

FUNDAÇÃO UNIVERSIDADE FEDERAL DO ABC
CENTRO DE ENGENHARIA, MODELAGEM E CIÊNCIAS SOCIAIS APLICADAS
TRABALHO DE GRADUAÇÃO III

Mateus Pepe Ramirez

DETECÇÃO AUTOMÁTICA DE
PENDELLUFT EM SEQUÊNCIAS DE
IMAGENS DE TOMOGRAFIA POR
IMPEDÂNCIA ELÉTRICA

São Bernardo do Campo - SP

2023

Mateus Pepe Ramirez

DETECÇÃO AUTOMÁTICA DE PENDELLUFT EM
SEQUÊNCIAS DE IMAGENS DE TOMOGRAFIA
POR IMPEDÂNCIA ELÉTRICA

Trabalho de Graduação III em Engenharia
Biomédica realizado na Fundação Universi-
dade Federal do ABC.

Orientador: Prof. Dr. John Andrew Sims

Coorientador: Prof. Dr. Erick Dario León
Bueno de Camargo

São Bernardo do Campo - SP
2023

Sistema de Bibliotecas da Universidade Federal do ABC
Elaborada pelo Sistema de Geração de Ficha Catalográfica da UFABC
com os dados fornecidos pelo(a) autor(a).

Pepe Ramirez, Mateus

DETECÇÃO AUTOMÁTICA DE PENDELLUFT EM SEQUÊNCIAS DE
IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA / Mateus Pepe
Ramirez. — 2023.

63 fls. : il.

Orientador: John Andrew Sims

Coorientador: Erick Dario León Bueno de Camargo

Trabalho de Conclusão de Curso — Universidade Federal do ABC, Bacharelado
em Engenharia Biomédica, São Bernardo do Campo, 2023.

1. Pendelluft. 2. Tomografia por Impedância Elétrica (TIE). 3. Fluxo Óptico. 4.
Decomposição Discreta de Helmholtz-Hodge. I. Sims, John Andrew. II. Dario León
Bueno de Camargo, Erick. III. Bacharelado em Engenharia Biomédica, 2023. IV.
Título.

Este exemplar foi revisado e alterado em relação à versão original, de acordo com as observações levantadas pela banca examinadora no dia da defesa, sob responsabilidade única do(a) autor(a) e com a anuência do(a) (co)orientador(a).

São Bernardo do Campo, 14 de agosto de 2023.

Mateus Pepe Ramirez



Nome completo e Assinatura do(a) autor(a)

John Andrew Sims

Nome completo e Assinatura do(a) (co)orientador(a)



São Bernardo do Campo, 7 de agosto de 2023.

Para: Coordenador do Trabalho de Graduação da Engenharia Biomédica.

2º. Quadrimestre de 2023

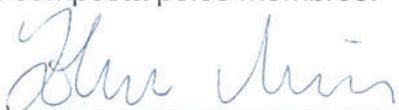
Atribuição de conceito (com banca examinadora, TG III)

Nome do(a) Orientador(a)	John Andrew Sims
Nome do(a) Aluno(a)	Mateus Pepe Ramirez
R.A.	21004016
Título do Trabalho	DETECÇÃO AUTOMÁTICA DE PENDELLUFT EM SEQUÊNCIAS DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA

A banca composta pelos membros que subscrevem este documento decidiu atribuir o conceito A ao referido aluno, tendo assim, o mesmo, preenchido os requisitos referentes ao Trabalho de Graduação.

Este conceito será considerado para TGIII somente após a entrega da Versão Final Corrigida à Coordenação de Trabalho de Graduação da Engenharia Biomédica.

A banca foi composta pelos membros:


Orientador(a) JOHN ANDREW SIMS


Titular 1 OLAVO CUPPI SILVA


Titular 2 FERNANDO MOURA

Resumo

Pendelluft é um fenômeno pulmonar caracterizado pelo fluxo de ar de regiões não dependentes para dependentes. Sua manifestação é imprevisível, de difícil detecção e pode acontecer durante respiração espontânea na ventilação mecânica, resultando em danos ao paciente acamado. O objetivo deste estudo foi desenvolver um método capaz de diagnosticar a condição de Pendelluft automaticamente em tempo real através de sequências de imagens de Tomografia por Impedância Elétrica (TIE) para dados de um humano com a condição (Humano P), um humano sem a condição (Humano N), um suíno com Pendelluft (Suíno P) e um suíno sem patologias pulmonares detectadas (Suíno N). As análises foram realizadas em Python e separadas da seguinte maneira: (i) segmentação da área pulmonar de interesse; (ii) criação de campos vetoriais de movimento (CVMs) através da aplicação do algoritmo de Fluxo Óptico de Farnebäck para cada par de imagens consecutivas; (iii) decomposição dos CVMs em campos de potenciais escalares irrotacional (W) e divergência nula (E) através da Decomposição Discreta de Helmholtz-Hodge (DDHH); (iv) observação ao longo do tempo da localização de valores críticos de W e E nas sequências de imagens de todos os sujeitos para criar um mapa de frequência. Um índice de Pendelluft P_d foi proposto para quantificar a diferença das posições e das magnitudes entre pontos de máximo e mínimo no campo de potencial escalar irrotacional, considerando que esses pontos de extremos têm ligação direta com fenômenos da mecânica pulmonar. O valor de P_d para Suíno P foi aproximadamente 770 vezes maior do que o do Suíno N. Em relação ao sujeito humano, o valor final de P_d para o Humano P foi aproximadamente 8 vezes maior do que o do Humano N. Frente a algumas limitações (e.g. tempo de processamento e definição de parâmetros), o índice de Pendelluft proposto mostrou resultados que permitem identificar o fluxo de ar anormal presente durante essa patologia e reforça a possibilidade de detectar e quantificar esses fenômenos patológicos em tempo real, ajudando a equipe médica e oferecendo mais segurança aos pacientes nas UTIs.

Palavras-chave: Pendelluft, Tomografia de Impedância Elétrica (TIE), Fluxo Óptico, Decomposição Discreta de Helmholtz-Hodge (DDHH).

Sumário

Lista de ilustrações	8	
Lista de tabelas	10	
1	MOTIVAÇÃO E CARACTERIZAÇÃO DO PROBLEMA	11
1.1	Imagens de Tomografia por Impedância Elétrica	14
1.2	Área de interesse	14
1.3	Fluxo Óptico	15
1.4	Decomposição dos Campos Vetoriais de Movimentos	16
1.5	O indicador de Pendelluft	17
2	OBJETIVOS	18
2.1	Objetivos gerais	18
2.2	Objetivos específicos	18
3	MATERIAIS	19
4	SEGMENTAÇÃO DE IMAGENS DE TIE	22
4.1	Introdução	22
4.2	Metodologia	22
4.3	Resultados	24
4.4	Discussão	26
5	COMPARAÇÃO DE MÉTODOS DE FLUXO ÓPTICO	28
5.1	Introdução	28
5.2	Metodologia	28
5.3	Resultados	29
5.3.1	Obtenção dos CVMs	29
5.3.2	Comparação entre algoritmos de FO	31
5.3.3	Comparação dos CVMs de sequência de TIE gerados pelos algoritmos de Horn & Schunck e Farneback	32
5.4	Discussão	35
5.4.1	Para a comparação final	35
5.4.2	Frames de TIE	35
5.4.3	Considerações	36
6	DESENVOLVIMENTO DE UM INDICADOR PARA DETECÇÃO DE PENDELUFT EM SEQUÊNCIAS DE IMAGENS DE TIE	37
6.1	Introdução	37

6.2	Método	39
6.2.1	Extração de potenciais escalares dos CVMs	39
6.2.2	Máximos e mínimos	40
6.2.3	Mapas de frequência	40
6.2.4	Índice proposto para detecção de Pendelluft (P_d)	41
6.3	Resultados	43
6.3.1	Mapas de frequência e ϕ	43
6.3.2	Índice P_d	45
7	APLICAÇÃO DO MÉTODO EM SEQUÊNCIAS DE IMAGENS DE TIE EM HUMANOS	47
7.1	Introdução	47
7.2	Método	47
7.3	Resultados	47
7.3.1	Mapas de frequência e ϕ	47
7.3.2	Índice P_d	48
7.4	Discussão	50
7.4.1	Mapas de frequência e ϕ	50
7.4.2	Índice P_d	53
7.4.3	Considerações finais	55
8	CONCLUSÃO	57
	REFERÊNCIAS	59
A	SOFTWARE DESENVOLVIDO	62
A.1	Códigos principais	62
A.2	Códigos associados	63
A.3	Códigos auxiliares	64
A.4	Arquivos adicionais	64

Lista de ilustrações

Figura 1 – Representação visual de um ciclo respiratório normal.	12
Figura 2 – Representação visual de um ciclo respiratório com Pendelluft.	12
Figura 3 – Representação da segmentação da região pulmonar na imagem de TIE.	14
Figura 4 – Exemplo de representação da aplicação do FO para dois frames consecutivos e seu CVM resultante.	15
Figura 5 – Frame 10 de “Backyard”	16
Figura 6 – Visualização dos CVMs em “Backyard”	16
Figura 7 – Diagrama de segmentação anterior à aplicação do limiar.	23
Figura 8 – Exemplo da aplicação do limiar percentual de segmentação.	23
Figura 9 – Comparação entre dois métodos de segmentação para Suíno N.	25
Figura 10 – Comparação entre dois métodos de segmentação para Suíno P.	25
Figura 11 – Máscara automaticamente segmentada com limiar 13,50% para Humano N	26
Figura 12 – Máscara automaticamente segmentada com limiar 2% para Humano N	26
Figura 13 – Máscara automaticamente segmentada com limiar 13,50% para Humano P	26
Figura 14 – Máscara automaticamente segmentada com limiar 2% para Humano P	26
Figura 15 – Campos Vetoriais de Movimento calculados para Suíno N através de Farnebäck	30
Figura 16 – CVMs calculados pelo método de FO de Farnebäck para dois pares sequenciais de frames do vídeo de TIE do Humano P.	30
Figura 17 – CVMs para frames 47-48 de Suíno N para diferentes métodos de FO.	31
Figura 18 – CVMs para frames 5525-5526 de Humano P para diferentes métodos de FO.	32
Figura 19 – CVMs para frames 8083-8084 de Humano N para diferentes métodos de FO.	32
Figura 20 – Sobreposição dos algoritmos para cálculo de FO em imagens do Suíno N.	33
Figura 21 – Mapas de intensidade para Farnebäck e H&S para o frame 47 de Suíno N.	33
Figura 22 – Sobreposição dos algoritmos para cálculo de FO em Humano P.	34
Figura 23 – Mapas de intensidade para Farnebäck e H&S para o frame 5525 de Humano P.	34
Figura 24 – Representação do campo de potenciais escalares.	37
Figura 25 – Mapas de frequência para o Suíno N	38
Figura 26 – Mapas de frequência gerados para o Suíno N	44
Figura 27 – Mapas de frequência gerados para o Suíno P	45
Figura 28 – Índice de Pendelluft para o Suíno N	46

Figura 29 – Índice de Pendelluft para o Suíno P 46

Figura 30 – Mapas de frequência gerados para o Humano N 47

Figura 31 – Mapas de frequência gerados para o Humano P 48

Figura 32 – Índice de Pendelluft para o Humano N 49

Figura 33 – Índice de Pendelluft para o Humano P 49

Figura 34 – Mapas de frequência para Humano N utilizando $D = 12$ 51

Figura 35 – Mapas de frequência para Humano P utilizando $D = 12$ 52

Figura 36 – Índice de Pendelluft i/a para sujeitos humanos com $D = 12$ 55

Lista de tabelas

Tabela 1 – Características dos dados registrados	19
Tabela 2 – Comparação entre os métodos de FO para diferentes imagens	31
Tabela 3 – Tempo levado para a extração dos campos dos potenciais escalares E e W através da Decomposição Discreta de Helmholtz-Hodge em CVMs de imagens de TIE de dimensões 32 x 32 pixels.	43
Tabela 4 – Valores de ϕ calculados para Suíno N	44
Tabela 5 – Valores de ϕ calculados para Suíno P	45
Tabela 6 – Valores de ϕ calculados para Humano N	48
Tabela 7 – Valores de ϕ calculados para Humano P	48
Tabela 8 – Valores de ϕ calculados para sujeitos Humanos com $D = 12$	52
Tabela 9 – Valores de P_d para suínos	53
Tabela 10 – Valores de P_d para sujeitos humanos ($D = 6$)	54

1 Motivação e Caracterização do Problema

O uso da Ventilação Mecânica abrange uma série de patologias que se expandem entre doenças respiratórias, doenças cardiovasculares, distúrbios neuromusculares entre outras (1). Sua presença é expressiva: em um determinado estudo, uma média de 39% de pacientes de Unidades de Tratamento Intensivo (UTIs) recebiam ventilação mecânica, sendo que a duração mediana de uso desse método foi sete dias (2). Os indicadores mais comuns para o início do uso da ventilação mecânica incluem insuficiência respiratória aguda, exacerbação aguda da doença pulmonar obstrutiva crônica, coma e distúrbios neuromusculares, tais eventos definem o risco e gravidade em que se encontram os pacientes que necessitam de ventilação mecânica (2).

Através dos ventiladores é oferecido um método para assegurar trocas gasosas adequadas nos casos de insuficiência respiratória. Atualmente, os mais modernos permitem que ocorra atividade de respiração espontânea sem a necessidade de suprimi-la, dessa forma somente auxiliam o paciente durante sua respiração, influenciando positivamente o êxito dos tratamentos, reduzindo as complicações e diminuindo o tempo de adaptação à remoção do ventilador (3). Entretanto, as complicações decorrentes da ventilação mecânica têm sido associadas ao colapso pulmonar e à hiper distensão alveolar, sendo tais patologias responsáveis pelo uso das técnicas de titulação cuidadosa da pressão respiratória final positiva, a qual evita e até reverte o colapso, e de manutenção de baixos volumes de correntes (low tidal volumes) para evitar a hiper distensão alveolar (4).

É nesse contexto de UTIs com pacientes em ventilação mecânica (majoritariamente) que abordaremos o Pendelluft. Em 1906, Ludolph Brauer propõe uma explicação para o movimento paradoxo do fluxo de ar em pulmões de pacientes que passaram por pneumotórax¹, onde uma certa quantidade de ar se movimentava entre os dois pulmões ao invés de apresentar o comportamento normal, no qual todo o fluxo de ar é unidirecional em uma dada fase da respiração (exemplificado na Figura 1) (5). Logo, o termo Pendelluft pode ser adaptado livremente do Alemão para “Ar em Pêndulo”, referenciando o movimento “pendular” inter-pulmões. Tal patologia pulmonar é definida como ventilação alveolar assíncrona e é causada por constantes temporais regionais diferentes, em casos de doenças obstrutivas pulmonares, ou variações da pressão pleural dinâmica em casos de respiração espontânea em pacientes com um pulmão prejudicado (6), sendo especificamente o fluxo de ar de regiões pulmonares não dependentes para dependentes (exemplificado na Figura 2) (7).

¹ O pneumotórax é uma condição caracterizada pelo extravasamento de ar para o espaço pleural e, eventualmente, o colapso pulmonar devido à perda da pressão negativa na cavidade pleural causada pela retenção de ar nesse espaço.

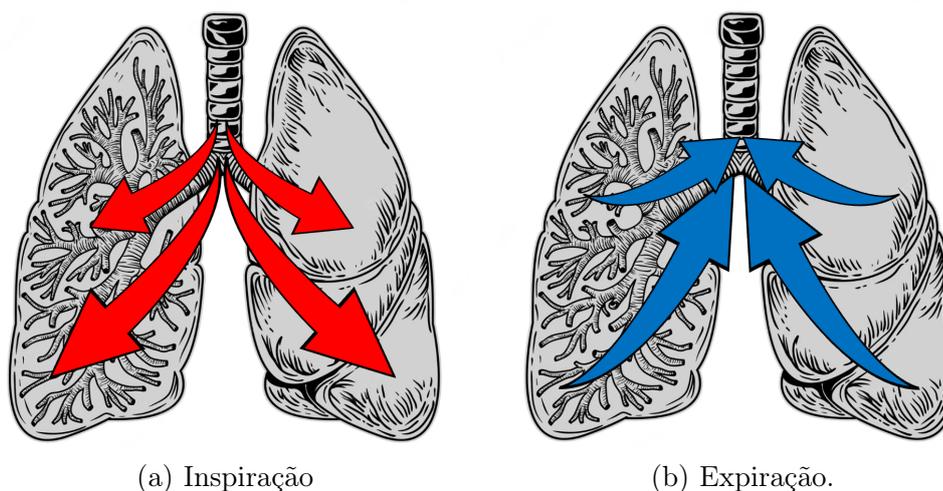


Figura 1 – Representação visual de um ciclo respiratório normal, onde as setas vermelhas indicam o fluxo de ar oxigenado e as azuis o fluxo de ar com baixa saturação de oxigênio.

Fonte: Adaptado de freepik.

