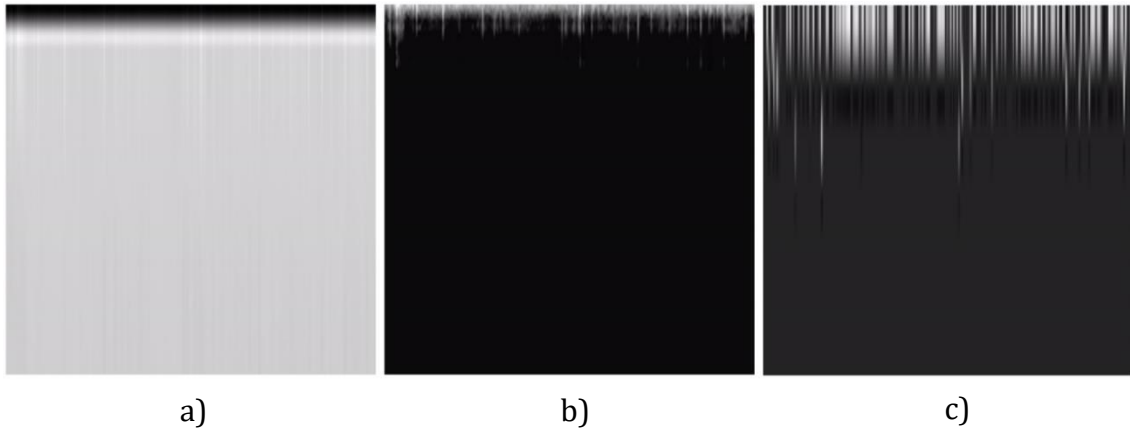


Figura 16 - Features MFCC, Mel Spectrogram e Spectral Contrast

- Chroma STFT: representação da distribuição de energia ou intensidade dos diferentes tons musicais ao longo do tempo. Útil para detetar padrões tonais e harmónicos. Exemplo de uma pessoa saudável: Figura 17a.
- Tempogram: representação visual do ritmo de um sinal de áudio ao longo do tempo. Fornece informações sobre a variação do ritmo e mudanças de acentuação ao longo de um som. Exemplo de uma pessoa saudável: Figura 17b.
- Tonnetz: representação da tonalidade do áudio, ou seja, descreve as relações de tonalidade entre as diferentes notas musicais do áudio. Útil para analisar e visualizar a harmonia e a modulação em músicas. Exemplo de uma pessoa saudável: Figura 17c.




Figura 17 - Features Chroma STFT, Tempogram, Tonnetz

## **2.5 Considerações Finais**

Considerando a proposta de trabalho lançada pela Altice Labs, o estado da arte procurou explorar os conceitos necessários aos dois desenvolvimentos propostos:

- Sistema de alertas baseado no cruzamento de informação proveniente de medições de sinais vitais e de questionários relacionados com a DPOC;
- Aplicação de modelos de *Deep Learning* sobre dados de sons respiratórios para o diagnóstico de doenças respiratórias (incluindo a DPOC).

A primeira solução será implementada e integrada no produto de telemonitorização SmartAL, para posterior validação por parte do profissional de saúde do CHULC envolvido no piloto da DPOC. Os detalhes de implementação desta solução serão encontrados no capítulo 4.

A segunda solução será desenvolvida em Jupyter, fora do SmartAL, uma vez que este não suporta ainda módulos de Inteligência Artificial, contudo, poderá ser integrada futuramente. Os detalhes de implementação desta solução serão encontrados no capítulo 5.



## 3 SMARTAL

Este capítulo detalha o estado atual da solução SmartAL da Altice Labs, no modelo B2B (*Business-to-Business*). Inclui, uma pequena introdução, a descrição das principais funcionalidades e a arquitetura de alto nível do sistema. Relembrando, o primeiro objetivo deste trabalho consiste na integração de uma nova funcionalidade nesta plataforma.

### 3.1 Introdução

SmartAL ou *Smart Assisted Living* é a solução de telemonitorização desenvolvida pela Altice Labs. Este produto tem como principal objetivo oferecer uma ferramenta a utilizadores que tenham necessidade de acompanhar remotamente e em tempo real, o seu próprio estado de saúde ou o de pessoas ao seu cuidado. Visa simplificar o quotidiano destes utilizadores na manutenção da sua saúde e no contacto social. A solução é altamente personalizável para atender às necessidades de cada utilizador, podendo cada um deles ser: paciente, profissional de saúde, cuidador informal e administrativo, entre outros.

A solução SmartAL está disponível como aplicação móvel, TV e Web. Atualmente, a oferta comercial visa o mercado de saúde, seguindo um modelo de negócio B2B, ou seja, o produto é vendido a instituições e só depois estas disponibilizam o serviço aos seus utilizadores.

### 3.2 Principais Funcionalidades

O funcionamento central do ecossistema do SmartAL é a recolha de dados de pessoas, através de dispositivos clínicos (e.g. medidor de SpO<sub>2</sub>) e não clínicos (e.g. *wearables*), para visualização numa interface comum, acessível e compreensível, tanto pelos próprios utilizadores, como pelos seus cuidadores. Usando o SmartAL, ambos conseguem manter-se sempre atualizados sobre o estado de saúde da pessoa telemonitorizada.

Nesta solução, é possível configurar limites (i.e., *thresholds*) para que quando o valor de uma certa medição estiver acima ou abaixo de um intervalo de referência considerado normal, os profissionais de saúde responsáveis pela pessoa, ou pessoas ao seu cuidado, sejam alertados o mais rapidamente possível e atuem de acordo com a gravidade da situação.

O SmartAL oferece a capacidade de medir sinais vitais (e.g., frequência cardíaca, glicose, temperatura, etc.) de forma manual ou automática, através de *Bluetooth*, APIs ou protocolos proprietários disponibilizados pelos fabricantes dos dispositivos. Permite lançar alertas, notificações e lembretes sempre que necessário. Para além disso, oferece serviços adicionais de suporte ao dia-à-dia

dos utilizadores, tais como: teleconsulta, chat e transferência de documentos; gestão da atividade diária através da atribuição e execução de tarefas; questionários de avaliação de sintomas e do bem-estar em geral; vídeos com tutoriais; relatórios e indicadores. O sistema assegura a privacidade dos dados e a encriptação na comunicação dos mesmos.

Atualmente, podem beneficiar desta solução hospitais, lares, municípios, centros de saúde, e outras instituições sociais ou académicas que envolvam profissionais de saúde, cuidadores e doentes que necessitem de cuidados permanentes (e.g., crónicos, idosos) ou ocasionais (e.g., pós-operatório, isolamento, em recuperação).

### 3.3 Arquitetura

A arquitetura de alto-nível do SmartAL B2B está representada na Figura 18.

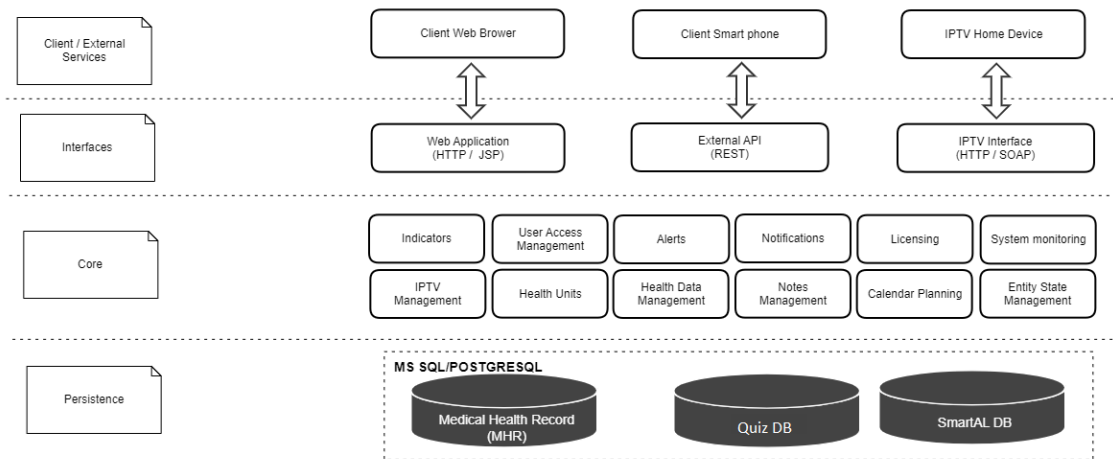


Figura 18 - Arquitetura SmartAL B2B de Alto Nível

No primeiro conjunto de blocos, representado em mais detalhe na Figura 19, é possível observar os três tipos de interfaces, já referidas anteriormente: *Web Browser*, *smartphone* e *TV*. Estes serviços refletem-se nas diferentes aplicações disponibilizadas aos vários tipos de utilizadores.



Figura 19 - Primeiro conjunto de blocos da arquitetura

No segundo conjunto de blocos (Figura 20), temos as interfaces utilizadas por cada um destes três tipos de serviços.



Figura 20 - Segundo conjunto de blocos da arquitetura

O primeiro módulo a desenvolver incide sobre a aplicação *Web* que utiliza o protocolo HTTP com JSP (*JavaServer Pages*), tecnologia que serve para criar páginas *web* dinâmicas com linguagem de programação Java.

No terceiro conjunto de blocos, representado na Figura 21, está o núcleo do SmartAL que contém os elementos funcionais essenciais da solução.



Figura 21 - Terceiro conjunto de blocos da arquitetura

Por fim, o quarto conjunto de blocos, na Figura 22, representa a “persistência” do SmartAL que se refere ao modo como o serviço gere e mantém os dados necessários para as suas operações.



Figura 22 - Quarto conjunto de blocos da arquitetura

É aqui que está presente o MHR (*Medical Health Record*) que contém o registo de saúde dos pacientes que utilizam o SmartAL, a base de dados Quiz que contém toda a informação relacionada com os questionários e a base de dados SmartAL que armazena a restante informação (e.g. relação entre os cuidadores e utentes, trocas de mensagens entre os mesmos, notas que cuidadores criam sobre os utentes, alertas despoletados pelos serviços, etc.). A tecnologia utilizada para o armazenamento é PostgreSQL, uma base de dados relacional e *open-source*.

### **3.4 Resumo**

Neste capítulo, foram apresentadas as principais funcionalidades e a arquitetura de alto nível do SmartAL B2B. É importante perceber o funcionamento e trabalho por detrás desta solução, uma vez que o primeiro módulo a ser desenvolvido será implementado e integrado nesta solução de telemonitorização da Altice Labs.

O próximo capítulo descreverá todo o processo de desenvolvimento deste trabalho, incluindo tecnologias utilizadas, módulos implementados, casos de uso e lições aprendidas, entre outros detalhes.

## **4 MÓDULO 1 – SERVIÇO DE ALERTAS DPOC**

A solução de telemonitorização SmartAL da Altice Labs continua em desenvolvimento e constante evolução. Deste modo, servirá de base para a primeira parte do trabalho a ser desenvolvido neste estágio que tem como objetivo: o desenvolvimento de lógica de serviço que cruza informação da medição de sinais vitais relativos à DPOC com informação de questionários, e gera notificações e alertas em conformidade com condições pré-identificadas. Este trabalho, surgiu no âmbito do programa de colaboração entre a Altice Labs e o Hospital CHULC (Centro Hospitalar Universitário de Lisboa Central) que resultou num piloto (ainda em curso) abrangendo inicialmente doentes com traumas pós-COVID, e mais recentemente doentes que sofrem de DPOC.

### **4.1 Tecnologias**

Nesta subsecção, são identificadas e descritas as tecnologias utilizadas na implementação do módulo 1 a integrar no SmartAL, designado Serviço de Alertas DPOC.

#### **4.1.1 Java versão 8+ e Apache Tomcat**

Java é uma linguagem de programação orientada a objetos desenvolvida na década de 90 na empresa *Sun Microsystems*. Esta linguagem é utilizada pelos programadores da Altice Labs no desenvolvimento de várias soluções. Por esse motivo, houve a necessidade de passar por um período de aprendizagem, uma vez que não tinha tido contacto com a mesma no meu percurso académico.

O Apache Tomcat é um popular servidor *open source web* de container *Servlet* para código Java e também foi utilizado no mesmo contexto.

#### **4.1.2 Visual Studio Code**

O Visual Studio Code é um editor de código-fonte leve e poderoso, executado na área de trabalho e disponível para vários sistemas operativos. Esta ferramenta vem com suporte integrado para JavaScript, TypeScript e Node.js e possui um rico ecossistema de extensões para outras linguagens de programação e *runtimes* como C++, C#, Java, Python, entre outras. Esta foi a tecnologia utilizada para implementar a lógica do serviço de alertas DPOC.

### 4.1.3 TortoiseSVN

O TortoiseSVN é um cliente *Subversion open source*, implementado como uma extensão *shell* do Microsoft Windows, que ajuda os programadores a gerir diferentes versões do código-fonte para os seus programas. Esta tecnologia é utilizada para gerir diferentes versões de código-fonte no SmartAL.

## 4.2 Implementação

Esta secção descreve a metodologia utilizada, os casos de uso, o fluxo de decisão e os detalhes da implementação.

### 4.2.1 Metodologia

A metodologia seguida para o desenvolvimento do novo módulo passou por várias fases que se apresentam de forma resumida na Figura 23.

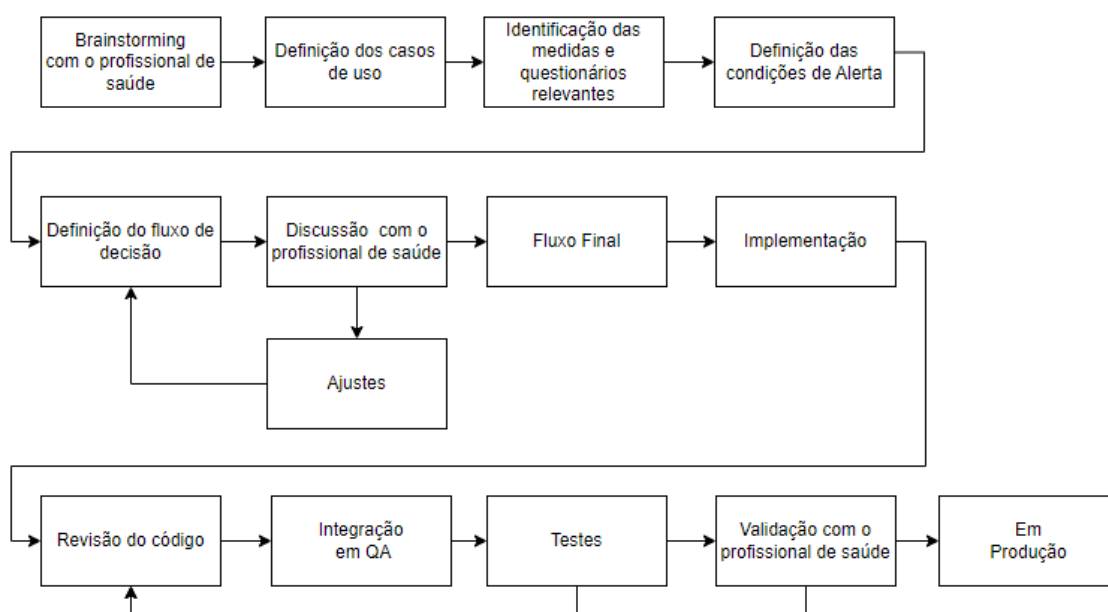


Figura 23 - Metodologia de implementação do Serviço de Alertas DPOC

Após algumas audioconferências com o profissional de saúde que acompanha vários doentes com DPOC no CHULC em regime de telemonitorização com o SmartAL onde se discutiu o objetivo e a mais-valia do novo serviço de alertas DPOC, delineararam-se os casos de uso. Para concretizar cada um dos cenários, foi necessário definir e colocar no SmartAL os questionários necessários e as respetivas pontuações, assim como identificar as medições a considerar e as severidades associadas. Depois de definir o fluxo de decisão que combinava as medições com as respostas aos questionários, apresentou-se o resultado ao profissional de saúde. Foram precisas algumas iterações, até tudo fazer sentido e fechar a lógica do serviço. Uma vez concluída, deu-se início à implementação.

A equipa da Altice Labs fez a revisão do código e a integração em QA com o SmartAL para se poder testar. Detetaram-se alguns erros que foram corrigidos. Validou-se o resultado final com o profissional de saúde que sugeriu ainda alguns ajustes nos alertas a enviar aos utilizadores. Assim que passou pela sua aprovação final colocou-se em produção na instância que serve o CHULC. Nas secções seguintes descrevem-se em detalhe alguns dos passos seguidos no processo de especificação e implementação do módulo.

#### **4.2.2 Casos de Uso**

Nesta subsecção, descrevem-se alguns dos casos de uso já existentes no SmartAL, ou seja, que já existiam, mas que são importantes serem explicados para dar contexto ao que foi desenvolvido. Para além desses, descrevem-se também os novos casos de uso.

Tabela 4 - Caso de uso "Login" (já existente)

<b>Caso de Uso</b>	<b>Login</b>
Descrição	Permite o paciente ou cuidador/médico fazer login na plataforma SmartAL utilizando as suas credencias, nome de utilizador e password, para aceder à sua conta.
Atores	Paciente ou cuidador/médico
Pré-condição	Estar registado na plataforma SmartAL
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. O utilizador acede à página de login do SmartAL.</li> <li>2. Insere o seu nome de utilizador e password.</li> <li>3. O sistema valida as credencias do utilizador.</li> <li>4. Se as credencias estiverem corretas, o acesso é garantido.</li> <li>5. Se as credencias estiverem incorretas, é apresentada uma mensagem de erro e o login falha.</li> <li>6. O utilizador pode tentar voltar a fazer login ou mudar a sua password.</li> </ol>

Tabela 5 - Caso de uso "Agenda Tarefa" (já existente)

<b>Caso de Uso</b>	<b>Agenda tarefa</b>
Descrição	Permite ao cuidador/médico agendar uma tarefa de medição no calendário do paciente. Esta facilita ao doente a lembrança de medir sinais vitais, tais como a pressão arterial, frequência cardíaca, temperatura, saturação do oxigénio ou glicose na plataforma SmartAL.
Atores	Cuidador/médico
Pré-condição	Estar registado na plataforma SmartAL e ter um paciente associado.
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. O cuidador/médico faz login na plataforma SmartAL.</li> <li>2. O cuidador/médico cria uma tarefa de medição na página de gestão de tarefas na aba "Planeamento" do menu da aplicação.</li> <li>3. O cuidador/médico digita um nome para a tarefa, seleciona os parâmetros, define uma periodicidade e configura as notificações.</li> <li>4. O cuidador/médico confirma os detalhes da tarefa e cria a tarefa.</li> <li>5. O cuidador/médico associa a tarefa a um paciente.</li> <li>6. A tarefa fica agendada no calendário do paciente.</li> </ol>

Tabela 6 - Caso de uso "Regista medida de saúde" (já existente)

<b>Caso de Uso</b>	<b>Regista medida de saúde</b>
Descrição	Permite ao paciente registar e armazenar o valor de medidas de saúde como a pressão arterial, temperatura, frequência cardíaca, saturação do oxigénio ou glicose na plataforma SmartAL.
Atores	Paciente
Pré-condição	Estar registado na plataforma SmartAL e ter uma tarefa associada.
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. O paciente faz login na plataforma SmartAL.</li> <li>2. O paciente acede à página de "Saúde" e regista o valor de uma medida de saúde de forma automática (acionando o Bluetooth) ou de forma manual.</li> <li>3. O paciente seleciona a medida de saúde que pretende registar e o respetivo valor.</li> <li>4. O paciente confirma o registo da medida de saúde.</li> <li>5. O valor da medida de saúde é registado com sucesso.</li> <li>6. A medida está normal e nada acontece ou a medida está fora do normal e gera um alerta.</li> </ol>

Tabela 7 - Caso de uso "Responde a um questionário" (já existente)

<b>Caso de Uso</b>	<b>Responde a um questionário</b>
Descrição	Permite ao paciente responder e submeter um questionário.
Atores	Paciente
Pré-condição	Estar registado na plataforma SmartAL e ter um questionário associado para responder.
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. O paciente faz login na plataforma SmartAL.</li> <li>2. O paciente acede à página de “Questionários” e verifica se existe algum questionário disponível para ser respondido.</li> <li>3. O paciente abre o questionário e responde às questões conforme as instruções facultadas.</li> <li>4. O paciente submete o questionário no fim de responder às questões.</li> <li>5. O questionário é submetido e as respostas são armazenadas na base de dados do Quiz podendo ou não gerar alertas.</li> </ol>

Tabela 8 - Caso de uso "Recebe alerta" (já existente)

<b>Caso de Uso</b>	<b>Recebe alerta</b>
Descrição	Permite ao cuidador/médico receber e visualizar alertas na plataforma SmartAL, quando os valores das medições de um paciente estão fora do normal.
Atores	Cuidador/médico
Pré-condição	Estar registado na plataforma SmartAL, ter um paciente associado e existirem valores de medidas de saúde fora do normal para esse paciente.
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. A aplicação gera um alerta em resposta a um certo valor ou conjunto de valores de medidas de saúde fora do normal para um dos seus pacientes.</li> <li>2. O cuidador/médico faz login na plataforma do SmartAL.</li> <li>3. O cuidador/médico recebe o alerta e acede ao perfil do utilizador para visualizar mais informações.</li> <li>4. O cuidador/médico verifica o alerta e toma as ações necessárias para resolver o problema.</li> </ol>

Tabela 9 - Caso de uso "Recebe notificação" (já existente)

<b>Caso de Uso</b>	<b>Recebe notificação</b>
Descrição	Permite ao paciente receber e visualizar notificações na plataforma SmartAL quando é necessário serem executadas determinadas tarefas ou em caso de avisos.
Atores	Paciente
Pré-condição	Estar registado na plataforma SmartAL, ter uma tarefa associada ou existirem valores de medidas saúde fora do normal para esse paciente.
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. A aplicação gera uma notificação em resposta a um esquecimento do paciente para realizar uma medição de saúde agendada.</li> <li>2. A aplicação gera uma notificação em resposta à atribuição de um questionário ao paciente, avisando o mesmo para responder.</li> <li>3. O cuidador/médico faz login na plataforma SmartAL.</li> <li>4. O paciente recebe a notificação.</li> <li>5. O paciente verifica a notificação e toma as ações indicadas para o problema.</li> </ol>

Tabela 10 - Caso de uso "Notificação Medições vs. Questionário QCD" (novo)

<b>Caso de Uso</b>	<b>Notificação Medições vs. Questionário QCD</b>
Descrição	Permite ao paciente receber uma notificação, caso tenha efetuados medições de sinais vitais e os valores estejam fora do normal. Essa notificação indica que tem de responder a um questionário QCD.
Atores	Paciente
Pré-condição	Paciente estar registado na plataforma do SmartAL. Paciente registar certas medidas de saúde fora do normal.
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. O paciente faz login na plataforma SmartAL.</li> <li>2. O paciente regista um valor fora do normal de saturação do oxigénio (gerando um alerta vermelho) e despoletando a associação do questionário QCD.</li> <li>3. O paciente regista dois valores consecutivos fora do normal para uma das seguintes medidas: saturação do oxigénio, temperatura, frequência cardíaca, pressão arterial ou glicose despoletando a associação do questionário QCD.</li> <li>4. O paciente regista dois valores fora do normal para duas das seguintes medidas: saturação do oxigénio, temperatura, frequência cardíaca, pressão arterial ou glicose despoletando a associação do questionário QCD.</li> </ol>

Tabela 11 - Caso de uso "Alerta 1 – Resultado QCD" (novo)

<b>Caso de Uso</b>	<b>Alerta 1 – Resultado QCD</b>
Descrição	Permite ao cuidador/médico receber um alerta, caso um paciente com DPOC tenha obtido uma pontuação igual ou superior a 2 no questionário QCD. Permite ao paciente receber uma notificação, caso tenha obtido uma pontuação igual ou superior a 2 no questionário QCD.
Atores	Paciente e cuidador/médico
Pré-condição	Paciente e cuidador/médico estarem registados na plataforma do SmartAL e associados entre si. Paciente despoletar o Tabela 10 - Caso de uso "Notificação Medições vs. Questionário QCD" (novo)
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. O paciente faz login na plataforma SmartAL.</li> <li>2. O paciente acede à aba “Questionários” e abre o Questionário QCD disponível.</li> <li>3. O paciente responde às perguntas do questionário de ‘Sim’ ou ‘Não’</li> <li>4. O paciente submete as respostas do questionário.</li> <li>5. O paciente obtém uma pontuação igual ou superior a 2 no questionário.</li> <li>6. O questionário de Acompanhamento da DPOC é associado ao paciente.</li> <li>7. A aplicação gera um alerta para o cuidador/médico com a mensagem “O utente (nome) obteve uma pontuação igual ou superior a 2 no QCD. Precisa agora de responder ao questionário de Acompanhamento da DPOC”.</li> <li>8. A aplicação gera uma notificação para o paciente com a mensagem “Por favor responda ao questionário de Acompanhamento da DPOC”.</li> </ol>

Tabela 12 - Caso de uso "Vigilância 24 horas" (novo)

<b>Caso de Uso</b>	<b>Vigilância 24 horas</b>
Descrição	Permite ao cuidador/médico receber um alerta, caso um paciente com DPOC tenha obtido uma pontuação inferior a 2 no questionário QCD. Permite ao paciente receber uma notificação, caso tenha obtido uma pontuação inferior a 2 no questionário QCD.
Atores	Paciente e cuidador/médico
Pré-condição	Paciente e cuidador/médico estarem registados na plataforma do SmartAL e associados entre si. Paciente despoletar o Tabela 10 - Caso de uso "Notificação Medições vs. Questionário QCD" (novo)
Cenários principais de sucesso	<ol style="list-style-type: none"><li>1. O paciente faz login na plataforma SmartAL.</li><li>2. O paciente acede à aba "Questionários" e abre o Questionário QCD disponível.</li><li>3. O paciente responde às perguntas do questionário de 'Sim' ou 'Não'</li><li>4. O paciente submete as respostas do questionário.</li><li>5. O paciente obtém uma pontuação inferior a 2 no questionário.</li><li>6. A aplicação gera um alerta para o cuidador/médico com a mensagem "O utente (nome) irá ficar 24 horas em vigilância".</li><li>7. A aplicação gera uma notificação para o paciente com a mensagem "Irá ficar 24 horas em vigilância".</li></ol>

Tabela 13 - Caso de uso "Alerta 2 – Acompanhamento da DPOC" (novo)

<b>Caso de Uso</b>	<b>Acompanhamento da DPOC</b>
Descrição	Permite ao cuidador/médico receber um alerta, caso um paciente com DPOC tenha obtido uma pontuação negativa na parte do CAT no questionário de Acompanhamento da DPOC. Permite ao cuidador/médico receber um alerta, caso um paciente com DPOC tenha obtido uma pontuação negativa na parte do TAT no questionário de Acompanhamento da DPOC. Permite ao paciente receber uma notificação, independentemente se obteve uma pontuação positiva ou negativa na parte do TAT no questionário de Acompanhamento da DPOC.
Atores	Paciente e cuidador/médico
Pré-condição	Paciente e cuidador/médico estarem registados na plataforma do SmartAL e associados entre si. Paciente despoletar o Tabela 10 - Caso de uso "Notificação Medições vs. Questionário QCD" (novo) Paciente despoletar o  Tabela 11 - Caso de uso "Alerta 1 – Resultado QCD" (novo)
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. O paciente faz login na plataforma SmartAL.</li> <li>2. O paciente acede à aba “Questionários” e abre o Questionário de Acompanhamento da DPOC disponível.</li> <li>3. O paciente responde às perguntas do questionário que tem vários subgrupos de questionários distintos disponíveis (CAT, TAT, Dispneia e características da expetoração).</li> <li>4. O paciente submete as respostas do questionário.</li> <li>5. O paciente obtém uma pontuação no questionário CAT. <ol style="list-style-type: none"> <li>5.1. O paciente obtém uma pontuação negativa no questionário CAT. <ol style="list-style-type: none"> <li>5.1.1. A aplicação gera um alerta para o cuidador/médico com a mensagem “O utente (nome) obteve uma pontuação negativa no questionário CAT (Alerta (respetiva cor))”.</li> </ol> </li> </ol> </li> <li>6. O paciente obtém uma pontuação no questionário TAT. <ol style="list-style-type: none"> <li>6.1. O paciente obtém uma pontuação positiva no questionário TAT <ol style="list-style-type: none"> <li>6.1.1. A aplicação gera uma notificação para o paciente com a mensagem “Boa adesão à medicação. Continue a tomar a sua medicação como indicado”.</li> </ol> </li> <li>6.2. O paciente obtém uma pontuação negativa no questionário TAT. <ol style="list-style-type: none"> <li>6.2.1. A aplicação gera um alerta para o cuidador/médico com a mensagem “O utente (nome) obteve uma pontuação negativa no questionário TAT (Alerta (respetiva cor))”.</li> <li>6.2.2. A aplicação gera uma notificação para o paciente com a mensagem “Baixa adesão à medicação. Tome a sua medicação como indicado”.</li> </ol> </li> </ol> </li> </ol>

Tabela 14 - Caso de uso "Alerta 3 - Estratificação" (novo)

Caso de Uso	Alerta 3 – Estratificação
Descrição	<p>Avaliação automaticamente efetuada após a submissão do questionário de Acompanhamento da DPOC</p> <p>Permite ao cuidador/médico receber um alerta, caso um paciente com DPOC tenha obtido uma pontuação negativa na estratificação.</p> <p>Permite ao paciente receber uma notificação, independentemente se obteve uma pontuação positiva ou negativa na estratificação.</p>
Atores	Paciente e cuidador/médico
Pré-condição	<p>Paciente e cuidador/médico estarem registados na plataforma do SmartAL e associados entre si.</p> <p>Paciente despoletar o Tabela 10 - Caso de uso "Notificação Medições vs. Questionário QCD" (novo)</p> <p>Paciente despoletar o</p> <p>Tabela 11 - Caso de uso "Alerta 1 – Resultado QCD" (novo)</p> <p>Paciente despoletar o Tabela 13 - Caso de uso "Alerta 2 – Acompanhamento da DPOC" (novo)</p>
Cenários principais de sucesso	<ol style="list-style-type: none"> <li>1. O paciente faz login na plataforma SmartAL.</li> <li>2. O paciente obtém uma pontuação na estratificação.             <ol style="list-style-type: none"> <li>2.1. O paciente obtém uma pontuação positiva na estratificação.                 <ol style="list-style-type: none"> <li>2.1.2. A aplicação gera uma notificação para o paciente com a mensagem “Boa. Continue”.</li> </ol> </li> <li>2.2. O paciente obtém uma pontuação negativa com alerta laranja na estratificação.                 <ol style="list-style-type: none"> <li>2.2.1. A aplicação gera um alerta para o cuidador/médico com a mensagem “O utente (nome) obteve uma pontuação negativa na estratificação DPOC (Alerta Laranja)”.</li> <li>2.2.2. A aplicação gera uma notificação para o paciente com a mensagem “Será contactado por videochamada”.</li> </ol> </li> <li>2.3. O paciente obtém uma pontuação negativa com alerta vermelho na estratificação.                 <ol style="list-style-type: none"> <li>2.3.1. A aplicação gera um alerta para o cuidador/médico com a mensagem “O utente (nome) obteve uma pontuação negativa na estratificação DPOC (Alerta Vermelho)”.</li> <li>2.3.2. A aplicação gera uma notificação para o paciente com a mensagem “Contactar 112, Serviço de Urgência”.</li> </ol> </li> </ol> </li> </ol>

#### 4.2.3 Desafio

O desafio é implementar e integrar um novo sistema de alertas na solução de telemonitorização SmartAL que tenha em conta informação proveniente de medidas de saúde e de questionários preenchidos por utentes que sofrem da DPOC. Esta solução permitirá aos cuidadores automatizar certos processos de alerta com base na correlação de informação, que de outra forma são feitos manualmente à posteriori quando avaliam cada doente. Para além disso, acrescenta-se o desafio pessoal que consiste em implementar e integrar esta

nova lógica de serviço no SmartAL, utilizando a linguagem de programação Java.

#### 4.2.4 Arquitetura do Fluxo

O fluxograma que reflete a lógica a implementar no novo sistema de alertas encontra-se representado na Figura 24.