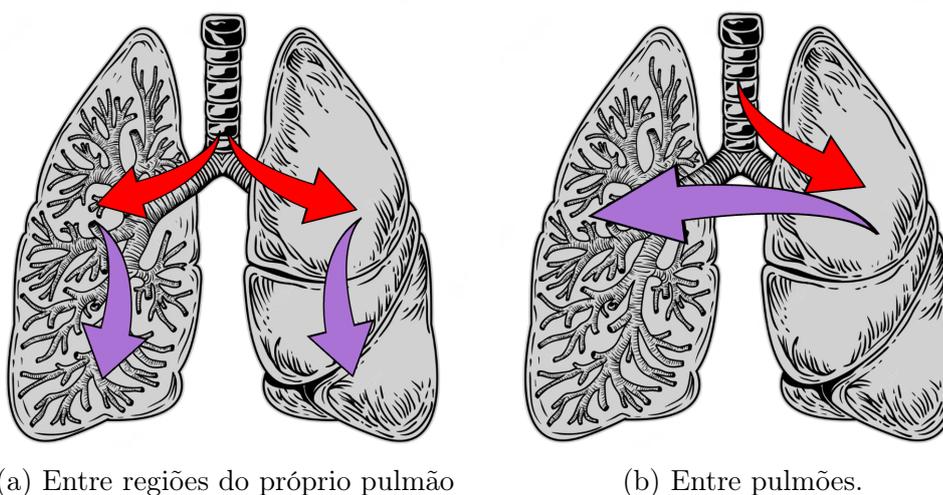


Figura 2 – Representação visual de um ciclo respiratório com Pendelluft. Onde a seta lilás representa o fluxo de ar anormal, com saturação desconhecida de oxigênio.

Fonte: Adaptado de freepik.

Por ser uma patologia que pode acarretar danos maiores aos pacientes já fragilizados (7) (como super extensão local, recrutamento de volume corrente e inflamação), sua detecção é de suma importância para que seu tratamento, ou estratégias de ventilação, seja ajustado e aplicado de acordo. Historicamente, vários métodos foram empregados para tentar identificar as ocorrências de Pendelluft, dentre eles podemos citar as imagens por ressonância magnética e a tomografia computadorizada, que retornavam informações indiretas das mecânicas regionais pulmonares, e métodos como microscopia de campo escuro, oximetria multi espectral e tomografia por emissão de pósitrons, que tentavam capturar medidas regionais diretas do Pendelluft (6). Entretanto, tais técnicas se mostraram de

utilização difícil, uma vez que não poderiam ser utilizadas continuamente para identificar e medir o Pendelluft em um paciente acamado em ventilação mecânica.

A técnica de imagem de Tomografia por Impedância Elétrica (TIE) traz um grande potencial para a detecção de Pendelluft. Ela é uma modalidade de imagem com mais de 30 anos de desenvolvimento e que pode monitorar pacientes em ventilação mecânica usando um equipamento portátil que não utiliza radiação ionizante, é não-invasivo e não exige o deslocamento do paciente para outra sala já que pode ser usado diretamente no leito por longos períodos (8). Seu funcionamento consiste no uso de uma cinta ao redor do tórax contendo um conjunto de eletrodos que ficam em contato com a pele. Uma baixa corrente é sequencialmente aplicada por cada eletrodo e o potencial elétrico gerado entre cada par é medido, permitindo que a distribuição de resistência seja calculada. Faz-se uso da propriedade de diferentes valores resistivos para cada tecido biológico, permitindo-se medir a impedância na região pulmonar e, uma vez que o ar tem alta resistência, identificar o fluxo de ar durante os momentos de inflação e deflação pulmonar (9).

Atualmente a TIE é estudada para ser utilizada na identificação de edemas pulmonares, pneumotórax, parâmetros específicos por paciente para ventilação mecânica e na quantificação de doenças pulmonares (9). Seu uso para a identificação de Pendelluft é estudado, porém os recursos disponíveis atualmente não são confiáveis ou suficientes para uma medição segura da patologia (6), sendo que o monitoramento contínuo para se tentar identificar uma patologia imprevisível em pacientes em ventilação mecânica é dispendioso e não compatível com a realidade de uma equipe médica em uma UTI.

O fenômeno de Pendelluft é classicamente identificado em pacientes paralisados por meio de uma manobra de oclusão no final da inspiração² (11). Recentemente, a disponibilidade da TIE à beira do leito permitiu que pesquisadores demonstrassem a presença de Pendelluft durante a ventilação mecânica assistida. Foi verificado que o fenômeno de pendelluft ocorre no momento da transição da expiração para a inspiração (12). Este fenômeno requer uma ferramenta de monitoramento regional com alta resolução temporal, tornando a TIE uma escolha ideal (12).

Ling Sang *et al* em (6) determinam uma poderosa ferramenta para quantificar os fenômenos de Pendelluft em vídeos de TIE avaliando por meio do deslocamento de fase regional (definido como a diferença de tempo entre as curvas de impedância globais e regionais) e diferenças de amplitude (definidas como a diferença de impedância entre a soma de todas as variações regionais de volume corrente e a variação global de volume corrente). Além da observação visual dos vídeos de TIE, essa técnica pode ser considerada como a mais atual para a identificação de Pendelluft (13).

Dada a gravidade dessa patologia e a dificuldade em identificá-la, existe a preocupação em relação a um método capaz de realizar automaticamente a detecção em tempo real

² Manobra de oclusão da via aérea no final da inspiração: um método para avaliar a pressão desenvolvida pelos músculos inspiratórios em pacientes com lesão pulmonar aguda sob pressão de suporte (10).

de ocorrências de Pendelluft em imagens de Tomografia por Impedância Elétrica. O método proposto por Fidelis, V. et al em “Extraction of Pendelluft Features from Electrical Impedance Tomography Images” (14) define parâmetros importantes para a identificação de Pendelluft em imagens de TIE, entretanto, por ter um custo computacional elevado, necessita de otimizações e adaptações para se tornar uma opção confiável para a detecção de Pendelluft em tempo real (14).

Para abordarmos o método proposto por Fidelis *et al* (14), faz-se necessário apresentar pontos cruciais da metodologia utilizada, a qual também foi largamente utilizada neste estudo.

1.1 Imagens de Tomografia por Impedância Elétrica

A Tomografia por Impedância Elétrica (TIE) é uma modalidade de técnica de imagem, como mencionado anteriormente, que torna possível a visualização do fluxo de ar no interior do pulmão devido às diferenças entre as características resistivas do ar e dos tecidos biológicos. Ao movimento realizado pelo ar dentro de pulmão se atrela padrões saudáveis e patológicos, que podem ser identificados visualmente por especialistas pneumologistas através da análise das imagens de TIE.

1.2 Área de interesse

As imagens de TIE contemplam não só áreas referentes ao pulmão, logo torna-se essencial que a região pulmonar a ser analisada seja definida e segmentada para que os métodos avaliativos empregados de forma automática “saibam” em qual região das imagens os dados são relevantes. Fidelis *et al* realizam a segmentação através do método de Otsu: uma seleção baseada em limiar em histogramas de nível de cinza (15). Neste estudo foi desenvolvido um método semi-automático para segmentação da área pulmonar das imagens de TIE.

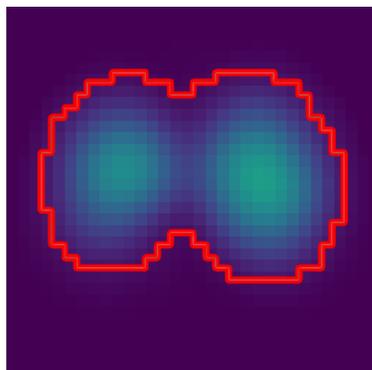


Figura 3 – Representação da segmentação da região pulmonar na imagem de TIE. O traço vermelho representa as bordas da área de interesse.

Fonte: do autor.

1.3 Fluxo Óptico

Para se tornar possível entender de forma objetiva o movimento do fluxo de ar nos pulmões, pode-se empregar o Fluxo Óptico (FO) às sequências de imagens de TIE. Essa técnica pode ser utilizada para determinar o movimento de objetos em uma sequência de quadros, ou vídeo, através da análise de dois quadros (frames) consecutivos e gerar uma estimativa da velocidade aparente para cada padrão de brilho da imagem. A estimativa das velocidades conta com duas matrizes bidimensionais de dimensões iguais às da imagem: u , que contém o valor do deslocamento horizontal estimado para cada pixel; e v , que contém o valor do deslocamento vertical estimado para cada pixel. A soma vetorial das matrizes u e v representa conceitualmente um Campo Vetorial de Movimento (CVM) denso que contabiliza, para todos os pixels de uma imagem, não só a magnitude do movimento, mas também a direção e sentido desse deslocamento (16). Um exemplo simples de representação da aplicação do FO e o CVM resultante está disponível na Figura 4, onde existe o deslocamento do quadrado entre os dois frames e em 4c é exibido o deslocamento que aquele conjunto de pixels (ou objeto) sofrerá.

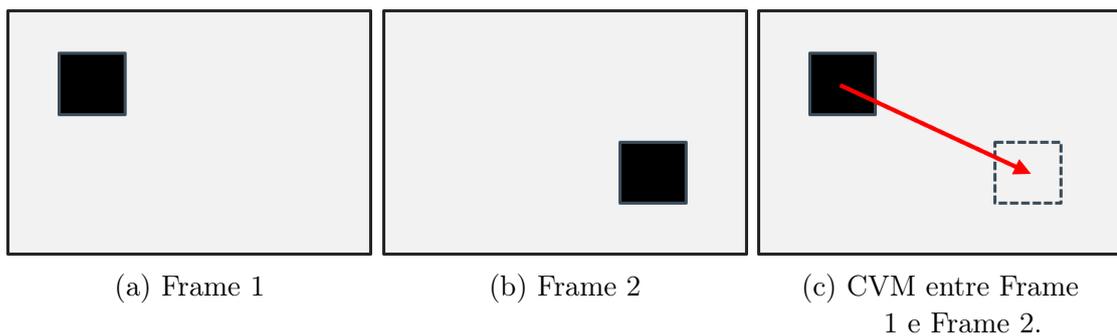


Figura 4 – Exemplo de representação da aplicação do FO para dois frames consecutivos e seu CVM resultante.

Fonte: do autor.

Para mais um exemplo de visualização de CVM, a Figura 5 e seu frame posterior (ambos provenientes de MiddleBuryVision³) foram analisados através do cálculo de FO de Farneback (18), o que resultou no CVM representado pelas setas vermelhas na Figura 6.

³ (17) disponível em <<https://vision.middlebury.edu/flow/>>



Figura 5 – Frame 10 de “Backyard”.
Fonte: The Middlebury
Computer Vision



Figura 6 – Visualização dos CVMs
em “Backyard”. Fonte:
do autor.

Para o estudo de Fidelis *et al*, foi adotado o algoritmo de FO de Horn & Schunck (16). Esse método, desenvolvido décadas atrás, teve um papel importante na história da pesquisa de fluxo óptico. Entretanto, como acontece com qualquer método inicial, sua confiabilidade pode ser influenciada por certas limitações e pressupostos inerentes ao seu design. Desde seu desenvolvimento, o campo de fluxo óptico evoluiu significativamente, contando com novos algoritmos projetados para lidar com algumas das limitações dos métodos mais antigos. Para este estudo o método de Farnebäck foi adotado por seu custo computacional reduzido e resistência ao ruído (19). Comparações foram realizadas entre ambos, a fim de determinar a confiabilidade e adequação de cada para o estudo proposto.

1.4 Decomposição dos Campos Vetoriais de Movimentos

Apesar da objetividade dos CVMs em indicar o movimento de cada pixel entre dois frames, é possível extrair ainda mais informações sobre esses movimentos através de sua decomposição em uma parte irrotacional (vetores sem rotação), uma parte divergência nula (sem fontes ou ralos) e uma parte harmônica. Tais partes podem ser obtidas a partir da Decomposição Discreta de Helmholtz-Hodge (DDHH), o algoritmo mais custoso temporalmente neste estudo e que até o momento inviabiliza sua utilização em tempo real, e ainda podem ser exploradas para estudar as características da incompressibilidade e vorticidade do fluxo de ar, tais como fontes, ralos e vórtices, pontos críticos de interesse para o estudo de Pendelluft. As partes extraídas podem ser utilizadas a partir do entendimento de seus pontos de máximos e mínimos, que podem significar, espacialmente, os pontos onde o ar entra e sai do pulmão durante a respiração.

1.5 O indicador de Pendelluft

Por fim, um indicador patológico busca representar as instâncias da doença de forma objetiva através de valores numéricos. Para Fidelis *et al*, o indicador patológico de Pendelluft, a medida quantitativa ϕ , era um representativo da assimetria entre os pontos de máximos e mínimos das partes extraídas dos CVMs, e comporta-se-ia retornando valores elevados caso o pulmão não apresentasse a doença e valores próximos de 0 para os casos de Pendelluft, onde a mecânica respiratória se encontrasse alterada. A medida de ϕ retornou valores compatíveis para os suínos, porém ao ser aplicada em dados humanos não manteve a confiabilidade necessária para uma medida significativa da patologia.

2 OBJETIVOS

2.1 Objetivos gerais

Criar um método capaz de identificar Pendelluft em tempo real, de modo automático, através de sequências de imagens de TIE para prevenir possíveis danos pulmonares e auxiliar decisões clínicas, com foco em pacientes em Unidades de Tratamento Intensivo (UTI) em ventilação mecânica.

2.2 Objetivos específicos

1. Portar os códigos de *Extraction of Pendelluft Features from Electrical Impedance Tomography Images* (14) de MATLAB para Python;
2. Definir um método para segmentação automática da área pulmonar em imagens de TIE;
3. Investigar as diferenças de resultados decorrentes do fluxo óptico de Horn & Schunck e Farneback;
4. Analisar os indicadores de Pendelluft resultantes de duas técnicas diferentes para a identificação de Pendelluft em sequências de TIE e verificar se seus resultados são capazes de distinguir entre casos com Pendelluft e casos que não apresentam a patologia.

3 MATERIAIS

Todos os dados utilizados no estudo presente são os mesmos que utilizados em Fidelis *et al* (14) e, para fins de especificação, são descritos novamente de forma resumida a seguir. Igualmente alguns dos arquivos descritos no capítulo “Scripts e arquivos” têm a mesma origem.

Foram fornecidos pela Faculdade de Medicina da Universidade de São Paulo (FM-USP) a partir de dois estudos anteriores: (I) “Titulação de PEEP guiada pela tomografia de impedância elétrica por manobra rápida e lenta e estabilidade pulmonar com estratégia protetora de ventilação mecânica em um modelo suíno de Síndrome do Desconforto Respiratório Agudo” (20) e (II) “Construção de um banco de dados de tomografias computadorizadas torácicas para aplicação em tomografia de impedância elétrica: um estudo retrospectivo”, ambos submetidos e aprovados pelo Comitê de Ética em Pesquisa.

Os dados foram registrados por um sistema de TIE (1800 Enlight, Timpel, São Paulo, Brasil) com 32 eletrodos e frequência de aquisição de 50 imagens por segundo. O formato de dados usado no registro foi de arquivos de texto simples (.txt), com colunas correspondentes aos pixels da imagem e linhas aos instantes de tempo durante a aquisição. Existem um total de 1024 colunas de registro, cada uma correspondendo a um elemento da matriz de pixels, de tamanho 32 linhas por 32 colunas. Os valores dos pixels representam a variação percentual da resistividade em comparação com um instante de referência. Os arquivos de texto foram exportados de um software desenvolvido no Labview (Labview 7.4, National Instruments, EUA). A análise de imagem proposta na seção de metodologia foi realizada em Python versão 3.9.16 usando um computador pessoal (Lenovo g40-70, Intel(R) Core(TM) i3-4005U CPU @ 1.70GHz, 12 GB de RAM, Windows 10 Pro 22H2). As características dos sujeitos e dos dados registrados são apresentadas na Tabela 1.

Tabela 1 – Características dos dados registrados

	Suíno P	Suíno N	Humano P
Tipo	Animal	Animal	Humano
Condição Pulmonar	Pendelluft	Saudável	Pendelluft
Tempo entre frames Δt (s)	0,02	0,02	0,02
Colunas (pixels da imagem)	1024	1024	1024
Linhas (número de frames)	245	756	1072
Número de ciclos respiratórios	5	5	5
Frequência de respiração (respirações/minuto)	61,22	19,84	14,00
Tempo de registro (s)	4,90	15,12	21,44

Inicialmente, os arquivos de texto contendo os registros de TIE foram carregados no código Python (escrito por Prof. Dr. Erick Dario León Bueno Camargo em MATLAB e portado pelo autor para Python, com adaptações do código de DHHD de Prof. Dr. John Andrew Sims). Para todos os sujeitos, os dados foram formatados de um arquivo de texto

2D para uma matriz 3D (matriz 2D por cada imagem + tempo): cada imagem na dimensão de 32 por 32 pixels. Foram rotacionadas para exibição em orientação convencional de modalidades de imagem: o tórax direito na parte esquerda da imagem e o lado anterior no topo.

Os dados dos animais foram extraídos de dois suínos da raça Landrance de aproximadamente 35 kg e até 1,1 m de comprimento, um com pendelluft (Suíno P) e outro sem patologias pulmonares detectadas (Suíno N), ambos sob ventilação controlada. Deve-se observar que o Suíno P apresentava falta de ar e, portanto, uma maior frequência respiratória. Como 5 ciclos respiratórios foram gravados para cada suíno, o número total de frames registrados para o Suíno P foi menor do que para o Suíno N.

Os dados humanos foram extraídos de um sujeito do sexo masculino que alternava entre momentos de Pendelluft. Devido à imprevisibilidade do pendelluft, um pneumologista experiente determinou o momento exato na gravação no qual o fenômeno pode ser observado. Diferente dos suínos, o sujeito humano não estava em ventilação controlada, apresentando pendelluft por meio de respiração espontânea sob ventilação assistida.

Detalhes de implementação sobre o software desenvolvido podem ser encontrados no Apêndice

Nota do Autor

Devido à natureza extensa deste trabalho, ou melhor, à natureza de estender um trabalho existente em várias direções, foi decidido-se usar um formato de capítulos para escrever este Trabalho de Graduação. A estrutura dos capítulos a seguir é baseada nos objetivos específicos, listados no Capítulo 2 deste texto.