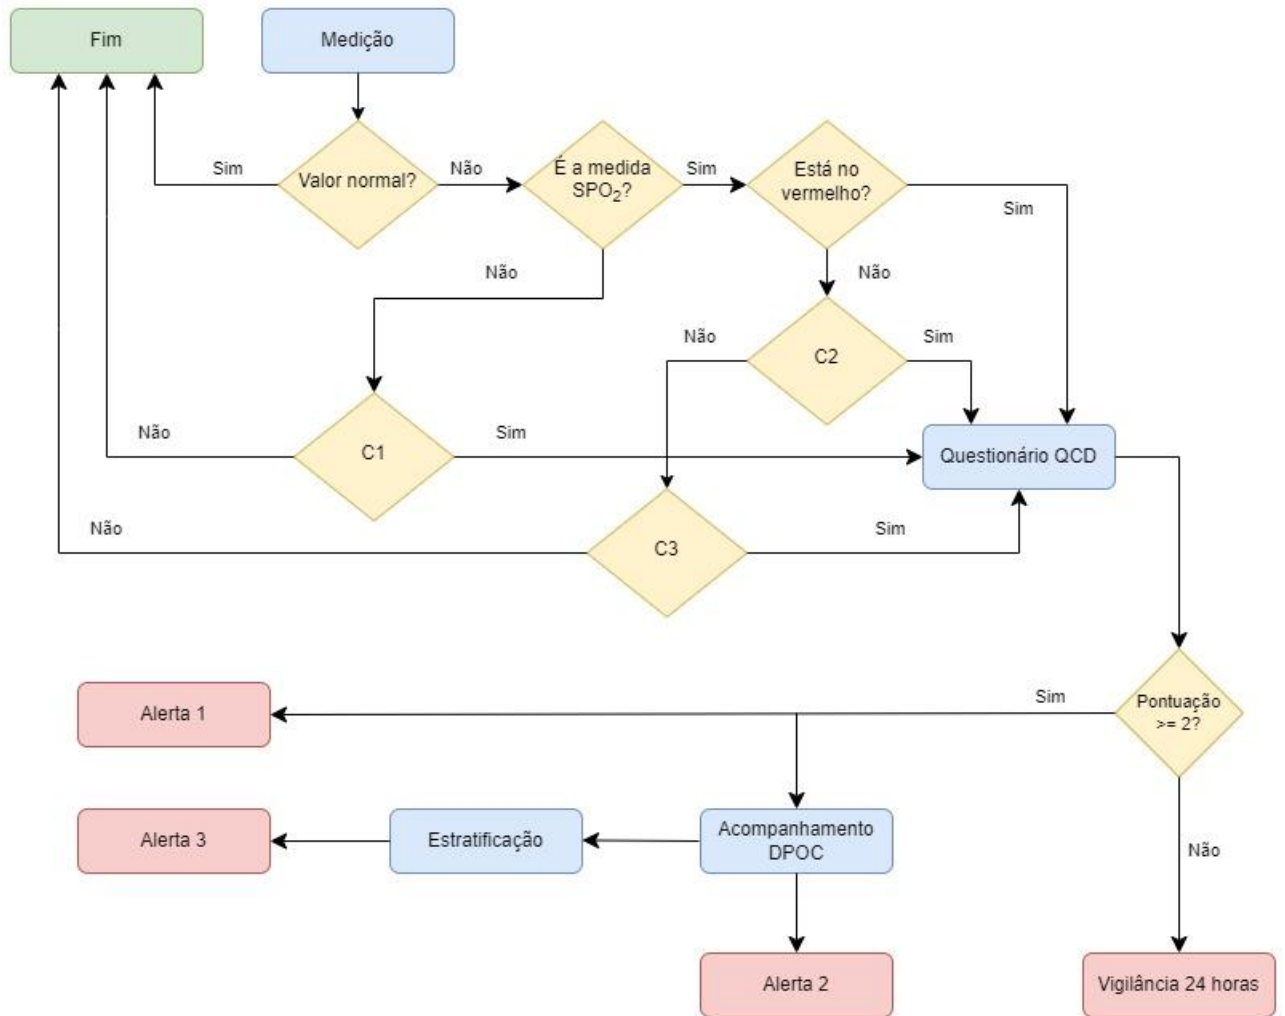


Figura 24 - Fluxograma da solução implementada

**C1:** Verifica se a medição feita é temperatura, frequência cardíaca, pressão arterial ou glicose. Se for, verifica se existem duas medições consecutivas dessa medida fora do normal (incluindo o valor da medição atual), ou se para além da medição feita houve outra medida com um valor fora do normal. Por exemplo: Se a medição for temperatura vai verificar se o último valor registado de temperatura está fora do normal ou se as restantes medidas (frequência cardíaca, pressão arterial, glicose ou saturação do oxigénio) têm um valor recente fora do normal.

**C2:** Verifica se a medida da saturação do oxigénio tem dois valores consecutivos fora do normal (incluindo o valor da medição atual).

**C3:** Verifica se alguma das medidas (temperatura, frequência cardíaca, pressão arterial ou glicose) têm um valor recente fora do normal.

**Vigilância 24 horas:** Envia um alerta ao cuidador/médico e uma notificação ao paciente a informar que o mesmo ficará sobre vigilância 24 horas.

**Alerta 1:** Na resposta ao pedido de submissão do questionário QCD, associa o questionário de Acompanhamento da DPOC ao utente e apresenta uma notificação com a mensagem “Por favor responda ao questionário de Acompanhamento da DPOC”. Para além disso, envia um alerta para o cuidador/médico com a mensagem “O utente (nome do utente) obteve uma pontuação igual ou superior a 2 no QCD. Precisa agora de responder ao questionário de Acompanhamento da DPOC”.

**Alerta 2:** Na resposta ao pedido de submissão do questionário de Acompanhamento da DPOC apresenta uma notificação ao utente a informar se a sua adesão à medicação está boa ou baixa. Para além disso, caso o utente tenha obtido pontuações negativas no questionário CAT ou TAT (incluídos no questionário de Acompanhamento da DPOC) envia um ou dois alertas com a respetiva cor do alerta para o cuidador/médico.

**Alerta 3:** No fim de serem realizados os cálculos automatizados da estratificação, caso a pontuação seja negativa envia um alerta com a respetiva cor/severidade ao cuidador. Para além disso, envia uma notificação ao utente com a informação do que deve fazer.

#### 4.2.5 Fontes de Dados

As fontes de dados utilizadas neste fluxo foram: os questionários de avaliação de sintomas para doentes com DPOC e uma tabela de condições para a fase de estratificação. Os questionários considerados são: o Questionário de Confirmação de Agudização (QCD) e o Questionário de Acompanhamento da DPOC, que é constituído pelo *COPD Assessment Test* (CAT), o Teste de Adesão Terapêutica (TAT), uma questão sobre Dispneia e uma questão sobre as características da expetoração. Estes questionários foram especificados em Excel onde se definiram as perguntas e as pontuações. Os respetivos questionários estão representados nas figuras seguintes (Figura 25, Figura 26, Figura 27 e Figura 28) e as condições de estratificação na Tabela 15 - Tabela de condições da fase de estratificação.

Questionário de Confirmação de Agudização	Sim	Não
1. Relativamente a ontem sente-se pior?		
2. Aumentou a quantidade de expetoração?		
3. A expetoração está mais escura?		
4. Sente-se mais cansado do que o habitual?		
5. Tem febre ou sensação de febre?		

Figura 25 - Questionário de Confirmação de Agudização (QCD)

<b>COPD Assessment Test</b>	<b>0 a 5</b>
1. Nunca tenho tosse   Tenho tosse o tempo todo	
2. Não tenho secreções no peito   O meu peito está cheio de secreções	
3. Não sinto nenhuma pressão no peito   Sinto uma grande pressão no peito	
4. Não sinto falta de ar quando subo uma ladeira ou um andar de escada   Sinto uma grande falta de ar quando subo uma ladeira ou um andar de escada	
5. Não sinto nenhuma limitação nas minhas atividades em casa   Sinto-me muito limitado nas minhas atividades em casa	
6. Sinto-me confiante para sair de casa, apesar da minha doença pulmonar   Não me sinto nada confiante para sair de casa, por causa da minha doença pulmonar	
7. Durmo profundamente   Não durmo profundamente devido à minha doença pulmonar	
8. Tenho muita energia (disposição)   Não tenho nenhuma energia (disposição)	

Figura 26 - COPD Assessment Test (CAT)

<b>Teste de Adesão Terapêutica</b>	<b>Sim</b>	<b>Não</b>
1. Na última semana esqueceu-se de tomar a medicação?		
2. Toma os medicamentos à hora indicada?		
3. Quando se sente melhor, deixa de tomar os medicamentos?		
4. Quando se sente pior, deixa de tomar os medicamentos?		

Figura 27 - Teste de Adesão Terapêutica (TAT)

<b>Dispneia (mMRC)</b>	<b>X</b>
Assinale qual a afirmação que melhor descreve a sua sensação de falta de ar:	
1. Só sinto falta de ar em caso de exercício físico.	
2. Fico com falta de ar ao apressar-me ou ao percorrer um piso ligeiramente inclinado.	
3. Eu ando mais devagar que as restantes pessoas devido à falta de ar, ou tenho de parar para respirar quando ando no meu passo normal.	
4. Eu paro para respirar depois de andar 100 metros ou passado alguns minutos.	
5. Estou sem fôlego para sair de casa.	
<b>Características da expetoração</b>	<b>X</b>
De que cor é a sua expetoração?	
1. Branca	
2. Amarelada	
3. Esverdeada	
4. Acastanhada	

Figura 28 - Questão sobre a Dispneia (mMRC) e expetoração

Tabela 15 - Tabela de condições da fase de estratificação

Parâmetros	0 pontos	1 ponto	2 pontos	3 pontos
SpO <sub>2</sub>	↓ 2%	↓ 3%-5%	↓ 6%-7%	↓ ≥ 8%
PAs	vt alerta verde menos ±15%	±15% do vt verde	vt alerta laranja	vt alerta vermelho
FC	46-100 bpm	101-110 bpm	111-115 bpm	>115bpm ou ≤45 bpm
Temperatura	≤ 37,0°C	37,1 – 37,4°C	37,5 – 37,9°C	≥ 38,0°C
Dispneia (mMRC)	Grau 0	Grau 1-2	Grau 3	Grau 4
CAT	↑ ≤ 2 pontos	↑ 3 pontos	↑ 4 pontos	↑ ≥ 5 pontos
Características da Expetoração	Branca	Amarelada	Esverdeada	Acastanhada

Legendas: SpO<sub>2</sub> – saturação periférica do oxigénio; PAs – pressão arterial sistólica; FC – frequência cardíaca; CAT – DPOC Assessment Test; vt – valor do threshold; bpm – batidas por minuto.

A fase de estratificação corresponde à avaliação geral do estado do paciente com base em algumas medidas de saúde (SpO<sub>2</sub>, pressão arterial sistólica, frequência cardíaca e temperatura) e algumas respostas ao questionário de Acompanhamento da DPOC (pontuação do CAT, pergunta da Dispneia e pergunta das características da expetoração). Esta fase é a última do fluxo e pode ter três saídas distintas sendo elas:

- Ligeira/Moderada ≤ 7 pontos (Boa);
- Grave 8 – 12 pontos (Contacto por videochamada);
- Muito Grave ≥ 13 pontos (Serviço de urgência, 112).

De forma a exemplificar os procedimentos e cálculos que são realizados na Tabela 15 para cada parâmetro, será considerado um paciente fictício designado por paciente 1:

- SpO<sub>2</sub>: O paciente 1 registou na sua última medição de SpO<sub>2</sub> 89% e o valor do seu *threshold* é 94%, temos uma descida de 5% entre os dois valores referidos. Observando a Tabela 15, uma descida de 5% está no aviso amarelo, e por isso, é adicionado 1 ponto à variável que armazena a pontuação final da estratificação.
- PAs: Os valores dentro do normal (verde) do *threshold* do paciente 1 para a PAs são 110 e 130. O aviso amarelo representa os valores entre 15% do primeiro e do segundo limite. O aviso verde representa o restante. Por exemplo, caso a última medição de PAs registada pelo paciente 1 seja 113 bpm está no aviso amarelo. Caso seja 114 bpm já está no aviso verde. Os restantes avisos estão entre os valores dos *thresholds* normais para o laranja e vermelho definidos no SmartAL para cada paciente.
- FC e temperatura: O paciente 1 registou na sua última medição de FC e de temperatura, 115 bpm e 37.2°C, respetivamente, observando a tabela

acima vão ser adicionados 2 e 1 pontos, respetivamente, à variável que armazena a pontuação final da estratificação.

- Dispnéia e características da expetoração: Aqui, é analisada a resposta dada pelo paciente 1 no questionário de Acompanhamento da DPOC à pergunta de dispneia e à pergunta da expetoração. Supondo que o paciente 1 selecionou na pergunta da dispneia a primeira opção esta corresponde ao aviso verde, e por isso, não são adicionados pontos à variável que armazena a pontuação final da estratificação. Para as características da expetoração a lógica é idêntica.
- CAT: O paciente 1 obteve no penúltimo questionário de Acompanhamento da DPOC uma pontuação de 15 pontos no CAT e no último 20 pontos, existiu uma subida de 5 pontos entre as últimas duas pontuações. Observando a tabela acima, esta subida representa um aviso vermelho, e por isso, são adicionados 3 pontos à variável que armazena a pontuação final da estratificação.

#### 4.2.6 Descrição da Implementação

Na fase inicial de implementação desta solução foi necessário perceber o funcionamento geral do SmartAL, e explorar o ambiente em que está inserido.

Inicialmente foi criada uma *flag* para ser possível ativar/desativar o fluxo, uma vez que apenas interessa ter a solução ativa para utentes que sofrem de DPOC. Todo o funcionamento deste fluxo está dependente de certas medições de saúde (saturação do oxigénio, temperatura, frequência cardíaca, pressão arterial e glicose) e dos seus respetivos valores.

O fluxo desenvolvido, representado na Figura 24, foi dividido em duas classes distintas. A primeira classe contém a função com o fluxo das medidas de saúde que termina na associação do questionário QCD e a segunda classe contém a função com o fluxo dos questionários que inicia após a associação do questionário QCD. Na Figura 29 estão representadas as declarações de cada uma das funções.

```
Class MeasurementsFlow:  
public static void flow (Entity patientEntity, String dataTypeGroupCode, int state, Map<String,  
HealthThreshold> mhrThresholdsCache)  
  
Class QuizFlow:  
public static void flow (SLQuizSession session, Entity patientEntity)
```

Figura 29 - Declaração das funções do fluxo de medidas e dos questionários

A função do fluxo das **medidas** é chamada na classe que testa os alertas e recebe como parâmetros, a entidade do paciente, a medida que foi avaliada, o estado da medida (alerta vermelho ou laranja) e a cache dos *thresholds* do MHR.

A função do fluxo dos **questionários** é chamada na classe de gestão dos quizzes onde é tratada a entrega dos mesmos; recebe como parâmetros a sessão de um questionário e a entidade do paciente.

Para invocar a função do fluxo das **medidas**, o utente tem de fazer uma medição e esta estar fora dos valores normais. Posteriormente, no início desta função, é verificada se a *flag* do fluxo da DPOC está ativa e se a medida de saúde avaliada está presente na enumeração dos tipos de medidas da DPOC. Caso isto se verifique, então começam aí a ser verificadas as restantes condições do fluxo.

Em relação à medida atual avaliada é possível, através do parâmetro *state* da função do fluxo de medidas, saber se está num alerta laranja ou vermelho. No entanto, quando é necessário verificar o valor dos alertas das medições que não a atual, ou seja, a medição anterior ou das outras medidas (temperatura, etc.) temos de recorrer à função representada na Figura 30.

Essa função recebe como parâmetros o tipo de medida, o id da entidade, o número de resultados (1 caso seja pretendida a última medida inserida, 2 caso seja pretendida a penúltima medida inserida) e a cache dos *thresholds*. Retorna o valor do alerta da medida facultada (0 para verde, 1 para laranja e 2 para vermelho) que é calculado tendo em conta os *thresholds* do utente e o valor da medição.

Exemplificando: caso tenha sido feita uma medição de SpO<sub>2</sub> que gerou um alerta laranja, seguindo o fluxo é necessário verificar se a penúltima medição de SpO<sub>2</sub> está dentro ou fora do normal. Para isso, é utilizada a primeira parte desta função com o número de resultados igual a 2. Caso, o valor verificado esteja dentro do normal, seguindo o fluxo, vamos verificar se as restantes medidas também têm um valor dentro do normal. Para isso, é utilizada a segunda parte desta função com o número de resultados igual a 1. Assim, com o novo estado de alerta calculado por esta função é possível fazer todas as avaliações necessárias para as diferentes medidas no fluxo.

```

// Calcular o estado da medida inserida
public static int calculateDataTypeGroupState (String dataTypeGroupCode, int idEntity, int nResults,
    Map<String, HealthThreshold> mhrThresholdsCache)
{
    int state = 0;
    HealthMeasurement[] myMeasurement = MedicalHealthRecordVitals.getVitals("pt", idEntity,
    dataTypeGroupCode, null, null, nResults, 1, false);
    String cacheKey = idEntity + "_" + dataTypeGroupCode;
    HealthThreshold mhrThresholds = mhrThresholdsCache.get(mhrThresholdsCache.get(cacheKey));

    if (mhrThresholds != null) {
        if (nResults == 2) { ← Penúltima medição
            if (myMeasurement.length > 1) {
                for (pt.ptin.smart.living.bo.results.measurement.MeasurementData measurementData :
                myMeasurement[1].dataList) {
                    if (!measurementData.getValue().isEmpty()) {
                        double value = Double.parseDouble(measurementData.getValue());
                        int tempState = MeasurementHome.calculateThresholdLevel(value, idEntity,
                        mhrThresholds, measurementData.getDataType());
                        if (tempState > state) {
                            state = tempState; }
                        ...
                    }
                }
            }
            if (nResults == 1) { ← Última medição
                for (pt.ptin.smart.living.bo.results.measurement.MeasurementData measurementData :
                myMeasurement[0].dataList) {
                    if (!measurementData.getValue().isEmpty()) {
                        double value = Double.parseDouble(measurementData.getValue());
                        int tempState = MeasurementHome.calculateThresholdLevel(value, idEntity,
                        mhrThresholds, measurementData.getDataType());
                        if (tempState > state) {
                            state = tempState; }
                        ...
                    }
                }
            }
        }
    }
    return state;
}

```

Figura 30 - Função *calculateDataTypeGroupState*

Para realizar a associação do questionário QCD ao utente foi desenvolvida a função apresentada na Figura 31. Basicamente, esta função permite através do id da entidade criar uma sessão do questionário QCD para a entidade facultada.

```
// Associar QCD
public static void AssociateQCDQuiz (int idEntity)
{
    int dpocQCDQuizID =
Integer.parseInt(ConfigFactory.getConfig().getParam(Const.CONTEXT_DPOC_QCD_QUIZ_ID);

    String[] quiz = new String[1];
    String[] entity = new String[1];

    quiz[0] = String.valueOf(dpocQCDQuizID);
    entity[0] = String.valueOf(idEntity);

    try
    {
        SLQuizCreateSessionsRequest createSessionsRequest =
new SLQuizCreateSessionsRequest(null, null, quiz, entity);
        SLQuizService.createSessions(createSessionsRequest, null);
    } catch (Exception e) {
        SmartLoggerManager.Error.getLogger().log(e.getMessage(), e);
    }
}
```

Figura 31 - Função *AssociateQCDQuiz*

Para além disso, sempre que é associado um questionário ao utente, é também enviada uma notificação para o mesmo a informar que tem de responder. Essa notificação é enviada através da função apresentada na Figura 32. Esta função recebe como parâmetros o id da entidade e uma mensagem chave (correspondente à mensagem indicada para a ocasião previamente declarada num ficheiro). Tanto os utentes como os cuidadores podem receber notificações.

```
// Enviar notificação
public static void sendDPOCNotifications (Entity patientEntity, String messageKey) throws
IOException
{
    ResourceBundle languageProps =
LanguageUtils.getLanguageFile(patientEntity.getDefaultLanguage());

    //Recebe a mensagem para o tipo de notificação
    String message = languageProps.getString(messageKey);

    //Envia a notificação para o webservice
    Notifications.sendNotificationBack(patientEntity.getIdEntity(), patientEntity.getIdEntity(), message,
new NotificationtypeHome().getNotificationType(Const.Agenda.NotificationType.ID_INFO), null, null,
true, null, null, null);
}
```

Figura 32 - Função *sendDPOCNotifications*

Quando for associado o questionário QCD ao utente e enviada a respetiva notificação, entramos na segunda parte do fluxo. Aqui, para invocar a função do fluxo dos questionários é necessário ter já a resposta do utente ao questionário que lhe foi atribuído anteriormente, neste caso, o QCD. Assim que responder, entra no fluxo que verifica se o id do questionário da sessão é igual

ao id do questionário QCD e se a pontuação obtida é igual ou superior a 2.0. Caso esta condição se verifique é associado o questionário de Acompanhamento da DPOC, caso contrário envia uma notificação ao utente e um alerta ao cuidador com a mensagem indicada para a ocasião.

A função responsável pelo envio dos alertas aos cuidadores utiliza a mesma lógica que a função de envio de notificações, mas como existem diferentes tipos de alerta (1, caso laranja e 2, caso vermelho) esta precisa de fazer algumas verificações relacionadas com o tipo de alerta recebido e a mensagem a enviar para o respetivo tipo de alerta (estas mensagens estão pré-definidas num ficheiro). Recebe como parâmetros o id da entidade, uma mensagem chave e um nível de alerta (1, caso laranja e 2, caso vermelho). Apenas os cuidadores podem receber estes alertas.

Após a associação do questionário de Acompanhamento da DPOC, o fluxo volta a ficar dependente da resposta do utente ao novo questionário. Assim que receber a resposta, volta a ser invocada a função do fluxo dos questionários que segue as instruções para o caso em que o id do questionário da sessão é equivalente ao id do questionário de Acompanhamento da DPOC. Neste caso, são guardadas em diferentes variáveis as pontuações necessárias para serem realizadas as avaliações (pontuação do CAT, TAT, dispneia e expetoração). São também enviadas as respetivas notificações para o utente, e alertas para o cuidador, consoante os resultados.

A última fase é a de estratificação. Para avaliar as medidas que constam na Tabela 15, é necessário ir buscar o último valor registado para a respetiva medida. Para isso, foi desenvolvida a função apresentada na Figura 33. Esta função permite, através do id da entidade, o tipo da medida e o número de resultados retornar o último valor registado para o tipo de medida facultado (accedendo ao registo médico dos sinais vitais).

```
// Receber o último valor registado
public static double getLastValue (int idEntity, String dataTypeGroupCode, int nResults)
{
    double value = 0.0;
    try
    {
        Date fromDate = new Date(0);
        Date toDate = Date.from(Instant.from(LocalDate.now()).atTime(LocalTime.MAX).atZone
(ZoneId.systemDefault()).toInstant());
        HealthMeasurement[] myMeasurement = MedicalHealthRecordVitals.getVitals("pt",
idEntity, dataTypeGroupCode, fromDate, toDate, nResults, 1, false);
        for (pt.ptin.smart.living.bo.results.measurement.MeasurementData measurementData :
myMeasurement[0].dataList)
        {
            if (!measurementData.getValue().isEmpty())
            {
                value = Double.parseDouble(measurementData.getValue());
            }
            break;
        }
    } catch (Exception e) {
        SmartLoggerManager.Debug.getLogger().log(e.getMessage(), e);
    }
    return value;
}
}
```

Figura 33 - Função *getLastValue*

Para além disso, na saturação do oxigénio e na pressão arterial sistólica é necessário saber os valores dos *thresholds* associados ao utente. Como tal, foi desenvolvida a função apresentada na Figura 34. Esta função permite, através do id da entidade e o tipo da medida retornar um *array* de *double* com os valores dos *thresholds* do utente para um determinado tipo de medida.

```
// Receber array de valores dos thresholds
public static double[] getThresholdsValues (int idEntity, String dataTypeGroupCode)
{
    double[] tValues = new double[4];
    try
    {
        HealthThreshold t = MedicalHealthRecordVitals.getThreshold("default", idEntity,
dataTypeGroupCode);
        for (Double[] array : t.getThresholds().values())
        {
            for (int i=0; i<array.length; i++)
            {
                tValues[i] = array[i].doubleValue();
            }
        }
    } catch (Exception e) {
        SmartLoggerManager.Debug.getLogger().log(e.getMessage(), e);
    }
    return tValues;
}
}
```

Figura 34 - Função *getThresholdsValues*

Assim, fica concluída a implementação do fluxo da DPOC especificado.

## 5 MÓDULO 2 - DIAGNÓSTICO DE DOENÇAS RESPIRATÓRIAS

O diagnóstico preciso e atempado de doenças desempenha um papel fundamental na área da saúde e no trabalho dos profissionais, influenciando diretamente os resultados clínicos e a qualidade de vida dos pacientes.

Neste âmbito e dado o seu constante aumento, o diagnóstico de doenças respiratórias tem-se tornado uma necessidade no panorama médico atual. A aplicação de técnicas avançadas de *Machine Learning* emerge como uma abordagem promissora para aprimorar o diagnóstico destas condições, por vezes complexas. Em particular, as redes neuronais surgem com a capacidade de superar limitações de interpretação humana e com potencial para identificar padrões distintivos, permitindo tratamentos mais eficazes e intervenções precoces.

Assim, inspirado no estado da arte e utilizando a base de dados pública de sons respiratórios da ICBHI [48], foram implementadas várias abordagens de *Deep Learning* para o diagnóstico de doenças respiratórias.

### 5.1 Tecnologias

Nesta subsecção, são identificadas e descritas as tecnologias utilizadas na implementação do módulo 2 designado Diagnóstico de Doenças Respiratórias.

#### 5.1.1 Python versão 3.10.10

Python é uma linguagem de programação de alto nível desenvolvida pela organização *Python Software Foundation* na década de 90. Esta linguagem foi utilizada ao longo de todo o módulo para o desenvolvimento dos modelos de *Deep Learning*.

As principais bibliotecas de Python utilizadas foram:

- Numpy: biblioteca para computação científica (funções matemáticas, *arrays*, entre outros).
- Pandas: biblioteca que fornece estruturas de dados para trabalhar com dados relacionais ou rotulados.
- Matplotlib: biblioteca para criar visualizações estáticas, animadas e interativas.
- Tensorflow: biblioteca para criar modelos de *Deep Learning*, diretamente ou usando bibliotecas que simplificam o processo.
- Keras: API de alto nível para *Deep Learning*, desenvolvida pela Google para implementar redes neuronais.

- Scikit-learn: biblioteca para realização de *Machine Learning*.
- Librosa: biblioteca para análise e processamento de música e áudio.

### 5.1.2 Projeto Jupyter e Jupyter Notebook

O Projeto Jupyter dá suporte ao desenvolvimento de software *open-source*, *standards* abertos e serviços para computação interativa em várias linguagens de programação (e.g. Julia, R, Python). O Jupyter Notebook é um ambiente computacional *web* para a criação de documentos na plataforma Jupyter. Este foi o ambiente utilizado para a implementação dos modelos.

### 5.1.3 Kaggle

O Kaggle [67] é a maior plataforma online de *Data Science* e *Machine Learning*. Permite que utilizadores de todo o mundo encontrem e publiquem dados, explorem e criem modelos em ambiente *web*, trabalhem com outros cientistas e engenheiros e participem em competições para resolver problemas de análise de dados. Esta plataforma foi utilizada neste módulo para executar os modelos implementados, uma vez que disponibiliza computação gratuita em GPU a membros inscritos e verificados na plataforma.

## 5.2 Implementação

### 5.2.1 Conjunto de dados *Respiratory Sound Database (RSD)*

Nos trabalhos de Rocha et al. [68]- [69], os autores explicam como criaram a base de dados *Respiratory Sound Database (RSD)*, que serve para resolver problemas relacionados com dados de sons respiratórios.

O RSD é um conjunto de dados público [48] criado ao longo de 7 anos por equipas independentes de dois países distintos, Portugal e Grécia. A maior parte da base de dados consiste em amostras de áudio gravadas pela equipa de investigação da Escola Superior de Saúde da Universidade de Aveiro (ESSUA) no Laboratório de Investigação e Reabilitação Respiratória (Lab3R) e no Hospital Infante D. Pedro, Aveiro, Portugal. A segunda equipa de investigação, da Universidade de Aristóteles de Salónica (AUTH) e da Universidade de Coimbra (UC), adquiriu sons respiratórios no Hospital Geral Papanikolaou, Salónica e no Hospital Geral de Imathia, Naousa, Grécia.

A base de dados contém 5 horas e meia de sons respiratórios de 126 pacientes representando um total de 920 sons anotados. Estes sons foram recolhidos de sete localizações do tórax (traqueia, esquerda e direita anterior, posterior e lateral) e de pacientes de todas as idades (crianças, adultos e idosos). As condições respiratórias variam entre Infeção do Trato Respiratório Superior (ITRS) e Infeção do Trato Respiratório Inferior (ITRI), Doenças Pulmonar

Obstrutiva Crónica (DPOC), asma, pneumonia, bronquiectasia e bronquiolite. Também existem pacientes sem qualquer condição respiratória.

Os sons foram gravados com um estetoscópio digital (Welch Allyn Master Elite Plus Stethoscope Model 5079-400), sete estetoscópios com microfone no tubo principal (3M Littman Classic II SE) e sete microfones de eletreto a ar (AKG C417L Microphone (AKGC417L)) localizados em cápsulas feitas de Teflon. A duração destes sons varia entre 10 e 90 segundos, contendo a grande maioria dos áudios 20 segundos. A anotação dos sons quanto à presença/ausência de ruídos adventícios e identificação das fases respiratórias foi concretizada por três especialistas.

### **5.2.2 Descrição da Implementação**

Tendo em conta o conjunto de dados facultado pela ICBHI e o conhecimento adquirido na exploração do mesmo e no estudo do estado da arte que operou sobre o mesmo *dataset*, decidiu-se responder a três problemas de classificação sendo eles:

- Classificação binária: SN - Saudável / Não Saudável (saudável como “*Healthy*” e não saudável como “*Unhealthy*”);
- Classificação multi classe: SCN - Saudável / Doente Crónico / Doente Não Crónico (saudável como “*Healthy*”, doente crónico como “*Chronic*” e doente não crónico como “*Non Chronic*”);
- Classificação multi classe: DR - Classificação de Doenças Respiratórias (asma como “*Asthma*”, bronquiectasia como “*Bronchiectasis*”, bronquiolite como “*Bronchiolitis*”, DPOC como “*COPD*”, saudável como “*Healthy*”, pneumonia como “*Pneumonia*”, infeção do trato respiratório superior como “*URTP*”, infeção do trato respiratório inferior como “*LRTP*”).

No balanceamento do conjunto de dados, presente na Figura 35, é possível observar um desequilíbrio evidente. Existe uma clara superioridade no número de amostras de áudio para pacientes com DPOC, em comparação com pacientes com outras doenças ou pacientes saudáveis. Para colmatar este problema, a primeira abordagem foi tentar adicionar amostras de áudio que representassem as classes minoritárias, mais concretamente, asma, bronquiectasia, bronquiolite, saudável, pneumonia, infeção do trato respiratório superior e inferior.




Figura 35 - Balanceamento do conjunto de dados original

Assim, utilizou-se um conjunto de dados público denominado “*A dataset of lung sounds recorded from the chest wall using an electronic stethoscope*” [70] que outros autores já tinham combinado com o *Respiratory Sound Database* para tentar resolver problemas de classificação, como por exemplo no trabalho de L. Fraiwan et al [71]. Este *dataset* é constituído por arquivos de áudio anotados, de sons pulmonares de 112 pacientes (35 saudáveis, 77 não saudáveis). A anotação inclui o tipo de som, o diagnóstico decidido por um especialista (saudável, asma, DPOC, bronquite, insuficiência cardíaca, fibrose pulmonar, pneumonia e derrame pleural) e a localização na parede torácica de onde foi feito o registo. Este conjunto adicional de dados permitiu aumentar o número de amostras de áudio de algumas classes e atuar nos seguintes problemas:

Primeiro problema (SN): foram excluídas as classes “*LRTP*” e “*Asthma*” por apenas conterem 2 e 1 amostras de áudio, respetivamente. As restantes classes, exceto a classe “*Healthy*”, foram combinadas numa só denominada de “*Unhealthy*”, dando origem a um problema de classificação binário. Neste problema, o novo *dataset* permitiu adicionar 105 áudios representando a classe “*Healthy*”.

Segundo problema (SCN): foram excluídas novamente as classes “*LRTP*” e “*Asthma*” pelos mesmos motivos do primeiro problema. Nas restantes classes, a “*Healthy*” manteve-se e a “*COPD*” deu origem à classe “*Chronic*”. Posteriormente, agruparam-se as classes “*Bronchiectasis*”, “*Bronchiolitis*”, “*Pneumonia*” e “*URTP*” originando a classe “*Non Chronic*”. Este problema, ficou assim reduzido a uma classificação multiclasse com 3 classes distintas. Aqui, o novo *dataset* permitiu adicionar 105 áudios representando a classe “*Healthy*” e 15 áudios representando a classe “*Non Chronic*”.