4 Segmentação de imagens de TIE

4.1 Introdução

A análise do pendelluft exige que a área dos pulmões esteja corretamente estabelecida nas imagens de TIE, dessa maneira é possível direcionar os algoritmos a utilizar somente a região pulmonar para explorar os fenômenos de interesse. Portanto, a segmentação dessa região de interesse fornece uma região de atuação do algoritmo de análise de Pendelluft limitada à região do pulmão nas imagens de TIE, assim excluindo fenômenos que possam ocorrer em outras regiões das imagens.

Para os testes, foram utilizadas as sequências de imagens de dois suínos: um com respiração normal “Suíno N” e um com pendelluft “Suíno P”.

Outros métodos encontrados na literatura abordam a segmentação automática da região pulmonar em vídeos de TIE utilizando diferentes técnicas, dentre eles:

- B. Grychtol *et al* empregam a comparação de coeficientes de regressão linear entre o sinal de impedância individual de cada pixel e o sinal médio da imagem completa, levando em consideração o registro da manobra pressão-volume antes da indução da lesão pulmonar (21);
- A. Zifan *et al* exploram a utilização de um filtro Kalman e um modelo estatístico 2D do formato pulmonar, obtido através de imagens de Tomografia Computadorizada de 50 pacientes, para identificar a região pulmonar nas imagens de TIE (22);
- Y.-F. Ko e K.S. Cheng baseam-se em deep-learning, especificamente a rede neural convolucional U-net, para transformar a imagem original de TIE em uma imagem da região pulmonar e refinar a distribuição de condutividade da imagem original (23).

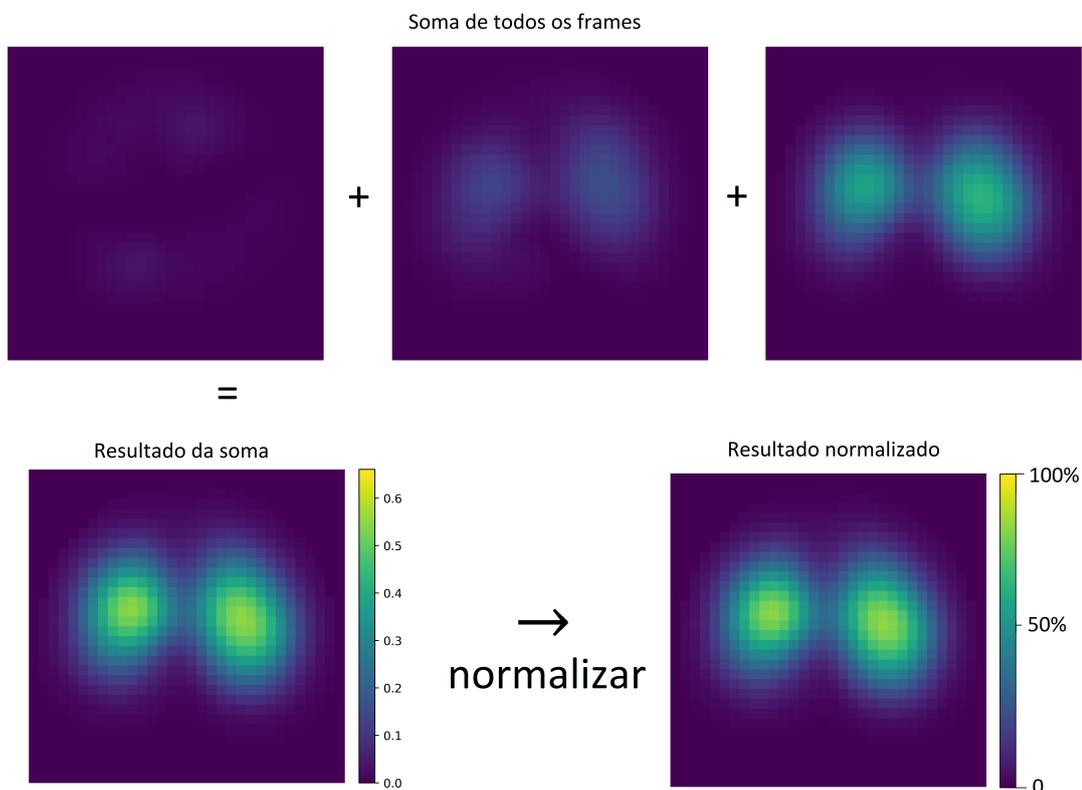
4.2 Metodologia

Devido às variações anatômicas naturalmente presentes dentre diferentes pacientes, foi proposto um método de segmentação semiautomática da área do pulmão, baseando-se na intensidade de cada pixel e o conhecimento que a área externa ao pulmão será, teoricamente, desprovida de qualquer sinal em comparação às áreas com fluxo de ar.

Logo, para cada vídeo, ou sequência de imagens, a soma de todos os frames resultou em uma matriz correspondente à representação da soma das intensidades para cada pixel através do vídeo ("matriz-soma"). Faz-se a normalização, associando o valor 1 ao pixel mais intenso da "matriz-soma", o que permite a aplicação adequada e reproduzível de um limiar em percentual, gerando a “matriz-normalizada” (sequência de operações representadas na Figura 7. Assim, uma matriz booleana de iguais dimensões é gerada, considerando

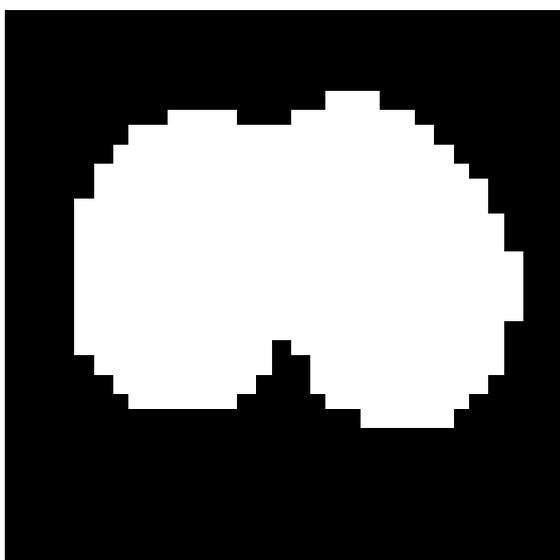
True onde os valores da “matriz-normalizada” eram iguais ou maiores em relação ao limiar estabelecido e *False* para os valores abaixo do limiar, resultando em uma máscara binária da região de maior atividade do pulmão (Figura 8).

Figura 7 – Diagrama de segmentação anterior à aplicação do limiar



Fonte: Do autor.

Figura 8 – Exemplo da aplicação do limiar percentual de 13,50% na sequência Suíno N.



Fonte: Do autor.

Um código auxiliar, “*Mask_tester.py*” (Apêndice A), foi criado e utilizado para entender e estabelecer o melhor limiar para a geração da máscara para os vídeos de TIE dos suínos analisados. Na referência (14), uma máscara foi manualmente segmentada para análise a partir do frame entendido como o de maior volume pulmonar, e o código mencionado realiza a avaliação da máscara automaticamente calculada através de um critério pré-estabelecido de tolerância de erro entre ela e a manualmente segmentada. A comparação foi realizada simultaneamente por dois métodos: similaridade por números de pixels, o qual verificava se a máscara calculada contava com a mesma quantidade de pixels denominados *True* tal qual a manualmente segmentada, e similaridade por localidade, que confere quantos pixels da máscara calculada ocupam a mesma posição que os pixels da máscara manual.

Simultaneamente, o centro dos pulmões é identificado automaticamente através da soma dos valores dos pixels por coluna da “matriz-normalizada”. Em seguida, é realizada a análise de proximidade das ilhas de mínimos ao centro da imagem e, eventualmente, do menor valor da ilha identificada como pertencente ao centro da imagem.

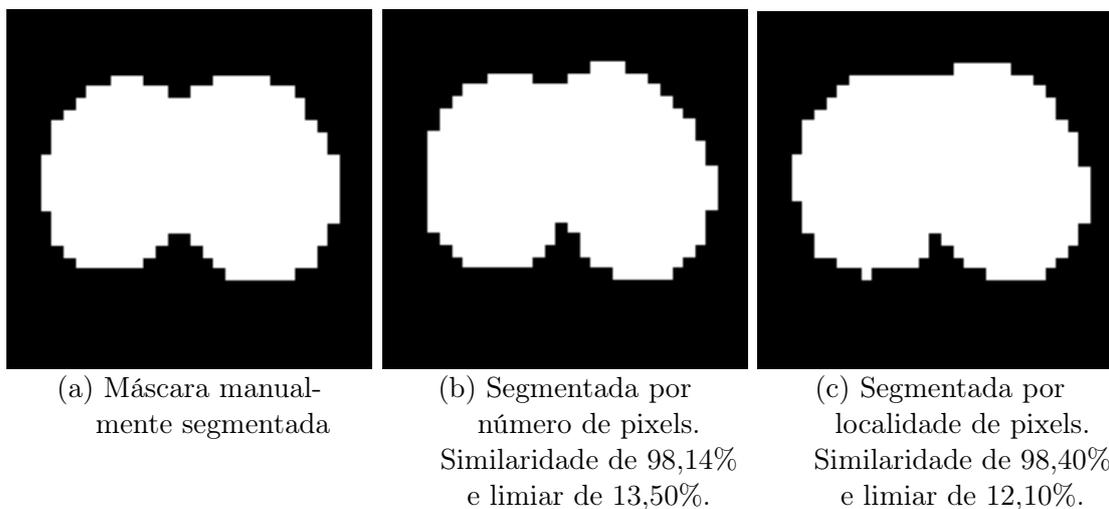
Para os dados humanos, o vídeo foi separado em duas partes: Humano N, que se refere à parte do vídeo onde não ocorre pendelluft (frames 8.000 a 10.000), e Humano P, referente aos frames onde foi identificado pendelluft (frames 5.500 a 7.500).

A segmentação automática durante os códigos principais é invocada em “Code_2.py”, através da chamada do código associado “Automatic_Segmentation.py”, sendo definido dentro do código principal o valor do limiar. Um arquivo, nomeado “LungMask.mat”, é salvo para posteriormente ser carregado em “Code_3.py” para as análises do índice de pendelluft. (Apêndice A)

4.3 Resultados

Através do uso de *Mask_tester.py* pôde-se previamente estabelecer qual seria o melhor limiar para a segmentação da região pulmonar para os dados dos suínos, estabelecendo-o em 13,50%. A Figura 9 abaixo corresponde ao teste comparativo entre a máscara calculada e a máscara manual para o Suíno N.

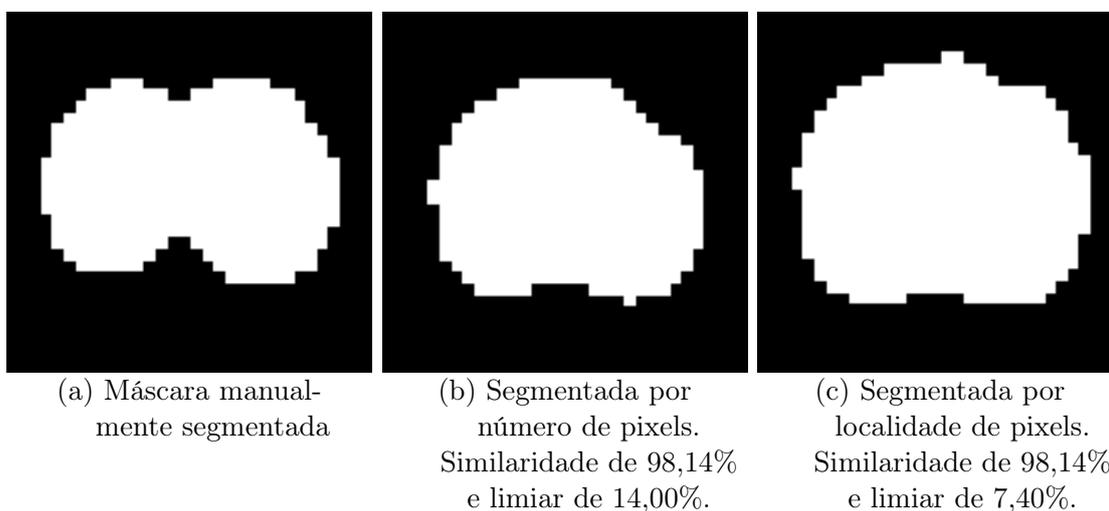
Figura 9 – Análise comparativa entre máscara manualmente segmentada (9a) e a máscara calculada através de dois métodos para o Suíno N (9b e 9c).



Fonte: do autor.

Ao realizar a mesma avaliação para os dados do Suíno P é possível perceber abaixo na Figura 10 um formato anormal para o pulmão. Entretanto o valor do limiar é próximo do estabelecido para o Suíno N, dado também que o último é considerado saudável, podemos considerar o limiar de 13,50% para seguir com as demais análises.

Figura 10 – Análise comparativa entre máscara manualmente segmentada (10a) e as máscaras calculadas por dois métodos para o Suíno P (10b e 10c).



Fonte: do autor.

Já para os dados humanos, o limiar encontrado anteriormente resultou em máscaras inconsistentes com o formato pulmonar normalmente observado em imagens de TIE, sendo necessário diminuir o limiar para a obtenção de máscaras mais adequadas.

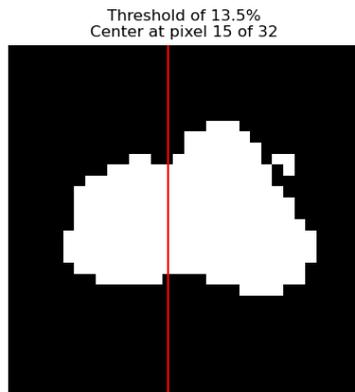


Figura 11 – Máscara automaticamente segmentada com limiar 13,50% para Humano N

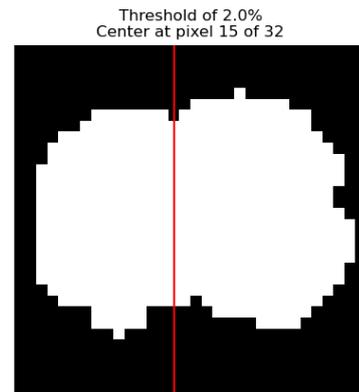


Figura 12 – Máscara automaticamente segmentada com limiar 2% para Humano N

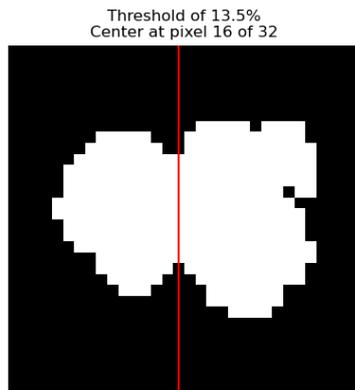


Figura 13 – Máscara automaticamente segmentada com limiar 13,50% para Humano P

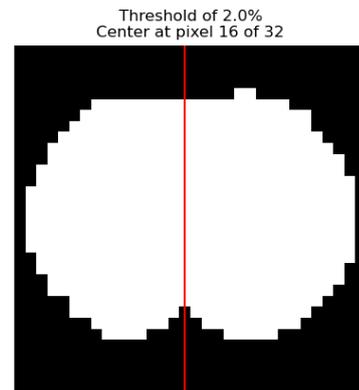


Figura 14 – Máscara automaticamente segmentada com limiar 2% para Humano P

4.4 Discussão

A metodologia apresentada oferece resultados eficientes para a segmentação semiautomática da região pulmonar em vídeos de TIE para análise offline. Seu maior empecilho está relacionado à determinação manual do mais adequado limiar de intensidade na “máscara-normalizada”, o que dificulta a aplicação 100% automática do algoritmo, já que tal limiar pode variar entre pacientes.

A aplicação de uma máscara base padrão (talvez universal para TIE) para automaticamente detectar o melhor limiar, feito manualmente neste Trabalho de Graduação por meio do código auxiliar “*Mask_tester.py*”, é uma alternativa que dará mais autonomia ao algoritmo, aliviando a carga de trabalho da equipe hospitalar e trazendo a análise de pendelluft mais próxima de situações em tempo real. Dessa maneira, o algoritmo

de adequação do limiar para se obter uma máscara mais próxima possível da máscara carregada poderá realizar a comparação com uma máscara estabelecida como a mais adequada à região pulmonar nas imagens de TIE. Adicionalmente, a metodologia empregada é consideravelmente rápida e leva menos de 6 segundos para calcular a máscara com um limiar estabelecido para uma sequência de 2000 imagens. Para o vídeo completo de 10.000 frames, o algoritmo realizou o cálculo em menos de 6 segundos.

5 Comparação de métodos de fluxo óptico

5.1 Introdução

O fluxo óptico (FO) é uma técnica que descreve a distribuição das velocidades aparentes dos padrões de brilho em uma sequência de imagens em movimento, e pode ser utilizado para determinar o movimento de objetos (16). O FO realiza o mapeamento das mudanças de brilho entre os pixels de um frame para outro por meio de um campo de vetores de deslocamento, ou campo vetorial de movimento (CVM) (18). Nas imagens de TIE pulmonar considera-se que as mudanças na resistividade e, portanto, nos valores de cada pixel são causadas pela passagem de ar, logo, torna-se possível identificar esse fluxo entre os frames através das velocidades de movimento dos pixels obtidas por meio da aplicação do fluxo óptico.

Uma das limitações dos métodos de fluxo óptico para estimativa do deslocamento é a pressuposição que as intensidades dos pixels analisados permanecem constantes durante toda a sequência de imagens. Por conta disso, alguns fenômenos na imagem como o desaparecimento (diminuição do brilho) ou o surgimento de elementos (intensificação do brilho) podem ocasionar estimativas imprecisas de movimento, levando a artefatos e irregularidades no Campo Vetorial de Movimento (24).