Por fim, no terceiro problema (DR): foi excluída apenas a classe “*LRTP*” por conter 2 amostras de áudio e foram mantidas todas as outras classes (“*Asthma*”, “*Bronchiectasis*”, “*Bronchiolitis*”, “*COPD*”, “*Healthy*”, “*Pneumonia*” e “*URTP*”) originando um problema de classificação multiclasse com 7 classes distintas. Neste problema, o novo *dataset* permitiu adicionar 105 áudios representando a

classe “Healthy”, 15 áudios representando a classe “Pneumonia” e 99 áudios representando a classe “Asthma”.

O balanceamento final dos conjuntos de dados considerados para os diferentes problemas está representado na Figura 36, Figura 37 e Figura 38.

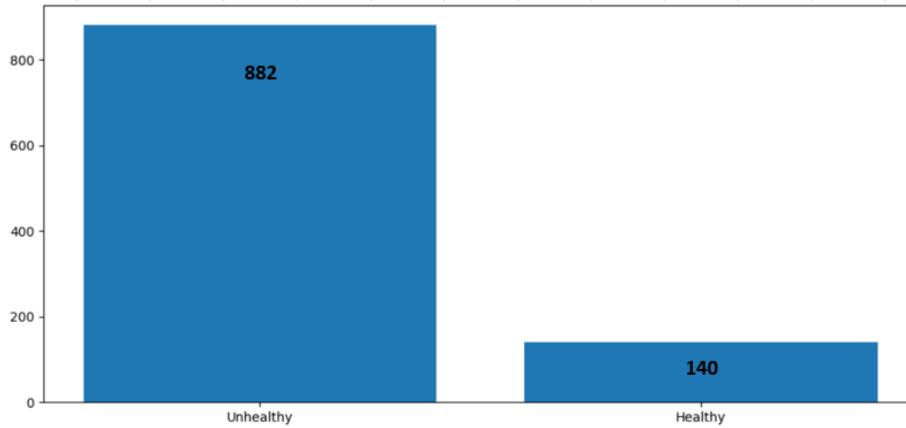


Figura 36 - Balanceamento do problema SN




Figura 37 - Balanceamento do problema SCN

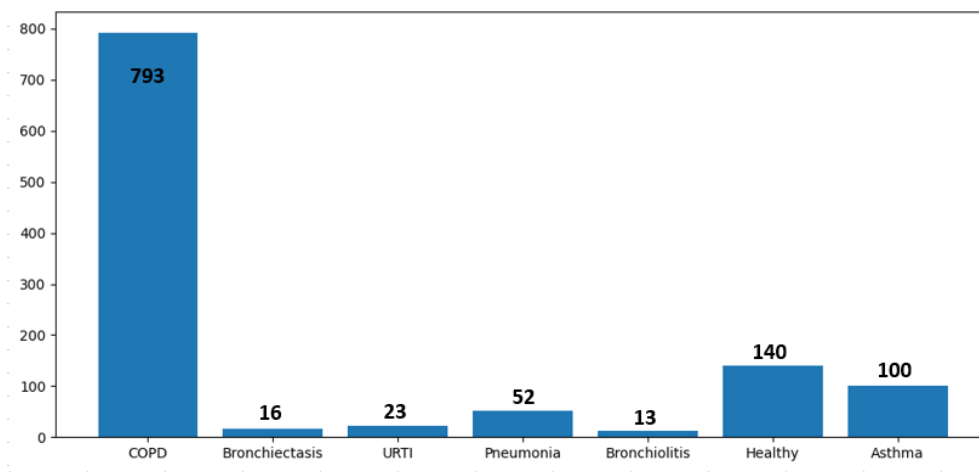


Figura 38 - Balanceamento do problema DR

A adição destes novos sons respiratórios aumentou o número de áudios para algumas das classes minoritárias nos diferentes problemas, contudo, o conjunto de dados final permaneceu significativamente desbalanceado, principalmente para a classe “*Unhealthy*” no problema SN, para a classe “*Chronic*” no problema SCN e para a classe “*COPD*” no problema DR.

Consequentemente, foi necessário encontrar uma nova solução para combater este desequilíbrio. Assim, surgiu a hipótese de implementar técnicas de aumento de dados ou *Data Augmentation*. Diferentes técnicas presentes nos trabalhos relacionados foram testadas, com o intuito de descobrir qual seria a estratégia com melhor desempenho. Experimentar essas técnicas e avaliar o seu impacto no desempenho do modelo é fundamental para determinar quais são mais eficazes para a classificação em questão.

À luz do que foi apresentado no estado da arte, a primeira técnica testada foi o *SMOTE*, uma das mais conhecidas e utilizadas para todo o tipo de problemas por ser particularmente útil em cenários onde as classes estão desproporcionalmente distribuídas (presente nos trabalhos [46] e [50]).

A segunda técnica foi o *Class Weights*, uma das técnicas mais simples e com menor custo computacional por não envolver geração de dados sintéticos, (presente no trabalho [46]).

A terceira técnica foi o *Sound Augmentation*, técnica mais utilizada para o aumento de dados sonoros devido à sua variedade de opções. As estratégias escolhidas foram *Time Stretch*, *Pitch Shift*, *Speed Changing* e *Add Noise* (presentes nos trabalhos [45] e [47]).

Por fim, foi testado o *SpecAugment*, uma estratégia mais recente apresentada por D. S. Park [66] que permite realizar o aumento de dados diretamente nos espectrogramas.

Detalhando, relativamente às estratégias do *Sound Augmentation*, no *Time Stretch* e no *Speed Changing*, foram utilizados valores aleatórios entre 0.8 e 1.2, que correspondem, respetivamente, a um encurtamento e um esticamento máximo de 20% da duração do áudio e, a uma diminuição e um aumento da velocidade de reprodução do áudio máximo de 20%. A principal diferença é que o primeiro não altera a frequência e o segundo altera. No *Pitch Shift*, foram utilizados os valores -1 e -0.5, que correspondem a uma redução da frequência do áudio em um e meio semitom, respetivamente, tornando o áudio ligeiramente mais grave. Para além destes, foram também utilizados os valores 0.5 e 1, que correspondem a um aumento da frequência de áudio em um e meio semitom, respetivamente, tornando o áudio ligeiramente mais agudo. Por fim, no *Add Noise*, foram utilizados os valores 0.002 e 0.005.

As alterações apresentadas criaram a possibilidade de realizar no máximo 10 modificações para cada som. Nas classes com muito poucas instâncias, essas

modificações, foram executadas na totalidade. Nas outras, apenas foi executado o necessário para aproximar do número de instâncias da classe maioritária.

Enfatiza-se ainda, o facto de alguns destes áudios sintéticos terem sido ouvidos por um especialista, com o intuito de perceber se o diagnóstico continuava intacto, o que se confirmou, acrescentando assim valor aos dados aumentados.

Antes da aumentação, o conjunto de dados final foi dividido em dois conjuntos independentes, um de treino (70%) e um de teste (30%), sendo esta divisão estratificada. A estratificação foi utilizada para garantir que a distribuição das classes é mantida em proporções semelhantes em ambos, conjunto de treino e conjunto de teste. Assim, evita-se que uma ou mais classes sejam sub-representadas num dos conjuntos, o que poderia levar a resultados enviesados.

Enfatiza-se que os dados sintéticos apenas foram adicionados no conjunto de treino.

Relativamente à estratégia *Sound Augmentation*, para o **problema SN**, a distribuição dos conjuntos de treino, sem e com DA e do conjunto de teste encontra-se representada na Tabela 16.

Tabela 16 - Distribuição dos conjuntos de treino e teste para o problema SN

Classe	Treino sem DA	Treino com DA	Teste
“Healthy”	98	588	42
“Unhealthy”	617	617	265

Para o **problema SCN**, a distribuição dos conjuntos de treino sem e com DA e do conjunto de teste está representada na Tabela 17.

Tabela 17 - Distribuição dos conjuntos de treino e teste para o problema SCN

Classe	Treino sem DA	Treino com DA	Teste
“Chronic”	554	554	239
“Healthy”	98	588	42
“Non Chronic”	73	584	31

Por fim, para o **problema DR**, a distribuição dos conjuntos de treino sem e com DA e do conjunto de teste está representada na Tabela 18.

Tabela 18 - Distribuição dos conjuntos de treino e teste para o problema DR

Classe	Treino sem DA	Treino com DA	Teste
“Asthma”	70	560	30
“Bronchiectasis”	11	110	5
“Bronchiolitis”	9	90	4
“COPD”	555	555	238
“Healthy”	98	588	42
“Pneumonia”	36	360	16
“URTI”	16	160	7

Assim, como se pode observar nas tabelas acima, a aumentação com *Sound Augmentation* permitiu melhorar o balanceamento no número de amostras em cada classe.

De seguida, utilizou-se a biblioteca *Librosa* para realizar o pré-processamento e a extração de *features* dos áudios. Para isso, foi criada uma função que, para cada áudio, extrai os primeiros 20 segundos com uma taxa de amostragem de 22500Hz (taxa normalmente utilizada para sons de ausculta pulmonar) e as suas *features* para a criação do respetivo espectrograma. Caso o áudio tenha uma duração menor que 20 segundos é aplicado *padding* de “zeros”, sobre o seu espectrograma, para esse áudio ficar com 20 segundos como nos restantes sons e, assim, manter equidade nos dados.

Inicialmente, as *features* de timbre individuais extraídas dos sons foram as seguintes: *MFCC*, *Mel Spectrogram* e *Spectral Contrast*. Estas *features*, já apresentadas no estado da arte, são representações numéricas derivadas de análises espectrais de sinais áudio, amplamente utilizadas em processamento de áudio e reconhecimento da fala. São especialmente úteis para capturar informações relevantes contidas nas características de frequência do sinal áudio.

Após o pré-processamento e a extração de *features* de timbre, cada áudio é convertido num vetor de duas dimensões. A primeira dimensão está relacionada com o número de *features* extraídas por cada técnica de extração. A segunda dimensão está relacionada com o tamanho da sequência. No caso, da *MFCC* são extraídas 20 *features*, logo, cada áudio é representado por um espectrograma de 20 x 862. O valor 862 é uma representação do número de quadros de tempo em que o espectro de frequência é amostrado ao longo da duração do áudio (20 segundos). O tamanho da janela e a taxa de sobreposição são fatores-chave na determinação desse número. Esses valores são definidos automaticamente pela função utilizada no *Librosa*. Resumidamente, esta dimensão ajuda a capturar como as características espectrais do som evoluem ao longo do tempo. O *Mel Spectrogram* e o *Spectral Contrast* extraem 128 e 8 *features*, respetivamente.

Por fim, é adicionada uma terceira dimensão que representa a cor, neste caso igual a 1, que se refere às escalas de cinza, uma abordagem comum para visualizar espectrogramas, uma vez que permite destacar de forma clara as variações na intensidade do espetro de frequência ao longo do tempo. Este processamento é frequentemente utilizado em redes neuronais que lidam com entradas de dados formatados a três dimensões. Primeira, número de *features*, segunda, tamanho da sequência, e terceira, número de canais. Os primeiros testes foram realizados com uma rede neuronal convolucional simples.

A maior parte dos algoritmos de ML não suportam rótulos de classificação não numéricos (e.g., saudável, não saudável), nem lidam bem com valores numéricos cuja importância não está relacionada com o valor em si (e.g., azul = 1, vermelho = 2, mas azul não é mais importante do que vermelho). Então, para converter os rótulos (*labels*), tanto de treino como de teste, utiliza-se o

*LabelEncoder*. Transforma os rótulos categóricos (não numéricos) em números inteiros, e os rótulos numéricos em codificação *one-hot*<sup>6</sup>, onde cada *label* passa a ser representado por um vetor binário (e não apenas um valor numérico inteiro) que indica a classe que representa.

A Figura 39 demonstra um resumo das fases de testes realizadas neste módulo e as suas principais características (rede neuronal utilizada, *features* extraídas e técnicas de *Data Augmentation* aplicadas).

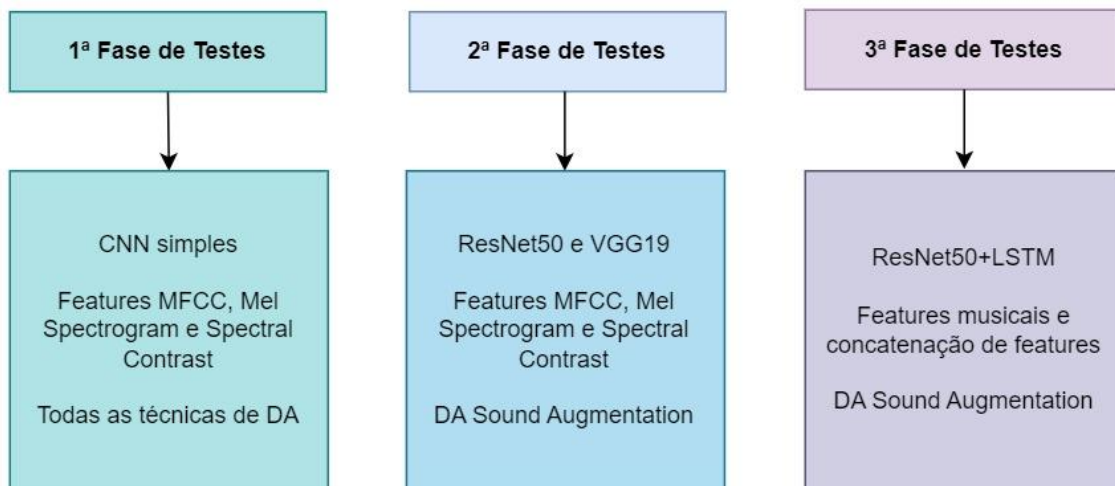


Figura 39 - Fases de testes implementadas e as suas principais características

A Figura 40 representa a arquitetura da CNN utilizada para o conjunto de testes da primeira fase. De notar, que para o problema SN foi utilizada a função de ativação *Sigmoid* (função logística que transforma qualquer valor real num valor compreendido entre 0 e 1) e a função de perda *binary\_crossentropy* por se tratar de uma classificação binária, e para os restantes a função de ativação *Softmax* (função que transforma qualquer saída *raw* de uma rede neuronal num vetor de probabilidades, facilitando assim a leitura e interpretação do resultado) e a função de perda *categorical\_crossentropy*. Chamam-se *crossentropy* às funções que calculam as perdas entrópicas entre as *labels* reais e as previstas para poder penalizar as previsões incorretas e consequentemente favorecer as mais corretas).

O algoritmo de otimização de treino utilizado foi o *Adam*, pois trata-se de um algoritmo computacionalmente “económico” que de forma eficiente calcula os pesos de uma rede neuronal, correndo repetidamente ciclos adaptativos de estimação/previsão. Também foi utilizada uma *seed* com o valor 42 (um valor aleatório comumente usado para iniciar redes neuronais) para inicializar os pesos da rede, e assim, garantir resultados consistentes e comparáveis entre as diferentes execuções do código.

<sup>6</sup> <https://machinelearningmastery.com/why-one-hot-encode-data-in-machine-learning/>




Figura 40 - Arquitetura da CNN implementada

Para validar os modelos implementados, foram realizados 5 testes para cada modelo, com um conjunto de dados de teste diferente e independente. Este conjunto de teste é determinado logo no início quando é realizada a divisão do conjunto de dados. Como o pretendido é realizar uma avaliação justa, foi utilizado um *random state* fixo na separação dos dados. Este parâmetro controla a *seed* utilizada pelo gerador de números aleatórios, e sempre que é utilizado um número fixo a divisão vai ser sempre a mesma, assegurando a reprodutibilidade dos resultados, conceito essencial em *Data Science*. Os *random states* utilizados para os cinco testes foram valores escolhidos aleatoriamente (0, 42, 123, 500 e 999).

Na primeira fase de testes, foram implementados, individualmente, modelos com *features MFCC*, *Mel Spectrogram* e *Spectral Contrast*. Para cada um destes modelos, foram aplicadas cinco técnicas de *Data Augmentation* (*SMOTE*, *Class Weights*, *SMOTE* combinado com *Class Weights*, *Sound Augmentation* e *SpecAugmentation*) de forma independente, e foi realizada a respetiva avaliação de desempenho do modelo. Para os três problemas avaliados (SN, SCN e DR), os melhores resultados foram obtidos pelos modelos que utilizaram *MFCC* e *Sound Augmentation*. Também nos modelos com as *features Mel Spectrogram* e *Spectral Contrast* existiu um domínio da técnica *Sound Augmentation*. A próxima subsecção contém os detalhes dos resultados.

Após a primeira fase de testes, decidiu-se tentar melhorar os resultados obtidos com a utilização de redes neuronais convolucionais profundas e *Transfer Learning*. Esta técnica consiste na utilização de um modelo pré-treinado numa determinada tarefa, como ponto de partida para treinar um novo modelo num problema relacionado. Neste caso, foram utilizadas as CNNs profundas VGG19 e ResNet50, pré-treinadas na base de dados ImageNet [59].

Naturalmente, a utilização destas novas redes neuronais exigiu algumas alterações no pré-processamento dos dados, pois as características dos dados de entrada deste tipo de redes são diferentes das utilizadas anteriormente. Relativamente à forma como as *features* foram extraídas e aos espectrogramas contruídos, não existiram modificações. Contudo, como a forma de entrada recomendada destas redes é de 224x224x3 (largura, altura e canais de cor), os espectrogramas foram transformados em imagens com estas dimensões. Para isso, inicialmente, foram redimensionados através da biblioteca OpenCV e foi aplicado o método de interpolação bicúbica, para suavizar a imagem. Posteriormente, realizou-se a normalização dos valores do espectrograma

considerando um intervalo de 0 a 255, e de seguida aplicou-se a estratégia MinMax, para acelerar a convergência, evitar sobrecargas e reduzir o *bias*. Por fim, foi criada a imagem RGB preenchida com os valores normalizados do espectrograma. Os restantes passos de teste dos modelos foram semelhantes aos anteriores.

A Figura 41 representa a arquitetura utilizada para a segunda fase de testes, com as redes neuronais convolucionais profundas ResNet50 e VGG19. Aqui, estão retratadas as camadas adicionadas ao modelo base oferecidas por estas redes. Relembrando, as arquiteturas do modelo base da VGG19 e da ResNet50 estão descritas no capítulo 2 relativo ao estado da arte, secção 2.4.1.2 - Figura 11 e 2.4.1.3 - Figura 12, respetivamente.

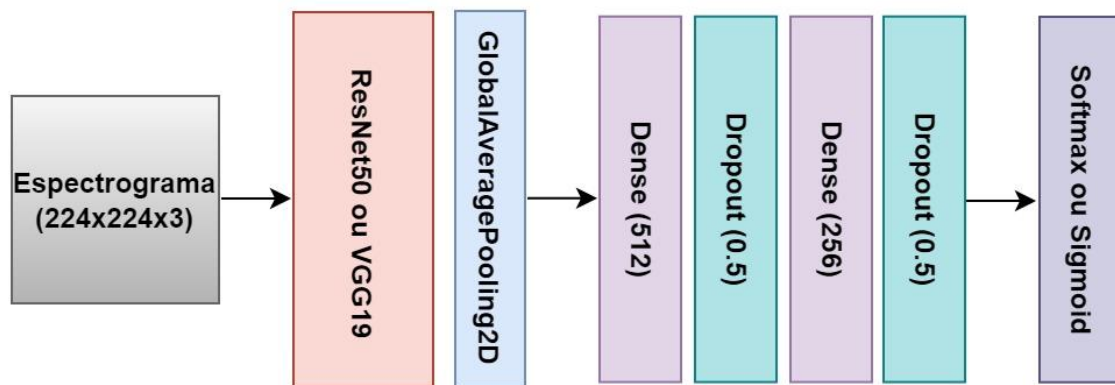


Figura 41 - Arquitetura das redes neuronais convolucionais profundas implementadas

Na segunda fase de testes, foram implementados os dois tipos de modelos (ResNet50 e VGG19), individualmente, com as mesmas *features* da primeira fase. Para cada um destes modelos, escolheu-se aplicar apenas a técnica de *DA Sound Augmentation* por ter garantido melhores resultados para 8 dos 9 testes executados na primeira fase. Para os três problemas avaliados (SN, SCN e DR), o modelo que utilizou a ResNet50 e *features Mel Spectrogram* obteve as melhores pontuações. A próxima subsecção contém os resultados em detalhe.

Por fim, a título experimental, decidiu-se realizar uma última fase de testes com um modelo híbrido, combinando o melhor modelo da fase anterior (ResNet50 com *features Mel Spectrogram*) e um tipo de redes neuronais recorrente (LSTM ou GRU). A arquitetura do modelo implementado está representada na Figura 42. O objetivo aqui foi tentar agregar a extração de diferentes *features*, uma vez que a ResNet50 é adequada para extrair características espaciais relevantes de imagens, enquanto a LSTM e a GRU são úteis para modelar sequências e capturar informações temporais, algo característico nos sons, que muitas vezes têm dimensão temporal significativa.




Figura 42 - Arquitetura do modelo híbrido implementado (ResNet50+LSTM ou GRU)

Outras experiências de interesse consistiram em testar novos tipos de extração *features* do som, desta vez musicais, mais concretamente, *Chroma STFT*, *Tempogram* e *Tonnetz*. O objetivo era tentar perceber se estas *features* poderiam ajudar no diagnóstico, uma vez que as doenças respiratórias têm padrões sonoros particulares, tais como pieiras e crepitações que, por vezes, são harmónicas. Para além disso, testar também a combinação de *features* e o seu impacto no diagnóstico.

Neste contexto, no primeiro conjunto de testes desta última fase, testaram-se dois tipos de modelos híbridos distintos, ResNet50+LSTM e ResNet50+GRU, com *features Mel Spectrogram*. Mais uma vez, para cada modelo foi aplicada a técnica de DA *Sound Augmentation*. Para os três problemas avaliados (SN, SCN e DR), a melhor performance foi obtida pelo modelo híbrido que utilizou ResNet50 com LSTM.

No segundo conjunto de testes para o problema DR, consideram-se as *features* musicais individualmente, utilizando o melhor modelo híbrido anterior. As pontuações obtidas foram fracas, quando comparadas com as alcançadas pelas *features* de timbre. Assim, seguiu-se a concatenação de *features* para a realização do último conjunto de testes.

A ideia de concatenar *features* surgiu com o objetivo de enriquecer a informação dos espectrogramas, e conseqüentemente o diagnóstico dos modelos. Na primeira concatenação, combinaram-se as *features* todas, ou seja, as três de timbre e as três musicais (Figura 43a). Na segunda concatenação, combinaram-se apenas as três de timbre (Figura 43b) por terem sido as que garantiram melhores resultados no geral. A Figura 43 representa as concatenações implementadas para os sons respiratórios de uma pessoa saudável.




Figura 43 - Exemplos da concatenação de *features* para sons respiratórios de uma pessoa saudável

Nesta última fase, testaram-se as duas concatenações de *features* do modelo híbrido (ResNet50+LSTM) para todos os problemas. As pontuações obtidas foram as melhores de todas as fases de teste.

### 5.2.3 Resultados

Os testes foram executados num computador com *Windows 10*, 16GB de memória *RAM* e disco *SSD* de 256GB. Para além disso, como algumas redes neuronais precisavam de muito poder computacional para fazer o treino, foi utilizado o *GPU P100* disponível na plataforma *Kaggle*.

A principal métrica de avaliação dos modelos foi a considerada nos trabalhos relacionados com a base de dados da ICBHI, denominada de ICBHI score. Esta pontuação é frequentemente empregada na base de dados utilizada e consiste na média da sensibilidade (SE) com a especificidade (SP):

$$m = \frac{SE + SP}{2}$$

A sensibilidade representa a taxa de verdadeiros positivos, ou seja, mede a capacidade de um modelo identificar corretamente os exemplos positivos num conjunto de dados. A fórmula para calcular esta métrica é:

$$SE = \frac{TP}{TP + FN}$$

Os Verdadeiros Positivos (TP) representam os exemplos que o modelo classificou corretamente como positivos, e os Falsos Negativos (FN) representam os exemplos que o modelo classificou erradamente como negativos, mas que são positivos.

A especificidade representa a taxa de verdadeiros negativos, ou seja, mede a capacidade de um modelo de identificar corretamente os exemplos negativos num conjunto de dados. A fórmula para calcular esta métrica é:

$$SP = \frac{TN}{TN + FP}$$

Os Verdadeiros Negativos (TN) representam os exemplos que o modelo classificou corretamente como negativos, e os Falsos Positivos (FP) representam os exemplos que o modelo classificou erradamente como positivos, mas que são negativos.

Para validar os modelos implementados foram realizados 5 testes com um conjunto de teste diferente e independente. A avaliação do resultado final de cada modelo consiste na média da métrica de avaliação utilizada (ICBHI score) nos 5 testes executados.

Relativamente ao treino dos modelos, este foi executado com um limite de 50 *epochs* de treino, sendo o *epoch* o parâmetro que mede o número de vezes que um algoritmo de aprendizagem trabalha o *dataset* de treino. Para além disso, foi empregada a técnica de *Early Stopping* que permite interromper o treino do modelo, assim que ele começa a apresentar um desempenho pior no conjunto de validação, em vez de continuar a sua execução até ao ponto em que se ajusta excessivamente aos dados de treino, provocando assim *overfitting*.

Nas tabelas que se seguem apresentam-se os resultados finais para cada um dos modelos implementados e testados ao longo do desenvolvimento deste trabalho.

A Tabela 19, Tabela 20 e Tabela 21 contêm o ICBHI score para o primeiro, segundo e terceiro conjunto de testes, respetivamente, executados na primeira fase. Relembrando, nesta fase foi utilizada a rede CNN, todas as técnicas de DA (*SMOTE*, *Class Weights*, *SMOTE* combinado com *Class Weights*, *Sound Augmentation* e *SpecAugment*), executadas individualmente, e as *features* MFCC, *Mel Spectrogram* e *Spectral Contrast*, respetivamente.

Tabela 19 - CNN, todas as técnicas de DA e *features* MFCC

Problema/Técnica	SMOTE	CW	S-CW	SA	SpecAug
SN	0.866	0.877	0.882	<b>0.910</b>	0.873
SCN	0.843	0.808	0.850	<b>0.853</b>	0.836
DR	0.741	0.702	0.725	<b>0.756</b>	0.688

As *features MFCC* foram as que garantiram as melhores pontuações para todos os problemas, tendo obtido 0.91 para o problema SN, 0.853 para o problema SCN e 0.756 para o problema DR. Este resultado superou as pontuações obtidas pelas *features Mel Spectrogram* (Tabela 20) e *Spectral Contrast* (Tabela 21).

Tabela 20 - CNN, todas as técnicas de DA e *features Mel Spectrogram*

Problema/Técnica	SMOTE	CW	S-CW	SA	SpecAug
SN	0.846	0.879	<b>0.895</b>	0.878	0.825
SCN	0.765	0.802	0.828	<b>0.835</b>	0.808
DR	0.711	0.710	0.718	<b>0.740</b>	0.718

Tabela 21 - CNN, todas as técnicas de DA e *features Spectral Contrast*

Problema/Técnica	SMOTE	CW	S-CW	SA	SpecAug
SN	0.873	0.870	0.885	<b>0.898</b>	0.866
SCN	0.782	0.723	0.817	<b>0.832</b>	0.771
DR	0.673	0.669	0.695	<b>0.749</b>	0.683

No geral, observando as tabelas anteriores, é possível concluir que a técnica de *Sound Augmentation* obteve melhores resultados (indicados a **negrito** na quarta coluna de cada tabela relativa às técnicas utilizadas), em 8 dos 9 testes efetuados para as diferentes *features* testadas. O único teste onde não existiu este domínio, foi no problema SN com as *features Mel Spectrogram*. Aqui, a técnica *SMOTE* combinada com *Class Weights* obteve melhor pontuação.

A Tabela 22, Tabela 23 e Tabela 24 contêm o ICBHI score para o primeiro, segundo e terceiro conjunto de testes, respectivamente, executados na segunda fase. Aqui, foram utilizadas as redes VGG19 e ResNet50, a técnica de DA *Sound Augmentation* e as *features MFCC*, *Mel Spectrogram* e *Spectral Contrast*, respectivamente.

Tabela 22 - VGG19 e ResNet50, DA Sound Augmentation e *features MFCC*

Problema/Rede Neuronal	VGG19	ResNet50
SN	0.923	<b>0.927</b>
SCN	<b>0.867</b>	0.853
DR	<b>0.757</b>	0.755

Tabela 23 - VGG19 e ResNet50, DA Sound Augmentation e *features Mel Spectrogram*

Problema/Rede Neuronal	VGG19	ResNet50
SN	0.925	<b>0.936</b>
SCN	0.865	<b>0.876</b>
DR	0.762	<b>0.772</b>

As *features Mel Spectrogram* foram as que garantiram as melhores pontuações para todos os problemas, tendo obtido 0.936 para o problema SN, 0.876 para o problema SCN e 0.772 para o problema DR. Assim, conseguiu-se uma melhoria, apesar de marginal, em relação aos melhores resultados da primeira fase (Tabela 19 - CNN, todas as técnicas de DA e *features MFCC*). As subidas

foram de 2.6% para o primeiro problema, 2.3% para o segundo e 1.6% para o último problema.

Enfatiza-se ainda, o facto de as *features Mel Spectrogram* se terem superiorizado às *features MFCC*, quando combinadas com redes neuronais convolucionais profundas.

Tabela 24 - VGG19 e ResNet50, DA Sound Augmentation e *features Spectral Contrast*

Problema/Rede Neuronal	VGG19	ResNet50
SN	0.878	<b>0.905</b>
SCN	0.797	<b>0.821</b>
DR	0.708	<b>0.728</b>

No geral, observando as tabelas anteriores, é possível concluir que a rede neuronal convolucional ResNet50 obteve melhores resultados, quando comparados com os da VGG19, em 7 dos 9 testes para as diferentes *features* testadas. Os únicos testes onde não exibiu este domínio, foi nos testes dos problemas SCN e DR, com as *features MFCC*.

Relativamente à Tabela 25, Tabela 26 e Tabela 27, estas contêm o primeiro, segundo e terceiro conjunto de testes, respetivamente, executados na última fase. Aqui, inicialmente utilizou-se um modelo híbrido ResNet50 combinado com as redes GRU e LSTM, a técnica de DA *Sound Augmentation* e as *features Mel Spectrogram*. No segundo conjunto de testes, foi utilizado o modelo híbrido só com ResNet50 e LSTM, a técnica de DA *Sound Augmentation* e as *features* musicais *Chroma STFT*, *Tempogram* e *Tonnetz*. Por fim, no último conjunto, foi utilizado o mesmo modelo híbrido ResNet50 e LSTM, a técnica de DA *Sound Augmentation* e *features* de timbre concatenadas (*MFCC + Mel Spectrogram + Spectral Contrast*) ou *features* de timbre combinadas com musicais (*MFCC + Mel Spectrogram + Spectral Contrast + Chroma STFT + Tempogram + Tonnetz*).

Tabela 25 - Modelo híbrido (ResNet50+GRU e ResNet50+LSTM), Sound Augmentation e *features Mel Spectrogram*

Problema/Rede Neuronal	ResNet50 + GRU	ResNet50 + LSTM
SN	0.923	<b>0.935</b>
SCN	0.869	<b>0.878</b>
DR	0.788	<b>0.797</b>

Na Tabela 25, é possível concluir que o melhor modelo híbrido para todos os problemas é o da rede neuronal ResNet50 combinada com LSTM. A diferença é consistente e varia entre 0.9% a 1.2% no ICBHI score, comparativamente ao da ResNet50 combinada com GRU. Para além disso, houve uma melhoria na pontuação, de 2.5% para o problema DR em relação ao melhor modelo anterior (Tabela 23 - VGG19 e ResNet50, DA Sound Augmentation e *features Mel Spectrogram*). Para os restantes problemas (SN e SCN) não existiram diferenças significativas.

Tabela 26 - Modelo híbrido (ResNet50+LSTM), Sound Augmentation e *features* musicais

Problema/Features	Chroma STFT	Tempogram	Tonnetz
DR	<b>0.711</b>	0.678	0.665

Já na Tabela 26, conseguimos concluir que as experiências com as *features* musicais não alcançaram resultados tão bons para o problema DR, como as *features* de timbre testadas anteriormente. Como tal, não foram realizados testes para os restantes problemas (SN e SCN).