Mais de um método computacional para o cálculo do fluxo óptico existem atualmente, e dentre eles pode-se citar o algoritmo de Horn e Schunck (16) e de Farnebäck (18). Em (14) é usado o método de Horn & Schunck (H&S), já que uma implementação das equações de FO linear de H&S já existia para o MATLAB. Para este trabalho foi utilizado o método de Farnebäck (Fb), que já se encontra integrado à biblioteca OpenCV no Python (25) e apresenta alto grau de confiabilidade e resistência à ruído (18). Concomitantemente, comparações entre os dois métodos foram realizadas através dos próprios registros de TIE e estão disponíveis na subseção 5.3.2.

Uma diferença explícita dentre os usos de técnicas de FO está no uso para monitoramento por câmeras de vídeo (como em (19), para um grupo de pessoas) e no uso para análise de mecânica dos fluidos, onde os algoritmos não tem como base uma textura com variadas intensidades de pixels, mas sim imagens com menos características. No estudo de Mendes *et al* (26) foi encontrado que o algoritmo de FO de Farnebäck atuou melhor, em relação ao de Horn & Schunck, para imagens sintéticas de diferentes tipos de fluxos estudados em mecânica dos fluidos.

5.2 Metodologia

Aplica-se o cálculo de FO de Farnebäck para uma sequência de imagens da seguinte maneira: o cálculo é realizado por par de frames e calcula o CVM entre um frame específico

e o imediatamente anterior, resultando em duas matrizes u e v , ambas de dimensões iguais às das imagens e representando, respectivamente, a magnitude da velocidade do pixel nas direções x e y de um frame para outro. Ao fim dos cálculos para uma sequência de N frames, temos $N - 1$ matrizes u e v , resultando em um conjunto de CVMs nos quais as setas em cada pixel representam a soma vetorial dos vetores u e v , ou seja, o deslocamento estimado de cada pixel entre o primeiro e o segundo frame. A este ponto ainda não levamos em consideração as máscaras calculadas automaticamente.

A metodologia especificamente relacionada ao cálculo de Farneback e a aplicação do algoritmo em Python podem ser encontrados, respectivamente, em (18) e (25).

O conjunto de CVMs, assim como as imagens carregadas do arquivo de texto, são salvos em um arquivo “.mat”¹ para posteriormente serem carregados pelo restante dos códigos principais ou códigos auxiliares.

Para realizar a comparação entre o tempo levado por cada método, foi criado o código auxiliar “*OF_time_comparison.py*”, que carrega duas imagens selecionadas pelo usuário, calcula o FO por Farneback e por H&S² e mostra o tempo levado por cada um. Ele também faz a exibição lado a lado das setas de cada método, portanto foi empregado para as imagens de teste coletadas em Middlebury.

O algoritmo de H&S presente no script de Fidelis *et al* (14) também devolve matrizes u e v , com a mesma representação por matrizes de Farneback, tornando, assim, mais fácil e objetiva a comparação entre ambos métodos. Outro código auxiliar nomeado “*OF_visual_comparison.py*” carrega dois arquivos “.mat” contendo os conjuntos de CVMs para cada método e exibe uma imagem do frame selecionado com setas sobrepostas, correspondentes à representação visual vetorial dos métodos empregados.

5.3 Resultados

5.3.1 Obtenção dos CVMs

As imagens geradas em “*Code_1.py*” (disponível no Apêndice A), e suas respectivas representações dos CVMs, são salvas em uma pasta no mesmo diretório do arquivo de texto dos dados de TIE. As imagens para o Suíno N são exibidas abaixo, na Figura 15. O frame 20 representa um momento intermediário da inspiração, enquanto o frame 40 equivale ao momento no qual os pixels no interior do pulmão exibiam a maior intensidade para esse ciclo respiratório, ou seja, representa o momento de inspiração máxima.

¹ Os arquivos .mat guardam dados formatados que podem ser carregados e editados pelo MATLAB ou Python, o que possibilita armazenar e trocar variáveis (como matrizes) entre diferentes códigos e até acessá-las após a realização das análises.

² Código adaptado em Python disponível em <<https://github.com/lmiz100/Optical-flow-Horn-Schunck-method>>).

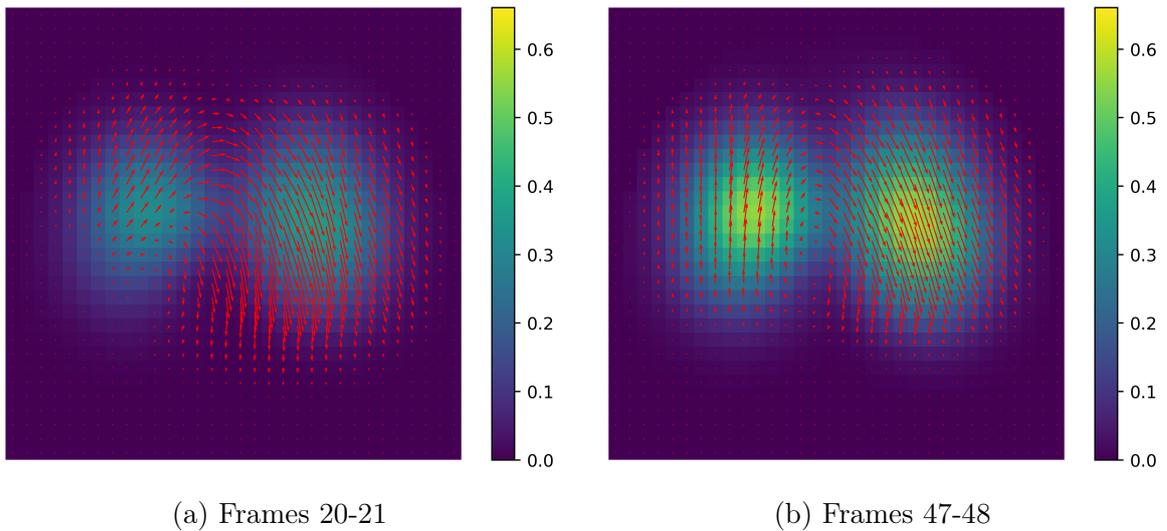


Figura 15 – Campos Vetoriais de Movimento (setas vermelhas) calculados pelo método de Fluxo Óptico de Farneback para dois pares de frames do vídeo de TIE do Suíno N, sobrepostos na representação colorida do sinal de TIE pulmonar. Escala em barra para a intensidade de brilho do pixel.

Os dados para o sujeito Humano também passaram pelo mesmo processo tanto para a sequência com Pendelluft quanto para a sequência Normal. A seguir, a Figura 16 mostra dois CVMs de uma sequência consecutiva de pares escolhidos do Humano P. Nota-se uma convergência do fluxo de ar para uma extremidade do pulmão e que a intensidade dos pixels do lobo esquerdo permanece maior durante toda a sequência de imagens enquanto que para a Figura 15b

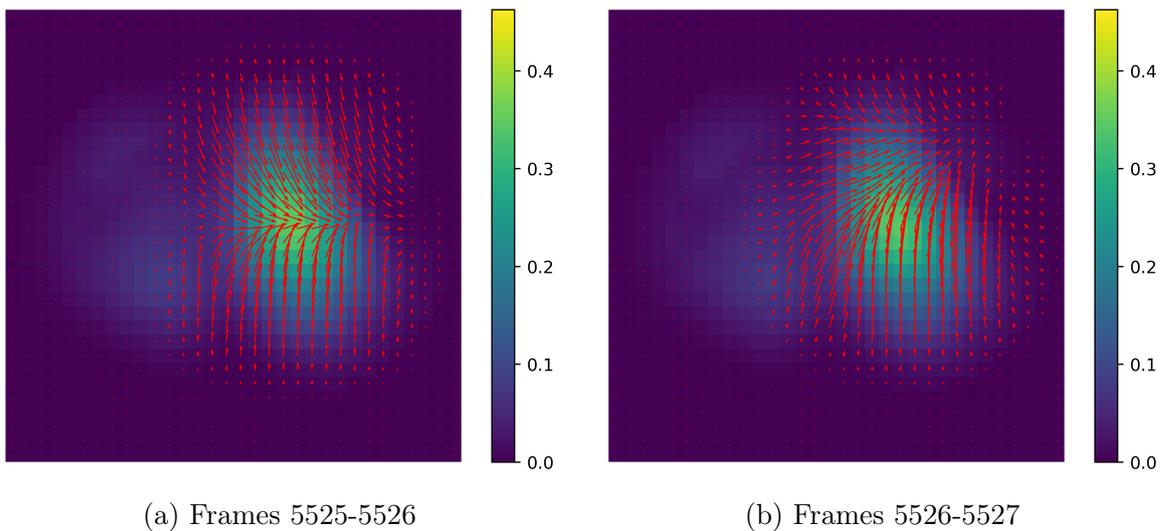


Figura 16 – CVMs calculados pelo método de FO de Farneback para dois pares sequenciais de frames do vídeo de TIE do Humano P.

5.3.2 Comparação entre algoritmos de FO

Já em termos de comparação entre o tempo para cada método podemos ver a diferença expressiva entre as duas aplicações. Abaixo, a tabela 2 traz uma relação entre pares de imagens analisados com o código “*OF_time_comparison.py*” e logo em seguida, as figuras para comparação.

Tabela 2 – Comparação entre os métodos de FO para diferentes imagens

Imagem	Dimensões (pixel)	Tamanho (kb)	Tempo H&S (s)	Tempo Farneback (s)	Figura
Suíno N (frames 47-48)	32 x 32	1,28	0,04573	0,00147	17
Humano N (frames 8083-8084)	32 x 32	0,94	0,02425	0,00135	19
Humano P (frames 5525-5526)	32 x 32	1,00	0,02489	0,00128	18

Logo a seguir, na Figura 17 para o Suíno N, a fonte de movimento divergente (o centro) não pode ser distinguido no FO de Farneback (Figura 17a). Entretanto, através do algoritmo de H&S ele se torna nítido no pulmão à esquerda (identificado pelo círculo amarelo na Figura 17b), e esse fenômeno de aparição errática entre diferentes métodos de FO se repete na comparação feita na Figura 18 para o Humano P. Mais adiante, na Figura 19 para o Humano N, é possível perceber que os centros foram computados em locais diferentes do lobo pulmonar, sendo mais à direita em Farneback e mais central ao lobo em H&S.

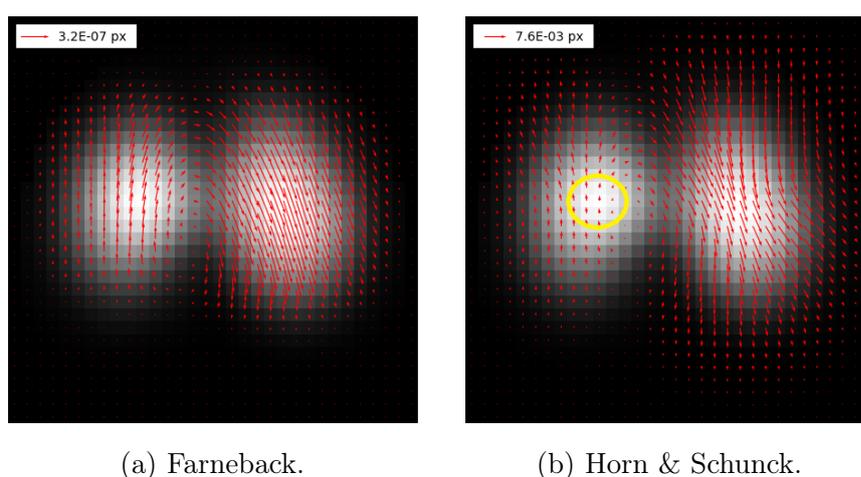
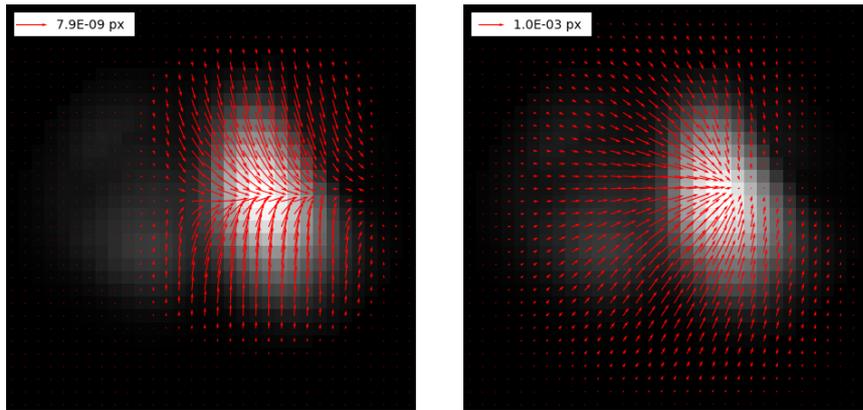


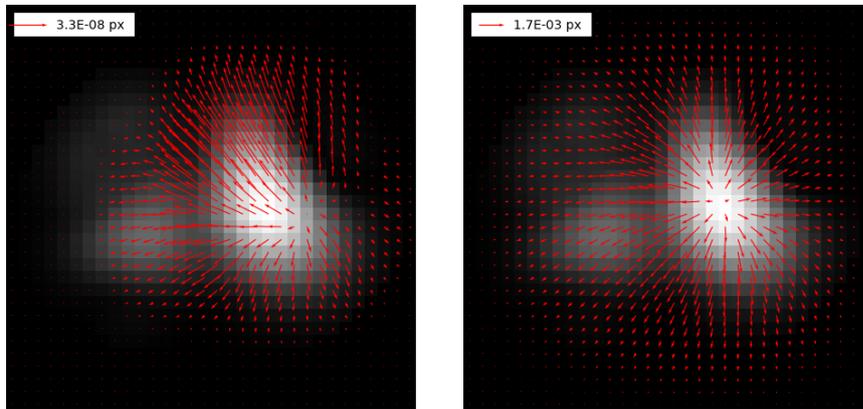
Figura 17 – CVMs para frames 47-48 de **Suíno N** para diferentes métodos de FO. Círculo amarelo em 17b indicando o centro de movimento divergente. A legenda mostra uma escala, em pixels, para as setas do CVM, dessa maneira é possível interpretar o deslocamento estimado para cada pixel entre o frame exibido e o seguinte.



(a) Farneback.

(b) Horn & Schunck.

Figura 18 – CVMs para frames 5525-5526 de **Humano P** para diferentes métodos de FO.



(a) Farneback.

(b) Horn & Schunck.

Figura 19 – CVMs para frames 8083-8084 de **Humano N** para diferentes métodos de FO.

5.3.3 Comparação dos CVMs de sequência de TIE gerados pelos algoritmos de Horn & Schunck e Farneback

Uma última análise entre os algoritmos foi realizada para visualizar a) os CVMs de cada um sobrepostos no mesmo frame (Figura 20 para o Suíno N e Figura 22 para o Humano P) e b) os vetores u e v separados.

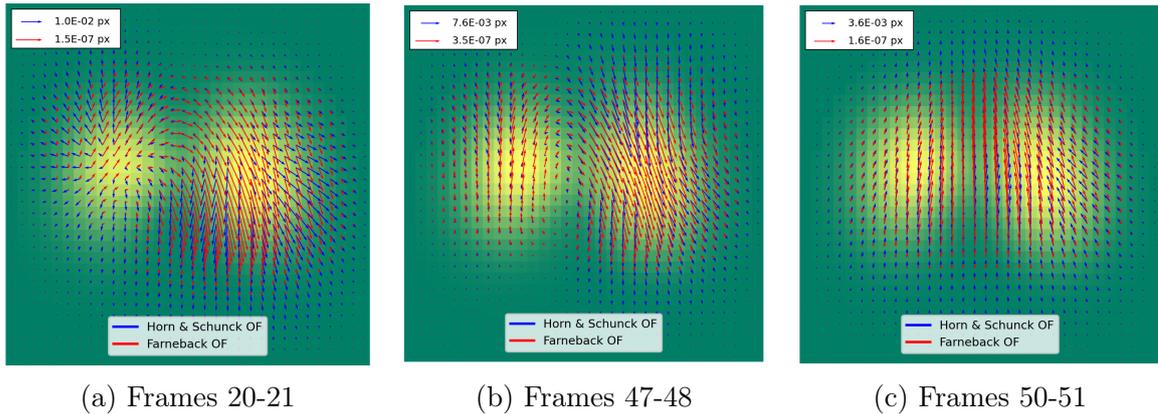


Figura 20 – Sobreposição dos algoritmos para cálculo de FO em imagens do Suíno N.

Para o frame 47 do Suíno N, o mapa de magnitude para os vetores u e v são plotados e distinguidos para cada algoritmo na Figura 21:

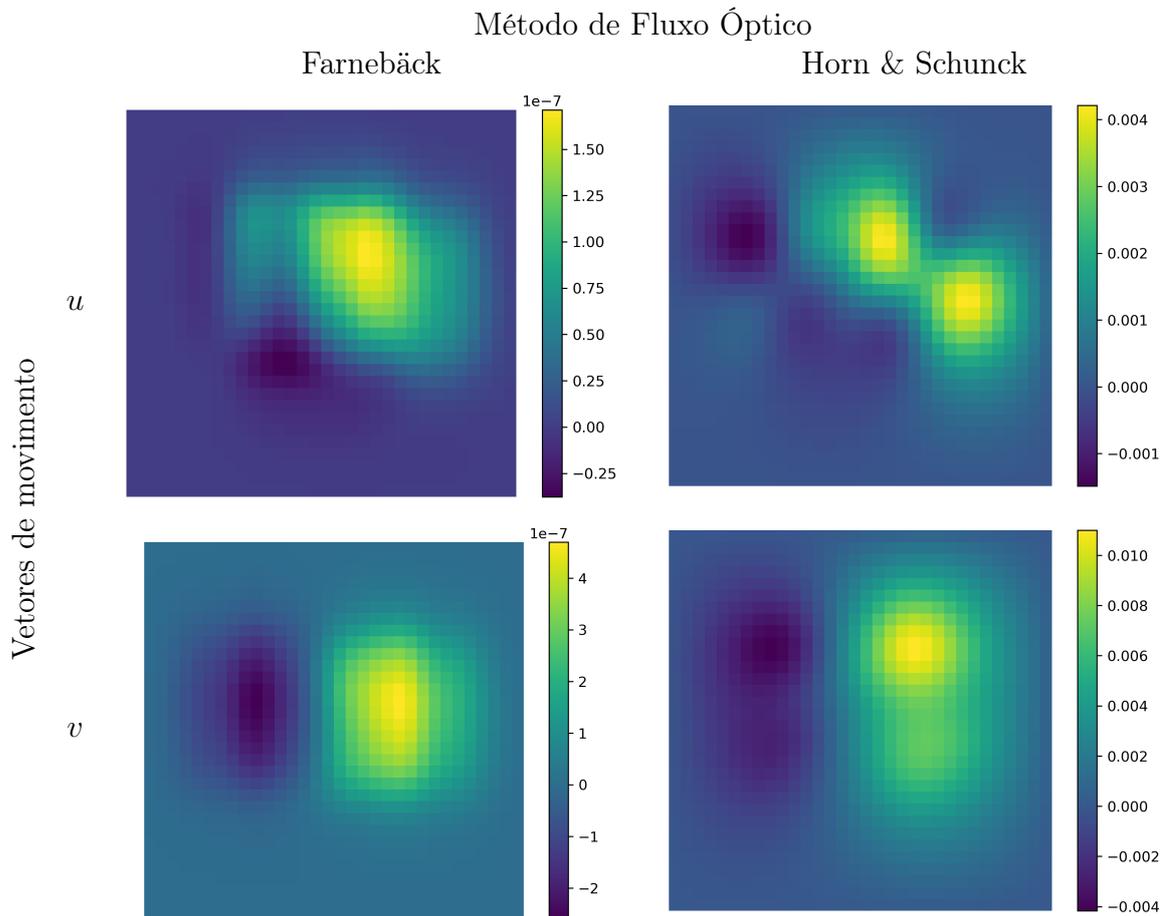


Figura 21 – Mapas de intensidade para Farneback e H&S para o frame 47 de Suíno N. Em “ u ”, um valor positivo de intensidade para um determinado pixel representa um movimento à direita, enquanto que um valor negativo significa uma tendência à esquerda. Em “ v ” um valor negativo indica um movimento “para cima” e um valor positivo um movimento “para baixo”.

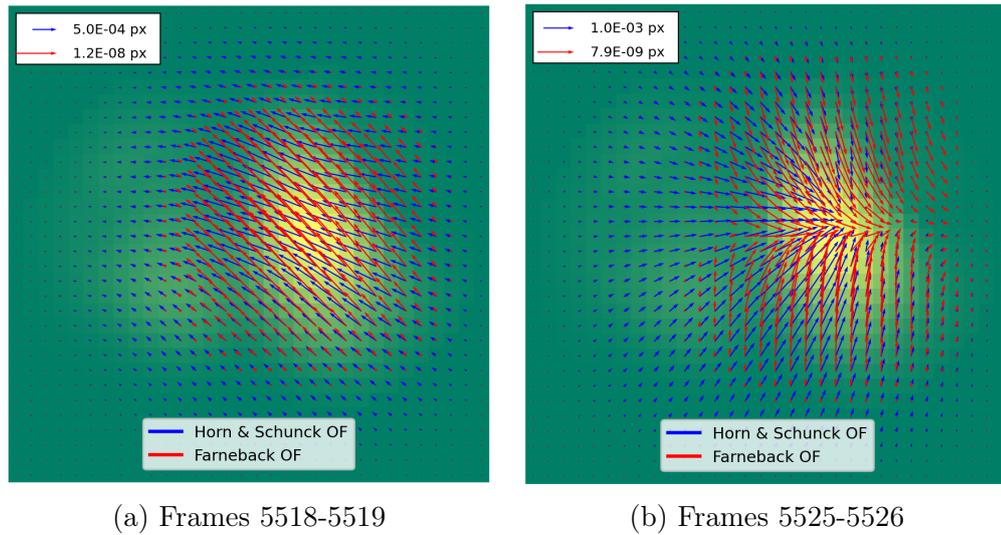


Figura 22 – Sobreposição dos algoritmos para cálculo de FO em imagens de Humano P.

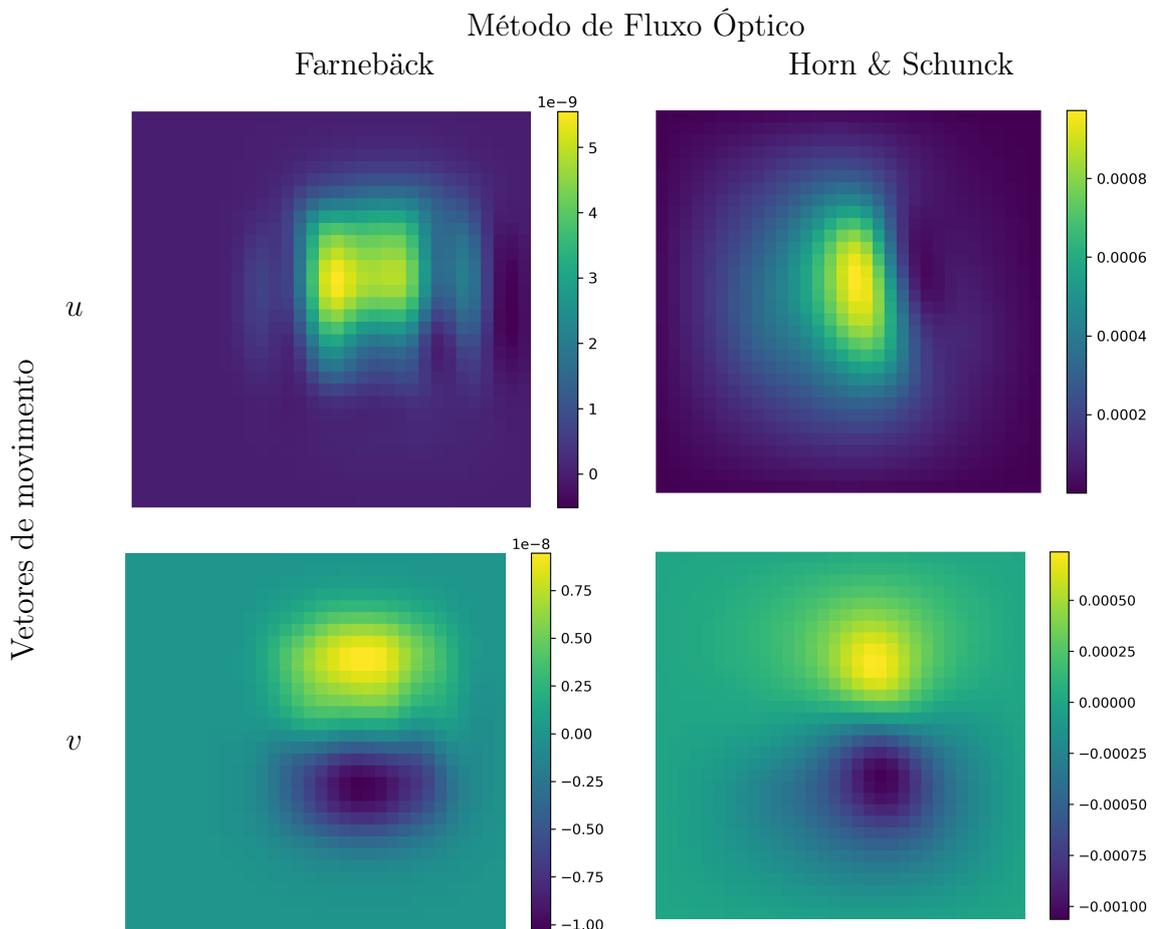


Figura 23 – Mapas de intensidade para Farneback e H&S para o frame 5525 de Humano P. Percebe-se como os diferentes métodos compartilham de similaridades de posição, porém apresentam diferenças em relação ao tamanho das áreas de atuação (regiões com valores extremos).

5.4 Discussão

O método de cálculo de fluxo óptico de Farnebäck, quando introduzido em 2003, foi um método inovador por conseguir estimar o movimento entre somente dois frames com um custo de velocidade super reduzido em relação a outros métodos coexistentes. Através de uma transformada de sinal inicial unicamente espacial, chamada de expansão polinomial, é possível estimar o deslocamento.

5.4.1 Para a comparação final

Apesar de ainda não ter sido mencionado neste trabalho (estará no Capítulo 6), os resultados referentes ao índice ϕ , especificado em (14), para os dados analisados através do FO de Farnebäck apresentaram proximidade significativa em relação ao método de H&S utilizado no trabalho mencionado de Fidelis *et al*, com o grande benefício de um custo computacional e temporal extremamente reduzidos.

Como demonstrado em (19), o algoritmo de Farnebäck se destaca na aplicação para sequências com pequenos e grandes deslocamentos em comparação aos métodos de Horn & Schunck, que também produz vetores de movimento de alta densidade mas é mais sensível a ruído.

Logo, para fins deste projeto, o método de Farnebäck se mostrou uma abordagem robusta, segura e eficiente para a obtenção dos conjuntos de CVMs de sequências de imagens de TIE para estimarmos o fluxo de ar dentro da região pulmonar e posteriormente analisar os comportamentos desse fluxo atuando no pulmão e no Pendelluft. No contexto de análise em tempo real, o FO de Fb se provou como adequado para o cálculo dos conjuntos de CVMs para vídeos de TIE.

Cabe mencionar que a implementação do cálculo de fluxo óptico de Horn & Schunck foi integrado a partir do repositório <https://github.com/lmiz100/Optical-flow-Horn-Schunck-method/> (acessado em 23 de Julho de 2023) e, apesar de ser uma aplicação direta da metodologia de H&S, pode não estar completamente otimizado. Entretanto, durante o trabalho de Graduação, foi percebido que o código em MATLAB responsável pelo cálculo do FO de H&S também demora consideravelmente mais que o código de Farnebäck em Python.

5.4.2 Frames de TIE

Assim como para as imagens teste da seção anterior, o tempo de processamento para Fb foi efetivamente mais rápido que o de H&S, entretanto, para esse tipo de arquivo, apesar de o processamento ainda ser rápido (a análise de um par de frames leva menos de 50 ms!), deve-se levar em consideração que os cálculos de FO acontecerão em tempo real, para uma sequência de imagens com taxa de amostragem de 50 Hz. Logo, 1 segundo

equivale a 50 imagens ou 49 pares consecutivos, aplicando a relação de tempo médio por par de TIE mostrada na Tabela 2 (H&S: 31,623 ms e Fb: 1,367 ms), temos: Horn & Shunck leva, em média, 1,55 segundo para processar 1 segundo de gravação de TIE (ou 50 frames consecutivos), já Farnebäck leva somente **67 ms para processar 1 segundo de gravação**.

Nas Figuras 20 e 22 vemos simultaneamente a representação em forma de setas da soma vetorial dos vetores u e v para cada CVM calculado por H&S e Fb. A partir dessas figuras pode-se avaliar a similaridade dos CVMs dos métodos diferentes de FO, dessa maneira, pode-se inferir que o comportamento geral segue direções e rotações similares entre os métodos de OF (Figuras 20b e 20c), com algumas exceções (no lado esquerdo da Figura 20a os vetores tomam direção x opostas).

Para as imagens do Humano P (Figura 22) observa-se tendências similares de direção e convergência, entretanto, especificamente na Figura 22b, os métodos acabam convergindo para pontos diferentes da imagem: H&S converge para a extremidade do pulmão à direita na imagem e Fb converge para um ponto mais à direita, fora da suposta região pulmonar. No decorrer da sequência de imagens do sujeito humano, percebe-se que os maiores valores de sinal se concentram no pulmão à direita, configurando um desbalanço lateral interlobos.

Como um método auxiliar para analisar os CVMs gerados, cada vetor u e v para um certo par de frames foi representado graficamente nas Figuras 21 e 23. Em ambas é possível identificar que os diferentes métodos compartilham de posições comuns entre os focos de seus vetores, porém apresentam diferenças especialmente em relação ao tamanho da área de atuação desses vetores.

5.4.3 Considerações

A alta velocidade de processamento do algoritmo de Farnebäck de OpenCV nos permite realizar vários testes com variações de parâmetros e, apesar de não ter sido realizado neste trabalho, comparar como essa variação e o próprio uso do método de Farnebäck afetam os resultados dos próximos códigos em relação ao uso de H&S (mais especificamente como afetam os resultados da Decomposição Discreta de Helmholtz-Hodge). Entretanto, a DDHH atualmente é demasiada custosa em termos de tempo.

Outra maneira para determinar a confiabilidade e grau de erro para cada método de FO e suas variações seria através do uso de Ground Truths (GTs) (17), que são um conjunto de vetores de movimento que determinam o deslocamento através de uma sequência de imagens, ou seja, são a informação de movimento precisa e acurada que é usada para avaliar algoritmos de fluxo óptico. Para isso, seria necessário comparar o CVM gerado para um par de frames com o Ground Truth para a mesma sequência.

6 Desenvolvimento de um indicador para detecção de Pendelluft em sequências de imagens de TIE

6.1 Introdução

Agora temos $N - 1$ Campos Vetoriais de Movimento (CVMs) para um sequência de N frames de TIE e é necessário analisar esses parâmetros para entender as características do fluxo de ar durante o tempo no qual o registro foi realizado. Um teorema fundamental em mecânica dos fluidos é que um CVM complexo pode ser decomposto em uma parte irrotacional W , uma parte divergência nula E e um restante harmônico H (27). Para isso, a decomposição de Helmholtz-Hodge pode ser empregada a fim de extrair esses componentes do CVM e estudar as características de incompressibilidade e vorticidade do fluxo de ar, tais como fontes, ralos e vórtices, e eventualmente obter pontos críticos de interesse (28).

Os pontos críticos são fontes e ralos, sendo que as fontes, local em que o campo do potencial W é mínimo (W_m) são tomadas como áreas de entrada de ar; e os ralos, local em que o campo do potencial (W_M) tem um valor máximo, são tomados como locais de saída de ar. Os centros de rotação horário e anti-horário são considerados como as direções de distribuição inter-regiões de ar no sentido horário (E_M) e sentido anti-horário (E_m), onde o campo do potencial E é máximo e mínimo, respectivamente (14). Uma representação visual da relação entre o campo de potenciais escalares e um CVM é observada na Figura 24. Nela também estão discriminados os pontos críticos para cada campo de potencial.

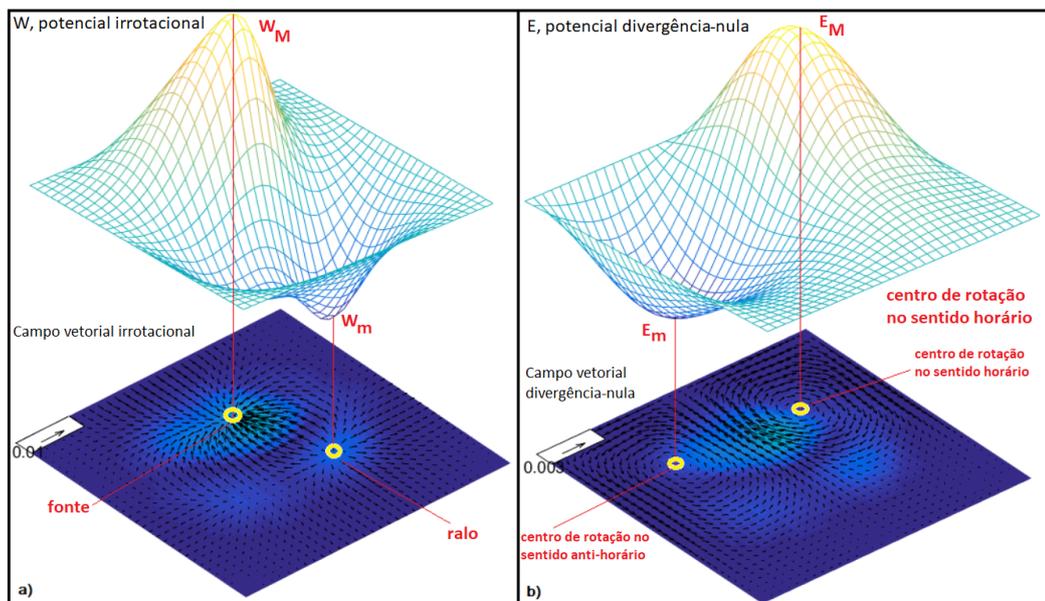


Figura 24 – a) Um valor mínimo no campo de potencial W representa uma fonte de fluxo no campo vetorial irrotacional, enquanto que um valor máximo representa um ralo. b) Um valor máximo no campo de potencial E representa um centro de rotação no sentido horário, enquanto que um mínimo representa um centro de rotação anti-horário. Fonte: Adaptado de Fidelis *et al* (14).

Dada a importância de tais pontos críticos W_m , W_M , E_m e E_M , convém a criação de um mapa de frequência de aparição por conjunto de CVMs (ou potenciais), que exhibe o número de vezes que cada extremo (para cada potencial) esteve presente em um dado pixel durante a sequência de imagens analisada. A Figura 25 mostra como os mapas de frequência para o Suíno N ficariam, onde os pontos de extremo são representados pelo X vermelho.