Tabela 27 - Modelo híbrido (ResNet50+LSTM), Sound Augmentation e todas as *features* de timbre ou todas as *features* musicais e de timbre

Problema/Rede Neuronal	Timbre	Timbre+Musicais
SN	0.941	<b>0.943</b>
SCN	<b>0.895</b>	0.884
DR	<b>0.805</b>	0.782

Por fim, na Tabela 27, é possível concluir que a concatenação de *features* melhora os resultados globais, ainda que marginalmente. Para o problema SN, a combinação de todas as *features* (timbre + musicais) apresentou o ICBHI score mais elevado, 0.943, uma melhoria de 0.8% em relação ao teste de ResNet50 com LSTM e *features Mel Spectrogram* (Tabela 23). Para os problemas SCN e DR a concatenação das *features* de timbre apresentou o ICBHI score mais elevado, 0.895 e 0.805, uma melhoria de 1,7% e 0.8%, respetivamente.

Contudo, enfatiza-se o facto de o modelo híbrido que obteve as melhores pontuações (ResNet50+LSTM) requerer muito mais poder computacional do que o modelo CNN simples que obteve os melhores resultados no primeiro conjunto de testes. Essa exigência deve-se ao facto de a arquitetura do modelo híbrido ser bastante mais complexa, pois para além de combinar duas redes distintas, contem um elevado número de camadas (50 só da ResNet), assim como um elevado número de parâmetros e processamento sequencial. O treino do modelo híbrido durou em média 4.5 vezes mais tempo a executar do que o da CNN simples. Os treinos duraram em média 2 minutos e 46 segundos no primeiro caso, enquanto apenas 37 segundos no segundo.

Portanto, embora os modelos híbridos possam oferecer vantagens em termos de desempenho e capacidade de modelagem em tarefas complexas, eles também acarretam um custo computacional significativamente maior, em comparação com modelos mais simples. Concluindo, escolher o melhor modelo deve levar em consideração os recursos computacionais disponíveis, a natureza da tarefa e os requisitos de desempenho.

Em termos empresariais, arriscaríamos a dizer que a melhor escolha recairia sobre a CNN simples porque também é eficiente na resposta às tarefas em questão e permitiria custos reduzidos (hardware mais barato), eficiência energética (consome menos energia), escalabilidade (normalmente são mais escaláveis), disponibilidade de recursos (mais fácil de ir ao encontro dos

requisitos) e simplicidade. Em termos científicos, o modelo híbrido (ResNet50+LSTM) é mais interessante, pois resultou de uma combinação não muito explorada nos artigos consultados e foi o que alcançou a melhor pontuação para todos os problemas, segundo a métrica de avaliação utilizada pela ICBHI.

Outra métrica de avaliação que se calculou no final de cada teste, foi a matriz de confusão. A matriz de confusão permite retirar informação crucial relacionada com o desempenho de um modelo de classificação (e.g., quantidade de instâncias que o modelo classificou corretamente e incorretamente como positivas e negativas).

A Figura 44 representa a matriz de confusão para a melhor execução do primeiro e segundo problema (SN e SCN), no modelo híbrido com *features* de timbre combinadas e DA *Sound Augmentation*. A Figura 45 representa a matriz de confusão para a melhor execução do terceiro problema (DR), usando o mesmo modelo híbrido.

	Healthy	Not Healthy		Chronic	Healthy	Non Chronic
Healthy	40	2	Chronic	230	1	8
Not Healthy	6	259	Healthy	0	37	5
			Non Chronic	2	6	23

Figura 44 - Matrizes de confusão do problema SN e SCN

	Asthma	Bronchiectasis	Bronchiolitis	COPD	Healthy	Pneumonia	URTI
Asthma	20	0	0	0	9	1	0
Bronchiectasis	0	4	0	1	0	0	0
Bronchiolitis	0	0	4	0	0	0	0
COPD	1	0	0	229	3	4	1
Healthy	3	0	3	2	29	1	4
Pneumonia	3	0	0	0	2	11	0
URTI	0	0	3	1	1	0	2

Figura 45 - Matriz de confusão do problema DR

Para analisar a taxa de acerto para cada classe na matriz de confusão utilizou-se a métrica de avaliação *accuracy*.

$$Accuracy = \frac{TP}{TP + TN}$$

É relevante destacar que a *accuracy* pode ser sensivelmente afetada pelo desequilíbrio dos dados. Por isso, não foi utilizada como métrica principal de avaliação neste trabalho. Contudo, a título exemplificativo, vai ser utilizada para analisar a taxa de acerto de cada classe individualmente, oferecendo assim *insight* sobre as classes que o modelo consegue classificar mais facilmente e aquelas que enfrentam mais desafios.

Para as diferentes matrizes de confusão temos:

- No problema SN, uma taxa de acerto de aproximadamente 95% para a classe “*Healthy*” e 98% para a classe “*Unhealthy*”;
- No problema SCN, uma taxa de acerto de aproximadamente 96% para a classe “*Chronic*”, 88% para a classe “*Healthy*” e 74% para a classe “*Non Chronic*”;
- No problema DR, uma taxa de acerto de aproximadamente 67% para a classe “*Asthma*”, 80% para a classe “*Bronchiectasis*”, 100% para a classe “*Bronchiolitis*”, 96% para a classe “*COPD*”, 69% para a classe “*Healthy*”, 69% para a classe “*Pneumonia*” e, por fim, a pior taxa de acerto na classe “*URTP*” de aproximadamente 28%.

Assim, conseguimos concluir que o modelo híbrido, na sua melhor execução, foi assertivo a classificar as classes “*COPD*” e “*Bronchiolitis*”. Conseguimos classificar bem as classes “*Bronchiectasis*”, “*Healthy*” e “*Pneumonia*”, apesar de com um maior número de falhas, e não foi assertivo a classificar a classe “*URTP*”.

Aqui, é possível também destacar a classe “*Asthma*” ter sido facilmente confundida com a classe “*Healthy*” (9 instâncias). Uma possível causa, reside no facto de algumas amostras de áudio da classe “*Healthy*” e da classe “*Asthma*” terem apenas entre 5 a 10 segundos de duração, ao contrário das outras classes. Como tal, torna-se mais difícil fazer o diagnóstico, especialmente em situações em que os sintomas de asma são leves.

Na Tabela 28, apresenta-se um resumo dos trabalhos relacionados (consultados aquando da análise de estado da arte) que utilizaram o mesmo conjunto de dados para classificar sons respiratórios, segundo os problemas SN, SCN e DR, o respetivo modelo que implementaram (na melhor pontuação), e o ICBHI score.

Tabela 28 - Resultados finais comparados com o estado da arte

Estudo	Modelo	Resultados
Este trabalho	ResNet50 + LSTM	SN: <b>0.94</b> SCN: 0.90 DR: 0.81
Aykanat et al.	CNN e SVM	SN: 0.86
Perna et al.	CNN	SCN: 0.88
Lam Pham et al.	CNN-MoE	SN: 0.91 SCN: 0.90
Tagarelli et al.	LSTM	SN: 0.91 SCN: 0.90
Srivastava et al.	CNN	SN: 0.93
Nguyen e Pernkopf	ResNet101	SN: <b>0.94</b> SCN: <b>0.92</b>

Desta tabela, enfatiza-se o trabalho de Nguyen e Pernkopf porque foi o que alcançou os melhores resultados para os problemas SN e SCN. Contudo, o presente trabalho conseguiu igualar o seu ICBHI score para o problema SN.

Para além disso, destaca-se também, a ausência de pontuações dos trabalhos apresentados na tabela, relativamente ao problema DR, pois não constou de nenhum dos estudos referidos.

Contudo, outros trabalhos relacionados que fizeram a classificação do problema DR, como não utilizaram a mesma métrica de avaliação (ICBHI score) e utilizaram técnicas de aumento no conjunto de dados de teste, não se colocaram na mesma tabela, pois como não partilham os mesmos parâmetros de avaliação não são comparáveis.

O trabalho executado no âmbito desta dissertação destaca-se dos restantes, essencialmente por:

- a) ter utilizado alguns sons respiratórios de outro conjunto de dados de áudio, com o intuito de aumentar as instâncias não sintéticas do *dataset* original e,
- b) por ter explorado e testado uma grande variedade de modelos de *Deep Learning*, técnicas de *Data Augmentation* e métodos de extração de *features* de áudio.

Para além disso, os resultados superaram a maioria dos trabalhos relacionados para o problema SN e igualaram a maioria para o problema SCN.

## 6 CONCLUSÕES E TRABALHO FUTURO

Os principais objetivos deste trabalho complementam-se na área da saúde, passando pelo tratamento e diagnóstico de doentes com doenças respiratórias, mais especificamente com DPOC. Estes são:

- a) implementar e integrar um novo sistema de alertas e notificações no SmartAL e
- b) desenvolver um modelo de classificação para diagnóstico de doenças respiratórias utilizando dados de áudio.

Primeiramente, foi implementado em linguagem Java e integrado, o sistema de alertas e notificações na plataforma de telemonitorização SmartAL, da Altice Labs. Este sistema teve como foco a DPOC, a terceira doença mais mortal no mundo. A solução permite aos cuidadores automatizar certos processos de alerta, com base na correlação de informação proveniente de medidas de saúde (SpO<sub>2</sub>, temperatura, frequência cardíaca, glicose e pressão arterial) e de respostas a questionários (QCD, CAT e TAT). Esta análise, era até então efetuada manualmente, à posteriori pelos profissionais aquando da avaliação de cada doente. A solução foi desenvolvida, integrada e validada com sucesso, sendo que está atualmente em produção nos pilotos DPOC da Altice Labs. Portanto, primeiro objetivo cumprido.

Em segundo lugar, foram implementados em linguagem Python, os modelos de classificação de doenças respiratórias. Aqui, foram usadas e testadas diferentes técnicas de DA (*SMOTE*, *Class Weights*, *Sound Augmentation* e *Spec Augmentation*), diferentes tipos de extração de *features* sonoras (*MFCC*, *Mel Spectrogram*, *Spectral Contrast*, *Chroma STFT*, *Tempogram* e *Tonnetz*) e diferentes abordagens de DL (e.g. CNN, VGG19, ResNet50, LSTM e GRU).

Assim, o segundo objetivo de carácter mais experimental foi também cumprido com sucesso, apresentando resultados muito interessantes. O modelo híbrido (ResNet50+LSTM) agregado com a técnica de DA *Sound Augmentation* e as *features Mel Spectrogram* conseguiu a melhor pontuação, em todas as tarefas, para a métrica de avaliação considerada (ICBHI score); 0.94 para o problema Saudável contra Não Saudável, 0.90 para o problema Saudável contra Doente Crónico e Doente Não Crónico, e por fim, 0.81 para a classificação de doenças respiratórias (asma, bronquiectasia, bronquiolite, DPOC, saudável, pneumonia e infeção do trato respiratório superior). O desempenho deste modelo foi assinalável, pois conseguiu melhor performance do que outros de trabalhos relacionados.

Contudo, a escolha do modelo mais adequado para um ambiente empresarial, recaiu sobre a CNN simples agregada à técnica de DA *Sound Augmentation* e *features MFCC* porque também é eficaz na resposta a todas as tarefas em questão, exigindo menos recursos.

Como trabalho futuro, seria interessante explorar novas abordagens de DL, como por exemplo, redes neuronais com transformações ou de transformadores que pertencem a uma classe recente de redes neuronais baseadas em mecanismos de autoatenção e que estão a fazer sucesso, sobretudo na análise de linguagem natural (e.g. modelos GPT, BERT). Também, seria de interesse estudar e testar outras *features*, tais como, dimensões fractais.

## 6.1 Considerações finais

O desenvolvimento deste trabalho proporcionou a aquisição de um conjunto alargado de novas competências.

A implementação e integração do fluxo da DPOC na solução de telemonitorização SmartAL fez-me adquirir novos conhecimentos e competências, das quais se salientam as seguintes:

- Contacto com a linguagem de programação, Java, a qual não tinha explorado no meu percurso de académico;
- Conhecimento detalhado do suporte informático inerente a uma solução de telemonitorização;
- Conhecimento detalhado da solução de telemonitorização SmartAL e dos fluxos de cuidados na perspetiva do utilizador final, tanto do ponto de vista do utente, como do cuidador/médico;
- Conhecimento detalhado da especificação, implementação, integração e validação de um novo fluxo lógico, numa solução já existente de telemonitorização;
- Conhecimento detalhado para estruturar ideias, formular casos de uso e pensar na ótica do utilizador;
- Conhecimento detalhado para estruturar código seguindo um fluxograma;
- Aperfeiçoamento de competências no que diz respeito ao processo metodológico que foi desde a conceção à implementação, integração e teste.

No desenvolvimento e implementação dos modelos de *Deep Learning* para a classificação de doenças respiratórias através de sons, fez-me adquirir os seguintes novos conhecimentos e competências:

- Conhecimento detalhado para manusear dados de som para a resolução de problemas de classificação;
- Aperfeiçoamento dos meus conhecimentos e competências em bibliotecas de Python (e.g. Tensorflow, Keras);

- Conhecimento detalhado de novas bibliotecas de Python (e.g. Librosa);
- Conhecimento detalhado para extrair *features* de timbre, harmonia e ritmo de dados de áudio;
- Aperfeiçoamento dos meus conhecimentos e competências a implementar modelos de *Deep Learning*;
- Aperfeiçoamento dos meus conhecimentos e competências com técnicas *Data Augmentation* e *Transfer Learning*;
- Aperfeiçoamento da minha capacidade de interpretação e análise de dados.

Para concluir, resta-me dizer que este estágio académico em ambiente empresarial, proporcionou sem dúvida a aquisição de múltiplas valências e aprendizagens.



## Referências

- [1] World Health Organization, “Ageing and health,” 1 10 2022. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/ageing-and-health>. [Acedido em 15 11 2022].
- [2] P. Maresova, “Consequences of chronic diseases and other limitations associated with old age - a scoping review,” *BMC Public Health*, vol. 19, n° 1431, 2019.
- [3] M. Hussein, “HIMSS - The Status of Informatics/eHealth Integration in Medical and Nursing Curricula,” 09 2022. [Online]. Available: <https://www.himss.org/resources/status-informaticsehealth-integration-medical-and-nursing-curricula>. [Acedido em 07 12 2022].
- [4] Worldometer, “Life Expectancy of the World Population,” 2022. [Online]. Available: <https://www.worldometers.info/demographics/life-expectancy/>. [Acedido em 22 11 2022].
- [5] “Eurostat,” [Online]. Available: [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Mortality\\_and\\_life\\_expectancy\\_statistics](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Mortality_and_life_expectancy_statistics). [Acedido em 02 02 2023].
- [6] “PORDATA,” [Online]. Available: <https://www.pordata.pt/portugal/indice+de+envelhecimento+e+outros+indicadores+de+envelhecimento-526>. [Acedido em 02 02 2023].
- [7] World Health Organization, “Noncommunicable diseases,” World Health Organization, 16 09 2022. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/noncommunicable-diseases>. [Acedido em 15 11 2022].
- [8] World Health Organization, “Invisible numbers: the true extent of noncommunicable diseases and what to do about them,” WHO, 2022.
- [9] F. Fixe, Interviewee, *A tecnologia é sempre um meio para melhorar a saúde e qualidade de vida de cada um de nós*. [Entrevista]. 25 06 2019.
- [10] M. Blix and C. Levay, “Digitalization and Health Care,” *The Expert Group on Public Economics*, 2018.
- [11] V. T. Reed, “Telehealth,” *The New England Journal of Medicine*, vol. 377, pp. 1585-1592, 2017.
- [12] S. McLean, “Telehealthcare for chronic obstructive pulmonary disease: Cochrane Review and meta-analysis,” *British Journal of General Practice*, vol. 62, n° 604, pp. 739-749, 2012.
- [13] World Health Organization, “The top 10 causes of death,” 9 12 2020. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>. [Acedido em 15 11 2022].