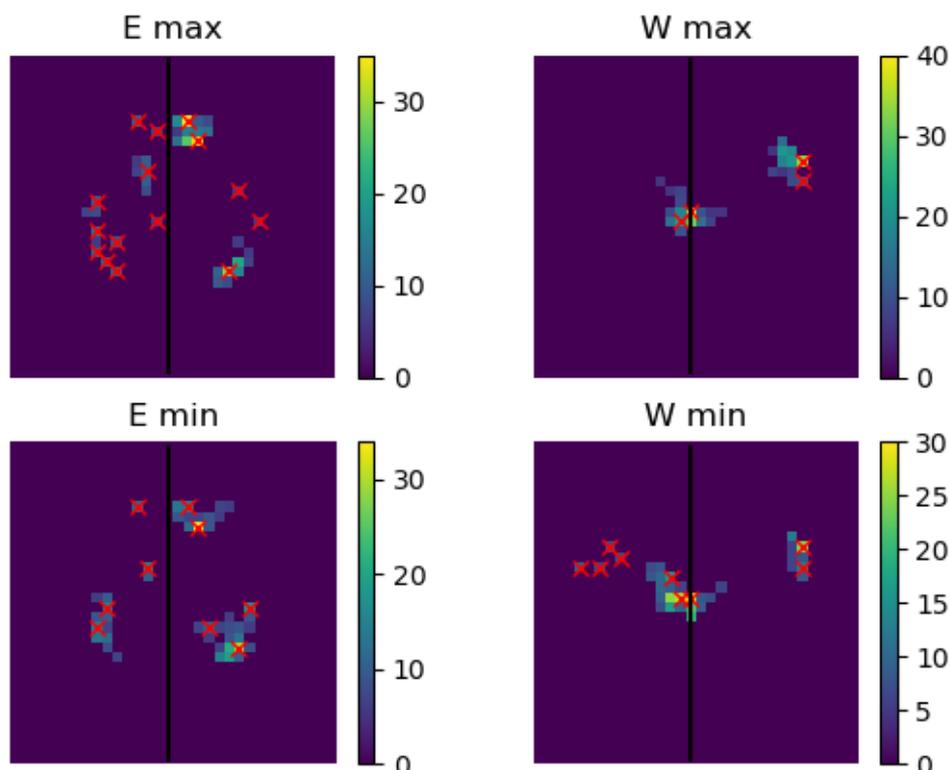


Figura 25 – Mapas de frequência para o Suíno N, sendo E - Potencial escalar divergência nula e W - potencial escalar irrotacional.

Fonte: Do autor.

O mapa de frequência abre caminho para hipóteses e análises relacionadas aos fenômenos do fluxo de ar dentro do pulmão e da manifestação de pendelluft. No trabalho de Fidelis *et al* (14) duas hipóteses foram formuladas e apresentadas abaixo. Elas servem como base para o novo método proposto para o desenvolvimento de um índice identificador de pendelluft:

1. Considerando que o ar oxigenado entra no corpo através da mesma via que o ar expirado, em condições normais de respiração, os caminhos aéreos usados durante inspiração e expiração deveriam ser os mesmos. Portanto, devem existir locais comuns frequentes nos mapas de frequência de W_m e W_M . Pela natureza cíclica da

respiração, se E_M representa o centro de distribuição de ar inter-regiões de sentido horário, então também deve haver pontos comuns no mapa de frequência de E_m representando o centro de sentido anti-horário quando o ciclo respiratório está na fase oposta de respiração;

2. Durante o Pendelluft, as vias usadas para entrada/saída de ar e distribuição inter-regiões de ar não são as mesmas em fases opostas do ciclo respiratório, ocasionando em poucos ou nenhum pontos em comum nos mapas de frequência de valores máximos e mínimos para os potenciais W e E.

Baseando-se nessas hipóteses, Fidelis *et al* criaram uma medida quantitativa ϕ adimensional para tentar distinguir a ausência e presença de Pendelluft. A equação responsável que define o método para se obter a medida ϕ está na Equação 6.1, na qual b representa o número total de pontos para os mapas de frequência das posições de máximos e mínimos, f_M^i representa a frequência de aparição para o i -ésimo ponto no mapa de valores máximos e f_m^i a frequência para o i -ésimo ponto no mapa de valores mínimos. Dessa maneira, cada sequência tem quatro valores de ϕ para a análise rotacional e análise divergente, ambas para cada pulmão (14).

$$\phi = \sum_{i=1}^b f_M^i \cdot f_m^i \quad (6.1)$$

Os cálculos e resultados de ϕ são contemplados neste trabalho, entretanto um novo método para classificação do grau de Pendelluft foi concebido neste estudo e é explorado na seção a seguir, expandindo o conceito de ϕ .

6.2 Método

6.2.1 Extração de potenciais escalares dos CVMs

Dado que o método de fluxo óptico de Farneback retorna CVMs bidimensionais, torna-se necessário aplicar a **Decomposição Discreta de Helmholtz-Hodge** (DDHH) para analisarmos as características do fluxo de ar. Na DDHH um Campo Vetorial de Movimento $\vec{\zeta}$ pode ser expressado como $\vec{\zeta} = (\nabla W) + (\nabla \times \vec{E}) + \vec{R}$, onde ∇W é a parte irrotacional (satisfazendo $\nabla \times (\nabla W) = \vec{0}$), $\nabla \times \vec{E}$ é a parte divergência-nula (satisfazendo $\nabla \cdot (\nabla \times \vec{E}) = 0$) e \vec{R} é o restante harmônico (satisfazendo $\nabla \cdot \vec{R} = 0$ e $\nabla \times \vec{R} = \vec{0}$ simultaneamente). Note que ∇ , $\nabla \cdot$ e $\nabla \times$ se referem aos operadores de gradiente, divergência e rotacional, respectivamente. W é uma função de potencial escalar de ∇W e \vec{E} é uma função potencial vetorial de $\nabla \times \vec{E}$ (28). Assim, temos o potencial escalar W que representa a parte irrotacional e o potencial escalar E que representa a parte divergência-nula (29).

Portanto, a DDHH é utilizada para extrair os potenciais escalares do conjunto de CVMs gerado através do cálculo de fluxo óptico de Farneback. A aplicação da decomposição é realizada por par de vetores u e v , já que sua soma vetorial contém o comportamento estimado do deslocamento entre um frame e outro consecutivo, resultando em $N - 1$ conjuntos de potenciais escalares E e W , sendo N o número total de frames presentes na sequência analisada. Cada potencial escalar tem as mesmas dimensões das imagens de TIE e, assim como os CVMs, existe um potencial E e W para cada par de frames.

Realizando a análise de máximos e mínimos diretamente através dos potenciais escalares produzidos pela decomposição é possível simplificar os procedimentos e identificar pontos críticos do fluxo, ao invés de analisar diretamente o CVM. Esses pontos são as características mais importantes do fluxo de ar (29) e são compostos por atratores, repelidores e selas, componentes que são considerados determinantes para a estrutura do fluxo.

6.2.2 Máximos e mínimos

Como mencionado no início deste Capítulo, os locais onde os potenciais escalares assumem valores extremos (ora máximos ou mínimos) são pontos críticos que representam fenômenos fisiológicos de interesse para nossa análise. Por conseguinte, dá-se a necessidade de analisar os potenciais escalares W e E e alocar seus pontos de extremo em campos de valores mínimos e máximos (W_m , W_M , E_m e E_M , respectivamente) para posteriores análises de presença de Pendelluft.

Considerando que cada potencial escalar é uma matriz bidimensional, é possível gerar matrizes binárias de iguais dimensões para comportar as “ilhas” de máximos e mínimos locais para cada potencial W e E . Essas matrizes são os “campos de valores extremos” W_m , W_M , E_m e E_M , para cada par de frames, totalizando $N - 1$ conjuntos de campos de valores extremos. São registradas, também, as posições de cada pixel extremo presente em cada um dos $N - 1$ conjuntos de campos de valores extremos em uma lista, apelidada de “Lista de Extremos”. Nota-se que a análise de extremos se restringe a região pulmonar segmentada semi-automaticamente pelo algoritmo.

6.2.3 Mapas de frequência

O mapa de frequência é uma representação da quantidade de vezes que determinados pontos se repetem. Em nosso contexto, o mapa de frequência, de dimensões iguais às das imagens de TIE, registrará a quantidade de vezes que um determinado pixel apareceu no registro de pontos extremos. Consideramos a frequência mínima para que o pixel fosse considerado no mapa de frequência como $D = 6$, logo os pixels com frequência menor que D foram desconsiderados. Também foi implementada uma breve análise de

máximo local do pré-mapa de frequência para que pontos dentro de um raio de 5 pixels do máximo local permanecessem no mapa, de modo a auxiliar na determinação das regiões pulmonares mais importantes para a dinâmica respiratória e movimento do ar. Ao fim, temos quatro mapas de frequência: $W_{m,fm}$, $W_{M,fm}$, $E_{m,fm}$ e $E_{M,fm}$ respectivamente para representar os mínimos e máximos do potencial Irrotacional W e do potencial divergência nula E .

6.2.4 Índice proposto para detecção de Pendelluft (P_d)

Os pontos críticos para entrada e saída de ar, relacionados ao Potencial Escalar Irrotacional W e denominados W_m e W_M respectivamente, são parâmetros de grande interesse para a avaliação de simetria entre fases opostas, pois representam os principais pontos de passagem de ar e podem estar em lugares diferentes caso uma doença como Pendelluft esteja acontecendo. Portanto, propõe-se um índice baseado na relação da distância entre pontos de máximo e mínimos do potencial Irrotacional encontrados através, do mapa de frequência, para a quantificação da ocorrência de Pendelluft.

A presença de um mapa de frequência e de um registro com todas as posições dos extremos para o potencial em questão permite que seja realizada uma relação espacial entre os pontos máximos e mínimos dos mapas de frequências de todos os frames da sequência analisada. Com isso, é possível a retenção não só do mapa de frequência, mas também da posição de cada ponto de extremo e de valor desse pixel no seu frame correspondente.

Uma vez que os dados estão organizados, a definição das relações entre pontos de máximos e mínimos (neste caso a ordem importa, assim, como “máximo” veio antes, ele será nossa REF e “mínimo” nosso GOAL, e a disposição de pares é REF \rightarrow GOAL, podendo um GOAL receber mais REFs) é estabelecida da seguinte forma:

1. *Análise de Distância*: Inicia-se a procura dos pares de máximo \rightarrow mínimo através da confecção de uma tabela, baseada na tabela de distâncias de Hausdorff¹, contendo uma relação entre cada ponto de máximo (cada coluna equivale a um ponto de máx.) e cada ponto de mínimo (cada linha corresponde a um ponto de mín.). Cada célula representa a relação entre o ponto REF de sua coluna e o GOAL de sua linha através de três parâmetros:

- *distância*²: o quadrado da distância em pixels entre o REF e o GOAL. Usado para avaliar proximidade;

¹ A distância de Hausdorff diz respeito à maior distância possível entre um ponto de um conjunto e o ponto mais próximo pertencente a outro conjunto (30). Uma das etapas para se determinar a distância de Hausdorff é a confecção de uma tabela de distâncias entre todos os pontos de ambos conjuntos. Para este estudo, o método de confecção da tabela ajudou a identificar pontos de mínimo mais próximos dos pontos de máximo.

- *MinRelativ/MaxRelativ*: razão entre quantos por cento do maior valor de intensidade para os possíveis GOALs equivale o valor de intensidade do GOAL atual e quantos por cento do maior valor de intensidade para as possíveis REFs equivale o valor de intensidade da REF atual. Dada em porcentagem e usada para avaliar se as intensidades são compatíveis;
 - *Desvio de valor relativo*: é o desvio da porcentagem acima (valor - 100).
2. *Definição dos Pares*: Como a tabela provê os valores de distância entre cada um dos pares, é possível definir qual é o ponto mínimo mais próximo de cada ponto de máximo (dessa forma, pois definimos inicialmente a relação REF:MÁX → GOAL:MÍN). É possível inferir, dessa maneira, que cada ponto de máximo se ligará somente a um ponto de mínimo, entretanto um ponto de mínimo pode estar ligado a mais de um máximo. Uma vez que todos os pontos de máximos tenham um par, podemos prosseguir;
 3. C_{max} : Cada par REF → GOAL conta com uma distância ($d(REF_n, GOAL_m)$), um valor para REF_n (α_{REF_n}) e um valor para $GOAL_m$ (α_{GOAL_m}). Assim, para cada par, podemos calcular um $C_{REF,n}$, sendo n o identificador único do máximo e m seu par, através da equação 6.2:

$$C_{REF,n} = |\alpha_{REF_n} - \alpha_{GOAL_m}| \cdot d(REF_n, GOAL_m)^2 \quad (6.2)$$

O coeficiente C_{max} é responsável pela correlação singular entre cada ponto de máximo e seu ponto de mínimo;

4. P_d : O índice P_d é então calculado através da média dos coeficientes $C_{REF,n}$ de todos os máximos (REFs), como mostrado na equação 6.3 abaixo:

$$\text{Pendelluft Degree} \rightarrow P_d = \frac{\sum_i^n C_{REF,i}}{n} \quad (6.3)$$

Desse maneira, busca-se exacerbar a influência de dois fatores: 1) pontos de máximos e mínimos muito distantes e 2) pares com intensidades muito diferentes. Caso a distância de um par seja 0, seu C_{REF} também será 0 e, portanto, sua contribuição para P_d causará uma aproximação do índice ao valor 0.

O índice P_d acaba se tornando um indicador adimensional para a correlação entre pontos de máximo e mínimo para o potencial irrotacional W (no código é contemplada a possibilidade de se analisar o potencial divergência nula E), representando a dispersão entre os pontos dos dois grupos (caso de Pendelluft, de acordo com a hipótese definida) com valores altos e a proximidade entre tais pontos com valores baixos, ambos sempre positivos.

Por fim, a representação gráfica por imagens e tabelas de pares das relações entre os pontos extremos é realizada para auxiliar a visualização do algoritmo.

6.3 Resultados

É importante levar em consideração o tempo levado para a extração dos campos de potenciais escalares a partir dos CVMs. Os tempos de processamento (ΔT) para as extrações podem ser observados na Tabela 3. Nota-se que tais valores são provenientes da execução dos algoritmos no computador do autor.

Tabela 3 – Tempo levado para a extração dos campos dos potenciais escalares E e W através da Decomposição Discreta de Helmholtz-Hodge em CVMs de imagens de TIE de dimensões 32 x 32 pixels.

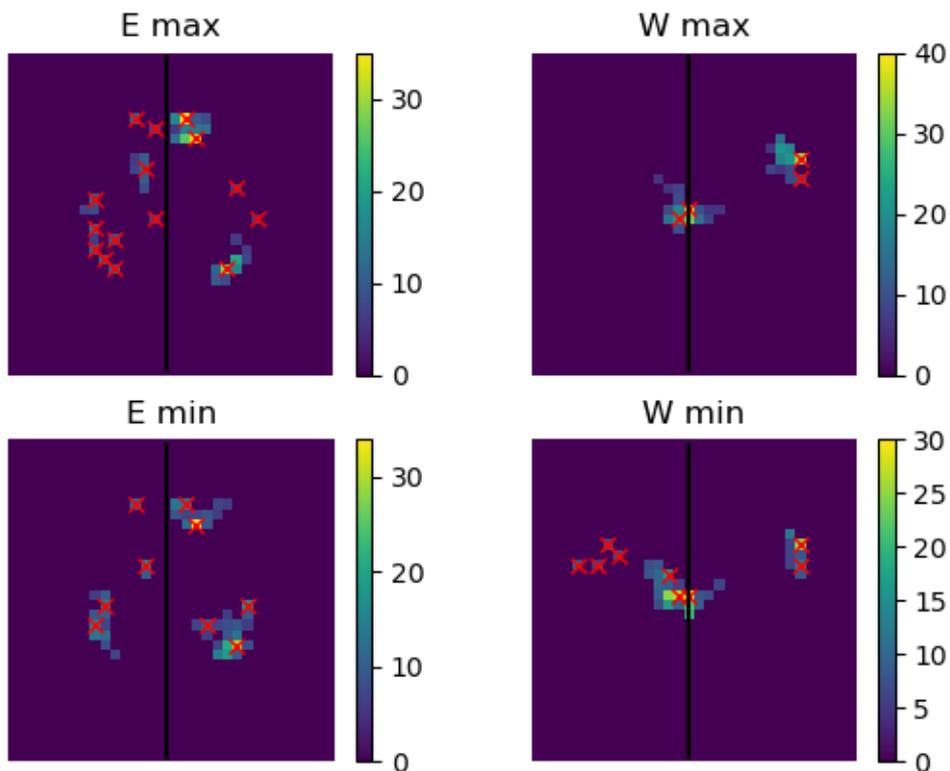
Sequência	Nº de frames	Tempo de registro (s)	ΔT (min)	ΔT (s)	ΔT médio por CVM (s)	Mapa de frequência
Suíno N	756	15,12	26	1570	2,08	[26]
Suíno P	245	4,9	8	455	1,86	[27]
Humano N	2000	40	65	3929	1,96	[30]
Humano P	2000	40	56	3357	1,68	[31]

Dessa maneira, podemos considerar que o algoritmo de DDHH leva, em média, 1,90 segundos para extrair os potenciais escalares de um CVM. Levando em consideração que, para uma taxa de amostragem de 50 Hz, cada CVM é o equivalente a 0,04 segundos (2 frames), uma possível redução da taxa de amostragem pode refletir a possibilidade de aplicar esse algoritmo em tempo real.

6.3.1 Mapas de frequência e ϕ

A seguir são exibidos os mapas de frequência e ϕ calculados para cada suíno (Suíno N e Suíno P) e para cada um de seus potenciais escalares E e W. Os pontos de extremos (máximos e mínimos) que são extremos locais estão identificados por um x vermelho.

Figura 26 – Mapas de frequência gerados para o Suíno N (sem Pendelluft), sendo E - Potencial escalar divergência nula e W - potencial escalar irrotacional.

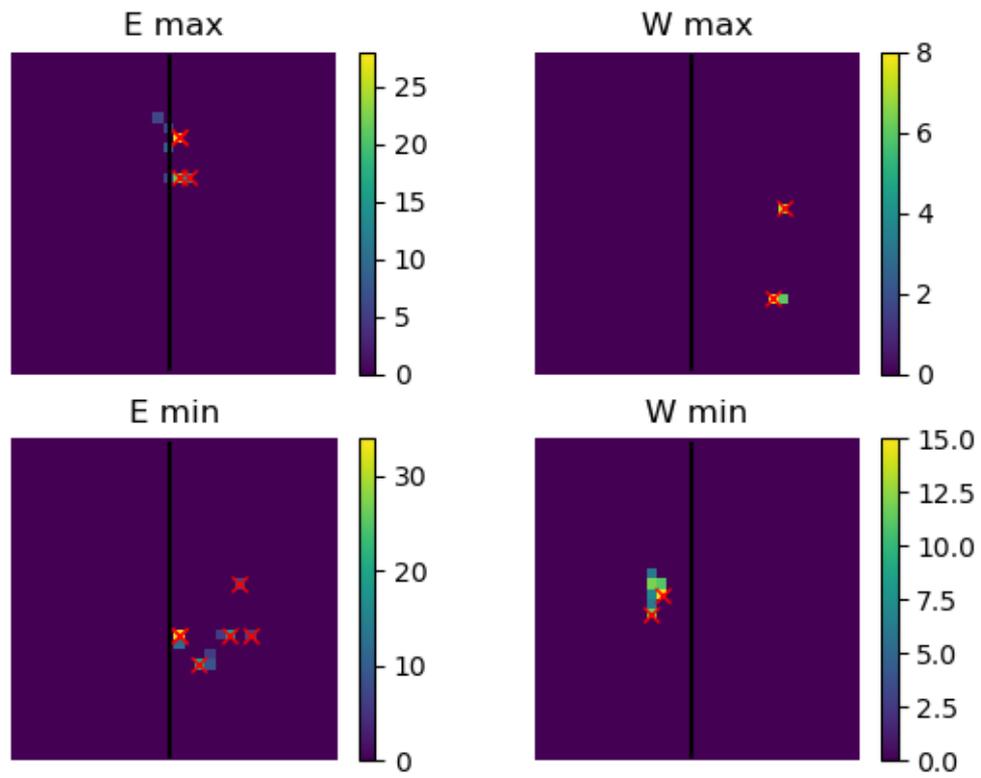


Fonte: Do autor.

Tabela 4 – Valores de ϕ calculados para Suíno N

Potencial	Valor de ϕ	
	Esquerda	Direita
Divergência Nula E	908,0	4169,0
Irrotacional W	1384,0	1689,0

Figura 27 – Mapas de frequência gerados para o Suíno P (com Pendelluft).



Fonte: Do autor.

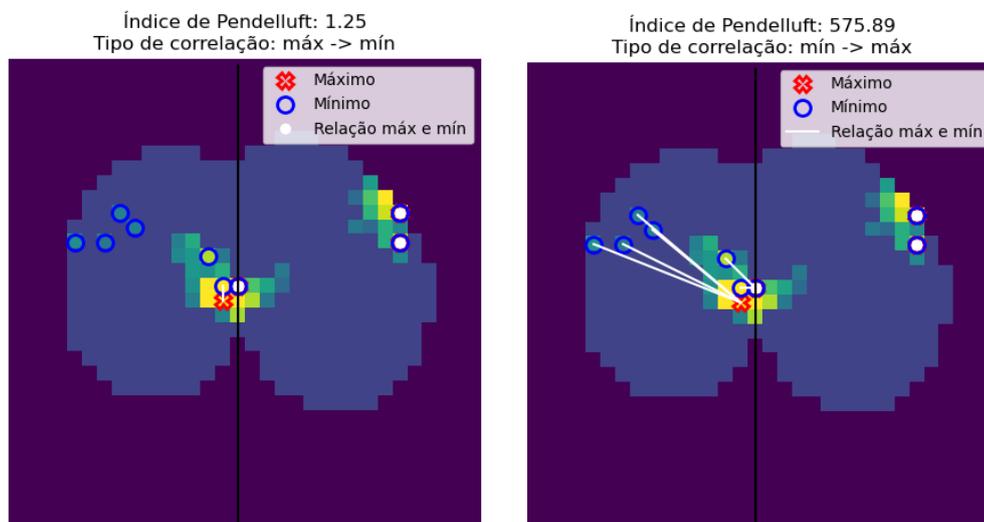
Tabela 5 – Valores de ϕ calculados para Suíno P

Potencial	Valor de ϕ	
	Esquerda	Direita
Divergência Nula E	0,0	0,0
Irrotacional W	0,0	0,0

6.3.2 Índice P_d

A fim de entender o comportamento do método proposto, os resultados dos cálculos são expostos a seguir para os suínos e diferentes relações (máx \rightarrow mín e mín \rightarrow máx).

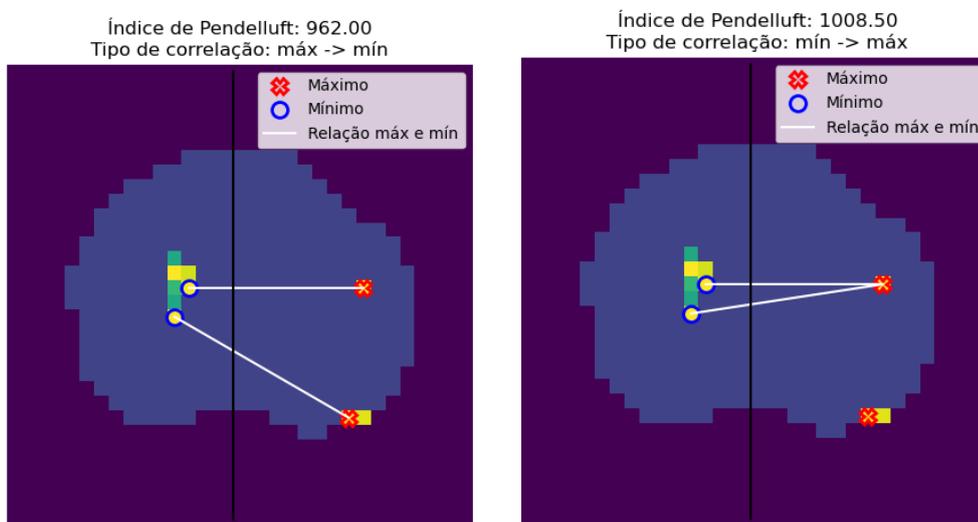
Figura 28 – Índice de Pendelluft para o Suíno N



(a) Correlação máx \rightarrow mín. $P_d = 1,25$. (b) mín \rightarrow máx. $P_d = 575,89$.

Fonte: Do autor.

Figura 29 – Índice de Pendelluft para o Suíno P



(a) máx \rightarrow mín. $P_d = 962,0$. (b) mín \rightarrow máx. $P_d = 1008,5$.

Fonte: Do autor.

A discussão dos resultados apresentados foi reservada para também abranger os resultados para os dados de TIE de humanos e é apresentada ao final do capítulo seguinte (7.4).

7 Aplicação do método em sequências de imagens de TIE em humanos

7.1 Introdução

Continuando a aplicação dos mapas de frequência, cálculo de ϕ e índice de Pendelluft P_d , reúnem-se aqui os resultados humanos e a discussão referente a ambos tipos de sujeitos.

7.2 Método

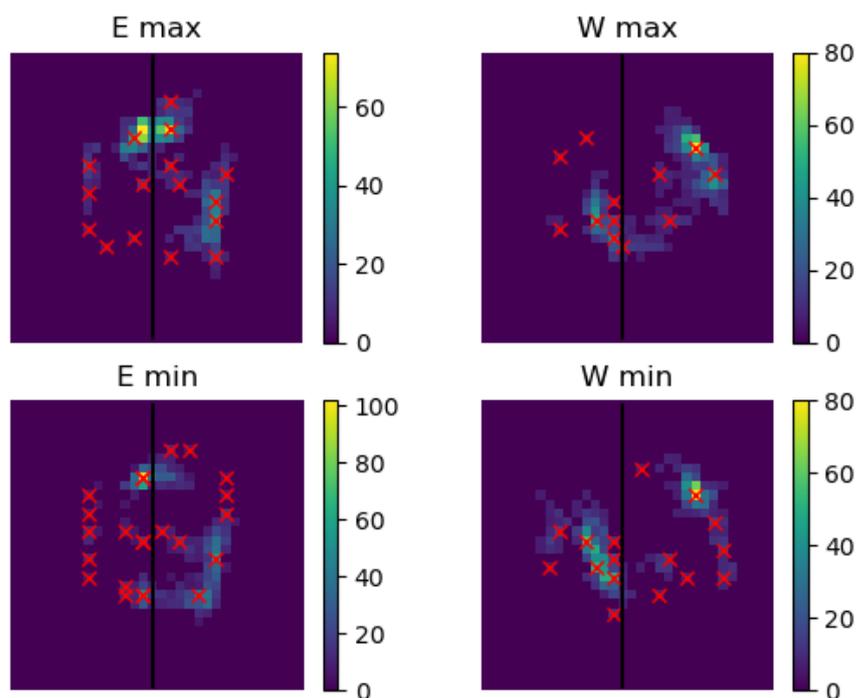
Para os dados humanos identificados como sem Pendelluft (Humano N) e com Pendelluft (Humano P), o método descrito no Capítulo 6 foi repetido, utilizando-se o Índice P_d desenvolvido.

7.3 Resultados

7.3.1 Mapas de frequência e ϕ

Os mapas de frequência a seguir foram calculados com o mesmo valor de $D = 6$.

Figura 30 – Mapas de frequência gerados para o Humano N (frames sem Pendelluft).

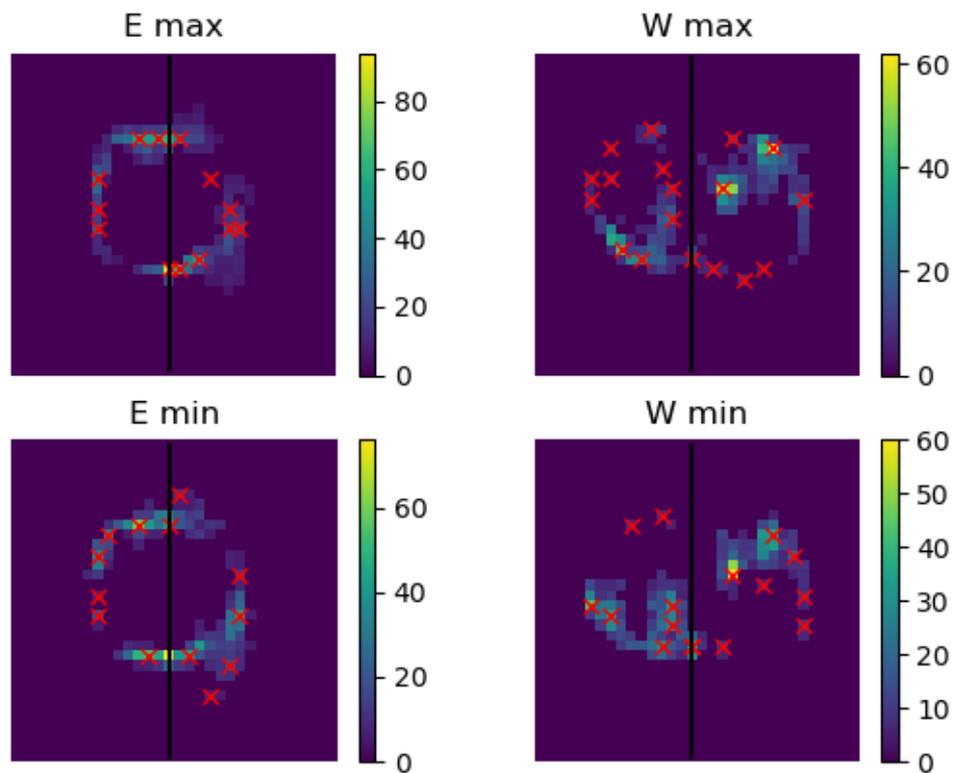


Fonte: Do autor.

Tabela 6 – Valores de ϕ calculados para Humano N

Potencial	Valor de ϕ	
	Esquerda	Direita
Divergência Nula E	16319,0	19881,0
Irrotacional W	13813,0	20964,0

Figura 31 – Mapas de frequência gerados para o Humano P (frames com Pendelluft).



Fonte: Do autor.

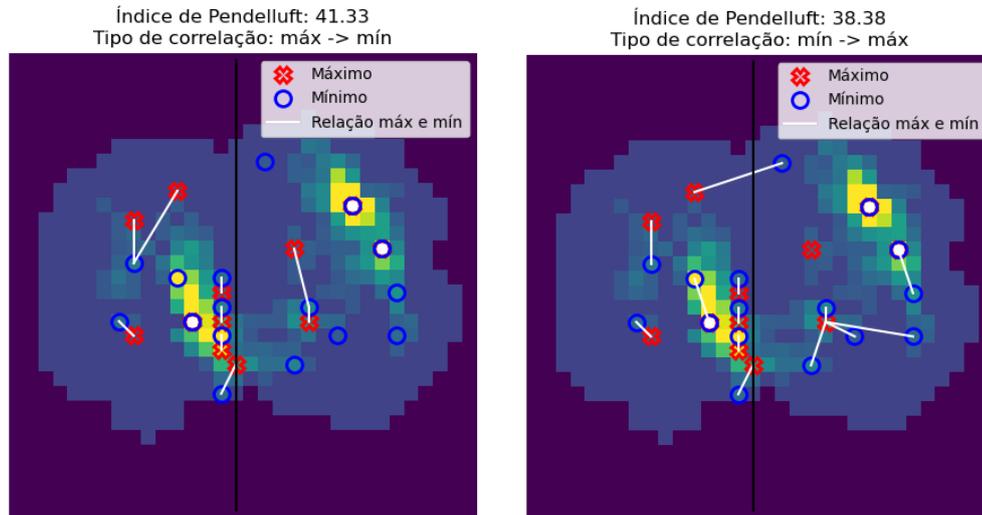
Tabela 7 – Valores de ϕ calculados para Humano P

Potencial	Valor de ϕ	
	Esquerda	Direita
Divergência Nula E	18131,0	16380,0
Irrotacional W	10529,0	15424,0

7.3.2 Índice P_d

A fim de entender o comportamento do método proposto, os resultados dos cálculos são expostos a seguir para os sujeitos humanos e diferentes relações (máx \rightarrow mín e mín \rightarrow máx).

Figura 32 – Índice de Pendelluft para o Humano N

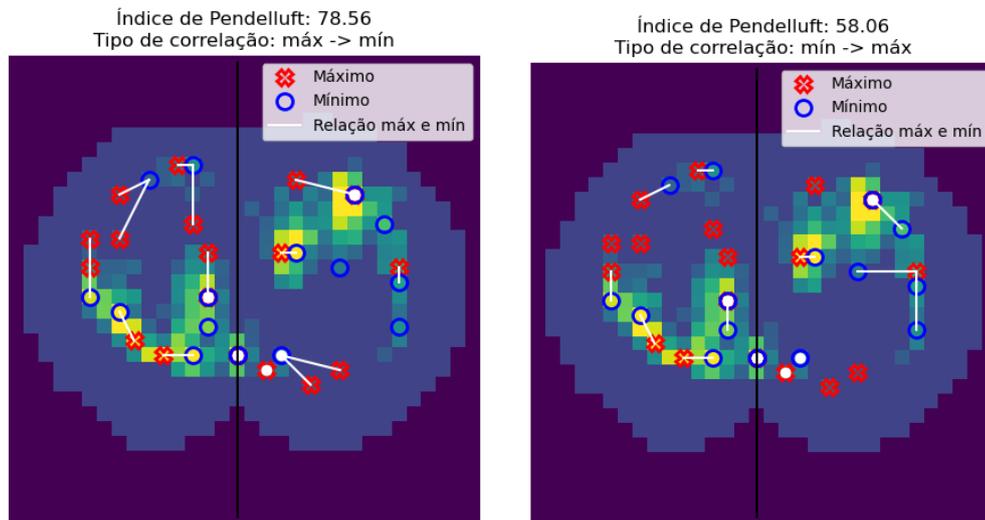


(a) máx → mín. $P_d = 41,33$.

(b) mín → máx. $P_d = 38,38$.

Fonte: Do autor.

Figura 33 – Índice de Pendelluft para o Humano P



(a) máx → mín. $P_d = 78,56$.

(b) mín → máx. $P_d = 58,06$.

Fonte: Do autor.

O cálculo do índice P_d consumiu, em média, 1,42 ms por par e 9,14 ms por mapa de frequência, considerando sua aplicação nos quatro dados apresentados (humanos e animais com e sem Pendelluft).

7.4 Discussão

A análise de extremos diretamente realizada através dos potenciais escalares produzidos pela decomposição discreta de Helmholtz-Hodge promove a simplificação dos procedimentos e a identificação dos pontos críticos do fluxo, ao invés de ser feita diretamente no CVM. Graças à decomposição, é possível lidar com potenciais escalares irrotacionais e divergência nula, que são representações importantes dos fenômenos presentes no fluxo de ar, para cada Campo de Vetores de Movimento, ou seja, com alta resolução temporal para cada transição de frames da sequência.

A identificação temporal dos ciclos respiratórios tem um papel importante em definir a época de análise para os algoritmos apresentados, já que as épocas denotam não só o intervalo de interesse para nossas análises manuais, mas também o comportamento que um possível algoritmo de detecção online automática de Pendelluft deve adotar para identificar o início e fim de cada ciclo respiratório.

Neste estudo, a sequência Suíno N e Suíno P contam com 5 ciclos respiratórios, enquanto que Humano N e Humano P contemplam pouco menos de 10 ciclos respiratórios (14).