- [14] P. J. Barnes and B. R. Celli, "Systemic manifestations and comorbidities of COPD," *European Respiratory Journal*, vol. 33, no. 5, pp. 1165-1185, 2009.
- [15] I. Tomasic, "Continuous remote monitoring of COPD patients—justification and explanation of the requirements and a survey of the available technologies," *Medical & Biological Engineering & Computing*, vol. 56, pp. 547-569, 2018.
- [16] G. Hillas, "Managing comorbidities in COPD," *International Journal of Chronic Obstructive Pulmonary Disease*, vol. 10, n° 1, pp. 95-109, 2015.
- [17] World Health Organization, "Chronic obstructive pulmonary disease (COPD)," 20 05 2022. [Online]. Available: [https://www.who.int/news-room/fact-sheets/detail/chronic-obstructive-pulmonary-disease-\(copd\)](https://www.who.int/news-room/fact-sheets/detail/chronic-obstructive-pulmonary-disease-(copd)). [Acedido em 15 11 2022].
- [18] GOLD, "Pocket guide to COPD diagnosis, management and prevention: a guide for health care professionals," Global Initiative for Chronic Obstructive Lung Disease, Fontana, 2021.
- [19] C. Bárbara, "Prevalência da doença pulmonar obstrutiva crónica em Lisboa, Portugal: estudo Burden of Obstructive Lung Disease," *Revista Portuguesa de Pneumologia*, vol. 19, n° 3, pp. 96-105, 2013.
- [20] Observatório Nacional das Doenças Respiratórias, "ONDR," Fundação Portuguesa do Pulmão, 2020.
- [21] M. T. Barbosa, "Telemedicine in COPD: An Overview by Topics," *COPD: Journal of Chronic Obstructive Pulmonary Disease*, vol. 17, n° 5, pp. 601-617, 2020.
- [22] F. Amorim, "Telemedicina e Telecuidados," Universidade da Beira Interior, 2011.
- [23] A. Romero, "Uso de alta tecnologia e digitalização do setor da saúde - realidade ou ficção?," *IDEAS LLYC*, 8 09 2021.
- [24] Serviço Nacional de Saúde, "Consultas em Telemedicina," SNS, 29 11 2022. [Online]. Available: <https://transparencia.sns.gov.pt/explore/dataset/consultas-em-telemedicina>. [Acedido em 07 12 2022].
- [25] S. X. Liu, "Economic Modeling of Heart Failure Telehealth Programs: When Do They Become Cost Saving?," *Int J Telemed Appl*, 2016.
- [26] D. Achelrod, "Health-economic evaluation of home telemonitoring for COPD in Germany: evidence from a large population-based cohort," *Eur J Health Econ.*, vol. 18, n° 7, pp. 869-882, 2017.
- [27] R. Nunes, "Telessaúde x Telemedicina: Qual é a diferença?," LinkedIn, 10 02 2022. [Online]. Available: <https://www.linkedin.com/pulse/telessa%C3%BAde-x-telemedicina-qual-%C3%A9-diferen%C3%A7a-regiane-nunes>. [Acedido em 07 12 2022].

- [28] Altice Empresas, “SmartAL - Monitorização da saúde à distância,” [Online]. Available: <https://www.altice-empresas.pt/solucoes/iot/saude-bem-estar/smartal>. [Acedido em 26 12 2022].
- [29] Hope Care, “O que é o HCAAlert?,” [Online]. Available: <https://hope-care.pt/pt/hc-alert/>. [Acedido em 26 12 2022].
- [30] Plano A, “Solução tecnológica de telessaúde,” [Online]. Available: <https://www.planoa.pt/>. [Acedido em 26 12 2022].
- [31] VitalMobile, “VitalMobile Health,” [Online]. Available: <https://www.vitalmobile.eu/>. [Acedido em 26 12 2022].
- [32] “Linde Saúde - Cuidados de saúde ao domicílio,” [Online]. Available: <https://www.lindesaude.pt/>. [Acedido em 26 12 2022].
- [33] SNS 24, “App Telemonit SNS 24,” 21 12 2022. [Online]. Available: <https://www.sns24.gov.pt/guia/app-telemonit-sns-24/#o-que-e-a-telemonit-sns-24>. [Acedido em 22 02 2023].
- [34] Centro Nacional de TeleSaúde, “Ficha Técnica Telemonitorização DPOC,” CNTS, 2019.
- [35] C. Kruse, “Telemonitoring to Manage Chronic Obstructive Pulmonary Disease: Systematic Literature Review,” *JMIR Med Inform*, vol. 7, n° 1, 2019.
- [36] X. Li, “Telemonitoring Interventions in COPD Patients: Overview of Systematic Reviews,” *BioMed Research International*, vol. 2020, 2020.
- [37] S. Jang, “A Systematic Review and Meta-Analysis of Telemonitoring Interventions on Severe COPD Exacerbations,” *Int J Environ Res Public Health*, vol. 18, n° 13, 2021.
- [38] S. Janjua, “Telehealth interventions: remote monitoring and consultations for people with chronic obstructive pulmonary disease (COPD),” *Cochrane Database Syst. Rev.*, 2021.
- [39] E. Metting, “Effectiveness of Telemonitoring for Respiratory and Systemic Symptoms of Asthma and COPD: A Narrative Review,” *Life (Basel)*, vol. 11, n° 11, 2021.
- [40] F. Nagase, “Effectiveness of remote home monitoring for patients with Chronic Obstructive Pulmonary Disease (COPD): systematic review,” *BMC Health Services Research*, 2022.
- [41] R. Nêveda, Interviewee, *Telemonitorização DPOC*. [Entrevista]. 15 2 2017.
- [42] TecnoHospital, “TecnoHospital,” 02 03 2021. [Online]. Available: <http://www.tecnohospital.pt/noticias/hospital-santarem-projeto-telemonitorizacao-domiciliaria/>. [Acedido em 12 12 2022].

- [43] HFF, “Hospital Professor Doutor Fernando Fonseca,” 17 11 2021. [Online]. Available: <https://hff.min-saude.pt/monitorizacao-a-distancia-da-dpoc-projeto-do-servico-de-pneumologia-do-hff>. [Acedido em 12 12 2022].
- [44] G. Petmezas, G. Cheimariotis, L. Stefanopoulos, B. Rocha, R. P. Paiva, A. K. Katsaggelos e N. Maglaveras, “Automated Lung Sound Classification Using a Hybrid CNN-LSTM Network and Focal Loss Function,” *MDPI Sensors*, vol. 22, n° 1232, 2022.
- [45] A. Srivastava, S. Jain, R. Miranda, S. Patil, S. Pandya e K. Kotecha, “Deep learning based respiratory sound analysis for detection of chronic obstructive pulmonary disease,” *PeerJ Computer Science*, 2021.
- [46] M. Garcia-Ordas, J. Benitez-Andrades, I. Garcia-Rodriguez, C. Benavides e H. Alaiz-Moretón, “Detecting Respiratory Pathologies Using Convolutional Neural Networks and Variational Autoencoders for Unbalancing Data,” *MDPI Sensors*, vol. 20, n° 1214, 2020.
- [47] V. Basu e S. Rana, “Respiratory diseases recognition through respiratory sound with the help of deep neural network,” em *4th International Conference on Computational Intelligence and Networks (CINE)*, 2020.
- [48] “ICBHI Challenge,” [Online]. Available: [https://bhchallenge.med.auth.gr/ICBHI\\_2017\\_Challenge](https://bhchallenge.med.auth.gr/ICBHI_2017_Challenge). [Acedido em 01 03 2023].
- [49] “Classification of lung sounds using convolutional neural networks,” *EURASIP Journal on Image and Video Processing*, vol. 65, 2017.
- [50] D. Perna, “Convolutional Neural Networks Learning from Respiratory data,” em *2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 2018.
- [51] D. Perna e A. Tagarelli, “Deep Auscultation: Predicting Respiratory Anomalies and Diseases via Recurrent Neural Networks,” em *IEEE 32nd International Symposium on Computer-Based Medical Systems (CBMS)*, 2019.
- [52] L. Pham, I. McLoughlin, H. Phan, M. Tran, T. Nguyen e R. Palaniappan , “Robust Deep Learning Framework For Predicting Respiratory Anomalies and Diseases,” em *42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 2020.
- [53] G. Altan, Y. Kutlu e N. Allahverdi, “Deep Learning on Computerized Analysis of Chronic Obstructive Pulmonary Disease,” *IEEE Journal of Biomedical and Health Informatics*, vol. 24, n° 5, pp. 1344-1350, 2020.
- [54] E. Paraschiv e C. Rotaru, “Machine Learning Approaches based on Wearable Devices for Respiratory Diseases Diagnosis,” em *International Conference on e-Health and Bioengineering (EHB)*, 2020.

- [55] T. Nguyen e F. Pernkopf, “Lung Sound Classification Using Co-Tuning and Stochastic Normalization,” *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, vol. 69, n° 9, pp. 2872-2882, 2022.
- [56] “What is Deep Learning?,” MathWorks, [Online]. Available: <https://www.mathworks.com/discovery/deep-learning.html>. [Acedido em 28 08 2023].
- [57] K. Simonyan e A. Zisserman, “Very Deep Convolutional Networks For Large-Scale Image Recognition,” em *ICLR*, 2015.
- [58] “VGG16 and VGG19,” Keras, [Online]. Available: <https://keras.io/api/applications/vgg/>. [Acedido em 28 08 2023].
- [59] “ImageNet,” [Online]. Available: <https://www.image-net.org/>. [Acedido em 28 08 23].
- [60] H. Kaiming, X. Zhang, S. Ren e J. Sun, “Deep Residual Learning for Image Recognition,” em *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [61] “ResNet and ResNetV2,” Keras, [Online]. Available: <https://keras.io/api/applications/resnet>. [Acedido em 28 08 2023].
- [62] Jonte Dancker, “A Brief Introduction to Recurrent Neural Networks,” Towards Data Science, [Online]. Available: <https://towardsdatascience.com/a-brief-introduction-to-recurrent-neural-networks-638f64a61ff4>. [Acedido em 28 08 2023].
- [63] Parth Dholakiya, “Medium,” [Online]. Available: <https://medium.com/@parthdholakiya180/smote-synthetic-minority-over-sampling-technique-4d5a5d69d720>. [Acedido em 28 08 2023].
- [64] Edward Ma, “Medium,” [Online]. Available: <https://medium.com/@makcedward/data-augmentation-for-audio-76912b01fdf6>. [Acedido em 28 08 2023].
- [65] “Librosa audio and music processing in Python,” [Online]. Available: <https://librosa.org>. [Acedido em 28 08 2023].
- [66] D. S. Park, W. Chan, Y. Zhang, C. Chiu, B. Zoph, E. D. Cubuk, Q. Le, “SpecAugment: A Simple Data Augmentation Method for Automatic Speech Recognition,” em *INTERSPEECH 2019*, Austria, 2019.
- [67] “Kaggle,” [Online]. Available: <https://www.kaggle.com/>. [Acedido em 23 08 27].
- [68] B. Rocha, D. Filos, L. Mendes, I. Vogiatzis, E. Perantoni, E. Kaimakamis, P. Natsiavas, A. Oliveira, C. Jácome, A. Marques, R. P. Paiva, I. Chouvarda, P. Carvalho, N. Maglaveras, “A Respiratory Sound Database for the Development of Automated Classification,” em *Precision Medicine Powered by pHealth and Connected Health*, 2017.
- [69] B. Rocha, D. Filos, L. Mendes, G. Serbes, S. Ulukaya, Y. P. Kahya, N. Jakovljevic, T. L. Turukalo, I. M. Vogiatzis e E. Perantoni, “An open access database for the

evaluation of respiratory sound classification algorithms,” *Physiological Measurement*, vol. 40, n° 3.

- [70] M. Fraiwan, L. Fraiwan, B. Khassawneh e A. Ibnian, “A dataset of lung sounds recorded from the chest wall using an electronic stethoscope,” Mendeley Data, [Online]. Available: <https://data.mendeley.com/datasets/jwyy9np4gv/3> . [Acedido em 28 08 2023].
  
- [71] L. Fraiwan, O. Hassanin, M. Fraiwan, B. Khassawneh, A. M. Ibnian e M. Alkhodari, “Automatic identification of respiratory diseases from stethoscopic lung sound signals using ensemble classifiers,” *Biocybernetics and Biomedical Engineering*, vol. 41, n° 1, pp. 1-14, 2021.

## ANEXO



# Mestrado em Engenharia Informática Proposta de Estágio

Ano Letivo de 2022/2023

Título	eHealth - Análise de dados de saúde e de usabilidade
Aluno	João Pedro Costa Antas (2018010878)
Orientador	Simão Paredes, Doutorado, <a href="mailto:sparedes@isec.pt">sparedes@isec.pt</a> <small>Politechnic of Coimbra, Department of Systems and Computer Engineering, Rua Pedro Nunes - Quinta da Nora, 3090-199 Coimbra, Portugal</small>
Empresa	Altice
Supervisor	Telma Mota, Team Leader da área Saúde, Mestre, <a href="mailto:telma@alticelabs.com">telma@alticelabs.com</a>
Local de trabalho	Altice Labs, Rua Engenheiro José Ferreira Pinto Basto, 3810-106 Aveiro

## SUMÁRIO

Este estágio baseia-se na extração de conhecimento diretamente a partir de dados clínicos (*data driven approach*) obtidos a partir de plataformas de telemonitorização. Assim, pretende-se criar novos elementos de suporte à decisão clínica, contribuindo deste modo para que administradores e cuidadores possam otimizar a prestação dos cuidados de saúde aos pacientes.

### 1. ÂMBITO

A área de eHealth/Assisted Living tem vindo a crescer com a necessidade de melhorar a qualidade de vida de pessoas que precisam de acompanhamento médico permanente (e.g. doença crónica) ou ocasional (e.g. pós-operatório, pandemia). Pretende-se, cada vez mais, acompanhar as pessoas de alguma forma em risco e recolher a informação necessária para poder traçar o perfil dos utentes e das doenças de que padecem ou de que podem vir a padecer. Para tal, cria-se uma base de dados a partir da informação de telemonitorização, e de dados complementares relativos ao utente (e.g. análises). Esta informação deve gerar conhecimento e indicadores que possam ajudar administradores e cuidadores a servir melhor os seus doentes.

De facto, a telemonitorização é considerada uma ferramenta poderosa na prevenção e diagnóstico de doenças em todo mundo, e também uma forma de dar ao utente o controlo do seu estado de saúde e bem-estar. Os Electronic Health Records (EHR) são versões eletrónicas do histórico do utente que são normalmente mantidos por entidades públicas e/ou instituições privadas e podem incluir não só informação puramente clínica, como também informação adicional sobre outros aspetos importantes da vida e bem-estar do utente (medicação, preferências, hobbies, etc.). Este projeto pretende analisar essa informação, e produzir indicadores que possam servir para melhorar ainda mais o serviço de telemonitorização. O seu sucesso depende do empenho dos próprios doentes na sua utilização o que implica que as aplicações devem estar verdadeiramente adaptadas às suas necessidades, assim como das dos seus cuidadores.

1/3



## 2. OBJETIVOS

O presente estágio pretende atingir os seguintes objetivos genéricos:

- Análise de informação proveniente de um conjunto de dispositivos clínicos pré-selecionados (balanças, oxímetros, botões de pânico, etc.), de wearables (smartwatches, mibands, etc.), dispositivos virtuais (fotografias, imagens, ficheiros e.g. análises, etc.), de APIs de terceiros (e.g. GoogleFIT, Apple HealthKit) e outra (e.g. questionários).
- Criação de indicadores relevantes quer para os doentes quer para os cuidadores que cruzem informação clínica e não clínica. Os indicadores serão identificados durante o projeto e poderão ir desde simples médias, valores máximos ou mínimos / unidade de tempo até valores mais complexos, correlacionados e que impliquem lógica de serviço associada de apoio ao diagnóstico (e.g. se tensão arterial atingiu o vermelho, número de passos <1000 e glicémia acima do normal duas vezes por semana então enviar notificação "grave").

## 3. PLANO DE TRABALHOS

*Nota: O trabalho total consiste em cerca de 1170 horas: 390 horas no 1º semestre e 780 horas no 2º semestre.*

O projeto/estágio/dissertação consistirá nas seguintes atividades e respetivas tarefas:

### T1. Análise do Estado da Arte

- Estudo de ferramentas de analytics e motores de regras
- Análise dos dados de saúde já disponíveis e especificação de indicadores simples e correlacionados
- Especificação da lógica de serviço associada em função dos indicadores identificados

### T2. Implementação dos indicadores

### T3. Construção de APIs de consulta e armazenamento

### T4. Validação e teste da solução final

### T5. Escrita da Tese

Serão produzidos os seguintes documentos ou materiais:

E1 – Estado da Arte

E2 – Protótipos iniciais

E3 - Versão final das implementações

E4 – Relatório final para provas públicas.



A calendarização prevista para os trabalhos e entregas será a seguinte:

	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul
<b>Tarefas</b>											
T1											
T2											
<b>Entregas</b>											
E1					X						
E2								X			
E3									X		
E4											X

#### 4. CARATERIZAÇÃO DO ESTÁGIO

- Data de início: 26/09/2022
- Data de fim: 28/07/2023