7.4.1 Mapas de frequência e ϕ

Já com os potenciais escalares extraídos dos CVMs, a geração dos quatro mapas de frequência é consideravelmente rápida, consumindo somente 1,23 segundos para a sequência Suíno P (245 frames), 3,53 s para Suíno N (756 frames) e 9,56 s para Humano N e P (2000 frames)! A média para o cálculo dos quatro mapas de frequência é de 4,82 ms por CVM (o número de CVMs por sequência é o N^o de frames - 1), considerado rápido pois o intervalo de tempo entre cada frame é de 20 ms.

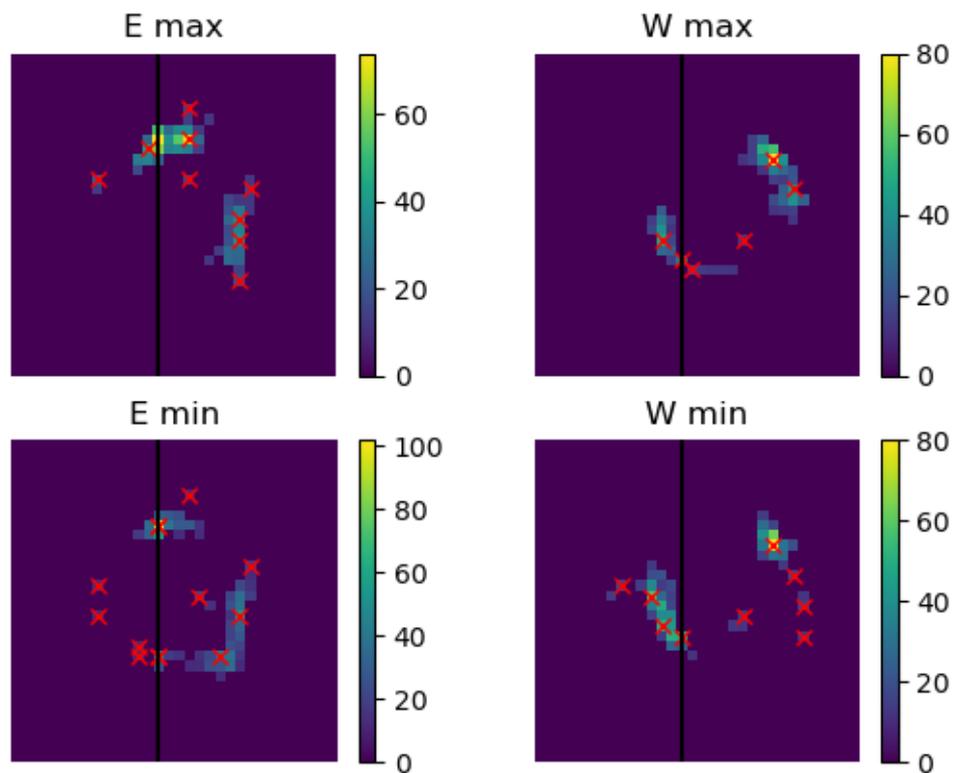
Os mapas apresentados proporcionam a identificação visual de pontos de extremos de potenciais que compartilham do mesmo local (exemplificado nos mapas do potencial W de Suíno N na Fig. 26) e da ausência de locais comuns para os pontos de extremos (potencial W em Fig. 27). Nesses casos, a aplicação de uma análise de similaridade entre os mapas de máximos e mínimos, como a medida quantitativa ϕ , provê bons resultados para a identificação de Pendelluft como os exibidos nas tabelas 4 e 5.

Entretanto, a aplicação da mesma análise pela medida quantitativa ϕ para os mapas de frequência de Humano N (Fig. 30) e Humano P (Fig. 31) não retorna resultados satisfatórios: como é possível observar na tabela 7, os valores obtidos para o Humano P se assemelham aos valores obtidos para o Humano N (tabela 6), mostrando pouco grau de distinção entre a ausência e a presença do fenômeno de Pendelluft. Essa tendência pode ser explicada pela alta complexidade da mecânica pulmonar humana em contraste à animal, que tem pulmões mais leves, menor volume pulmonar e uma capacidade respiratória menor (14). Igualmente, é possível observar nos mapas de frequências para o sujeito humano

(Figuras 30 e 31) a diferença de quantidade de pontos de extremos, configurando uma situação mais complexa se comparada à dos animais, já que a presença de mais pontos de extremos afeta diretamente o resultado obtido de ϕ .

É importante notar que o mesmo valor de $D = 6$ foi utilizado para os dois tipos de dados (animal e humano) e, como as seqüências humanas têm quase o dobro de ciclos respiratórios, é necessário adequar esse valor às características da seqüência analisada. Observa-se abaixo, na Figura 34, como a geração dos mapas de frequência através de um valor de $D = 12$ (escolhido devido à presença do dobro de ciclos respiratórios) restringe a quantidade e a localização dos pontos de extremos a locais onde realmente se encontram concentrações de extremos, um avanço se comparado à Figura 30.

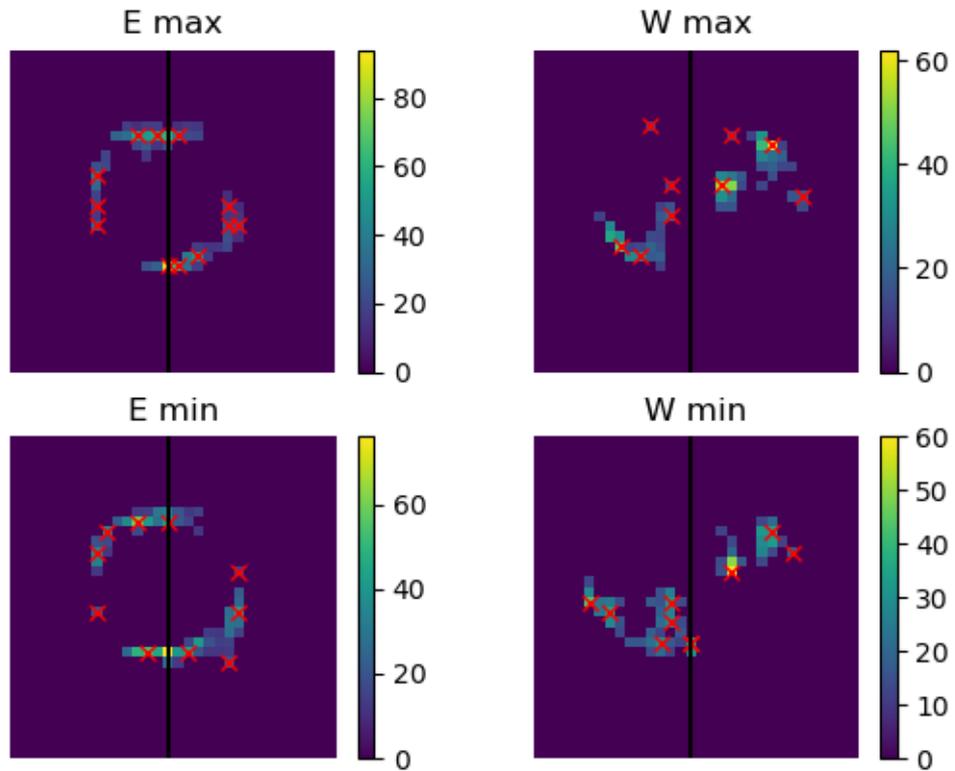
Figura 34 – Mapas de frequência para Humano N utilizando $D = 12$.



Fonte: Do autor.

A mesma adaptação pode ser realizada para a seqüência Humano P, com os resultados observáveis abaixo:

Figura 35 – Mapas de frequência para Humano P utilizando $D = 12$.



Fonte: Do autor.

Apesar da melhora na qualidade da distribuição de pontos de interesse nos mapas de frequência com valor de D ajustado, os valores de ϕ permanecem próximos (Tabela 8). É interessante notar que os valores de ϕ para os potenciais irrotacionais W do Humano P permanecem menores em relação aos do Humano N, podendo realmente significar uma medida, ainda a ser aprimorada, para a identificação do Pendelluft.

Tabela 8 – Valores de ϕ calculados para sujeitos Humanos com $D = 12$

Sujeito	Potencial	Valor de ϕ	
		Esquerda	Direita
Humano N	Divergência Nula E	15061,0	16566,0
	Irrotacional W	11248,0	18014,0
Humano P	Divergência Nula E	16313,0	13621,0
	Irrotacional W	8184,0	12491,0

Mesmo que os valores de ϕ tenham somente sido ligeiramente afetados pela alteração de D , veremos a seguir que essa alteração acentuou o grau de precisão para o índice P_d de Pendelluft. Portanto, a escolha sensível de valores adequados de D ao decorrer das

análises é de suma importância para a correta identificação dos pontos de extremos e, eventualmente, dos pontos críticos.

Propõe-se a substituição de um valor D nominal por um valor D percentual a ser aplicado em um pré-mapa de frequência normalizado para mitigar possíveis variações decorrentes da análise de épocas diferentes entre si. Entende-se “pré-mapa de frequência” como o mapa de frequência bruto, para determinados pontos de extremo de um determinado potencial escalar, prévio à aplicação de limiares de eliminação de pixels que tenham frequência inferior à mínima estabelecida. Dessa maneira, sua normalização permitirá a aplicação de um limiar percentual que pode conferir mais estabilidade e confiabilidade aos pontos de extremos considerados.

7.4.2 Índice P_d

A identificação do grau de Pendelluft P_d pelo método inovador proposto neste Trabalho alcança patamares expressivos ao se avaliar os resultados expostos para os dois tipos de sujeito. Através da metodologia que define pares “máx \rightarrow mín” (abreviada como “i/a”), associando cada ponto de máximo a um ponto de mínimo no mapa de frequência de extremos do potencial escalar irrotacional W , é possível estabelecer uma relação de proximidade e diferença de magnitude entre os pontos tidos como críticos para o fluxo de ar, assim estabelecendo e reforçando a primeira hipótese apresentada no início do Capítulo 6.

Os índices P_d [i/a] obtidos para Suíno N ($P_d = 1,25$, Fig. 28a) e para Suíno P ($P_d = 962$, Fig. 28a), reproduzidos na Tabela 9, são indicadores significativos para a ocorrência do fenômeno de Pendelluft em sequências de imagens de TIE, resultando em altos valores para representar a presença da doença e baixos valores para sua ausência. Entretanto, para o caso de pares mín \rightarrow máx (i/a), o valor de P_d para Suíno N acaba sendo consideravelmente alto ($P_d = 575,89$), mas ainda assim continua abaixo do mesmo valor calculado para Suíno P ($P_d = 1008,50$). Tal efeito em Suíno N pode ser explicado pela presença de mínimos consideravelmente distantes de baixa magnitude se comparados ao conjunto de máximos para esse mapa de frequência, elevando assim, o valor para o grau de Pendelluft.

Tabela 9 – Valores de P_d para suínos

Dados	Valor de P_d	
	i/a	a/i
Suíno N	1,25	575,89
Suíno P	962,00	1008,50

Já para os índices humanos, os resultados para a presença de Pendelluft e sua ausência não apresentam magnitudes tão distintas tal qual as de Suíno N e Suíno P, como pode

ser observado na Tabela 10 abaixo. Tal fato pode decorrer da presença de vários pontos considerados extremos porém de baixa relevância para uma análise expressiva do grau de Pendelluft.

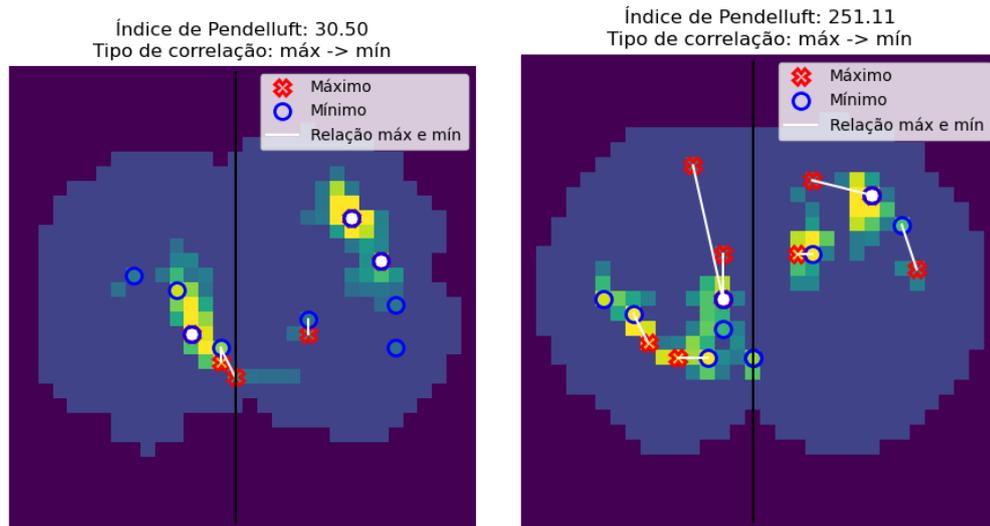
Tabela 10 – Valores de P_d para sujeitos humanos ($D = 6$)

Dados	Valor de P_d	
	i/a	a/i
Humano N	41,33	38,38
Humano P	78,56	58,06

Para o último caso mencionado ($D = 6$) ainda é possível ver valores menores de P_d para Humano N em relação a Humano P. Esse comportamento pode ser explorado para adequar o algoritmo a uma análise semi-automática *online*, utilizando-se da expertise dos profissionais pneumologistas em campo para informar ao algoritmo, em tempo real, se no momento em análise está ausente o fenômeno de Pendelluft. Dessa maneira, ao se estabelecer o grau P_{dB} basal do paciente para os momentos sem Pendelluft, o algoritmo torna-se capaz de realizar comparações entre o índice de Pendelluft calculado para o momento atual e o valor P_{dB} estabelecido previamente para sua ausência. Como foi verificado que durante o Pendelluft o índice P_d tem valor maior, então, ao se identificar um P_d [i/a] 70% maior que o P_{dB} [i/a] basal, por exemplo, pode-se informar à equipe médica que o paciente possivelmente está passando por Pendelluft.

Todavia, como mencionado ao final de 7.4.1, o ajuste do valor de D influenciou significativamente a identificação de pontos de extremos nos mapas de frequência para os sujeitos humanos, refletindo em um posicionamento mais preciso de acordo com a frequência geral de aparição desses máximos e mínimos do potencial irrotacional W através dos frames da sequência de TIE.

Para o cálculo do índice P_d [i/a] de grau de Pendelluft para os mapas de frequência dos sujeitos humanos utilizando $D = 12$ (Figuras 34 e 35), foram obtidos resultados satisfatórios apresentados na Figura 36 abaixo. Pode-se inferir, portanto, que o correto ajuste do limiar de frequência mínima acentua o grau de precisão do método inovador proposto para o cálculo de um índice de Pendelluft, amplificando os valores obtidos em situações de Pendelluft e atenuando-os em sua ausência.

Figura 36 – Índice de Pendelluft i/a para sujeitos humanos com $D = 12$.(a) Humano N. $P_d = 30,50$.(b) Humano P. $P_d = 251,11$.

Fonte: Do autor.

7.4.3 Considerações finais

O índice P_d denomina uma metodologia complexa e que abrange as relações dos extremos em diferentes lobos, o que permite maior liberdade de comparação e análise. Esse método pode beneficiar-se de uma métrica adicional que eleva o grau calculado de Pendelluft na ocorrência de um par inter-lobos, o que, por sua vez, denotaria um comportamento atípico para a dinâmica pulmonar já que, pela primeira hipótese, os pontos de máximo e mínimo mais relevantes deveriam se encontrar o mais próximo possível.

É importante observar que o método atual baseia-se na média aritmética simples dos coeficientes C obtidos para cada par de extremos e, por sua vez, é calculado a partir de $C_{REF,n} = |\alpha_{REF_n} - \alpha_{GOAL_m}| \cdot d(REF_n, GOAL_m)^2$, onde α_{REF_n} e α_{GOAL_m} são, respectivamente, as magnitudes do ponto de extremo referencial e do ponto de extremo mais próximo a ele (objetivo), e $d(REF_n, GOAL_m)^2$ é o quadrado da distância em pixels do ponto referencial ao objetivo. Dessa forma, quanto mais parecidas as magnitudes e quanto mais próximos os pontos do par estiverem, menor será o valor do coeficiente C para esse par. Entretanto, pontos distantes mas de igual magnitude dentro de um par resultarão em um coeficiente $C = 0$. Logo, se torna necessária uma revisão e adaptação da metodologia para contemplar casos como o citado, sendo possível avaliar quais seriam os pontos de referência mais significativos, através de sua magnitude, para assim considerá-los no cálculo de P_d .

A geração dos mapas de frequência se limita a um amalgama de frames de um determinado período de tempo, entendido como 5 ciclos respiratórios para os suínos e quase 10 ciclos para os humanos. Portanto, a determinação de um intervalo de tempo (em

quantidade de ciclos respiratórios) para se realizar as análises, promove a padronização do método e permite uma escolha mais clara de parâmetros como, por exemplo, o limiar de frequência mínima D . Assim, uma análise estendida em respeito ao tempo dentre os próprios máximos e mínimos (inter-relações entre os pontos de máximo, por exemplo) do campo do potencial W para cada CVM pode ajudar a identificar anomalias com mais precisão, podendo até identificar pontos que coexistam em lugares inapropriados.

8 Conclusão

Neste estudo, uma metodologia inovadora foi proposta para identificar a doença de Pendelluft em tempo real e de maneira automática baseando-se em sequências de imagens de Tomografia por Impedância Elétrica em humanos e animais. Inicialmente, o software em MATLAB foi, com sucesso, portado a Python, onde nenhuma inconsistência foi observada. Logo em seguida, a partir das sequências de TIE, o algoritmo de fluxo óptico de Farnebäck foi aplicado para cada par de frames consecutivos para a obtenção dos Campos Vetoriais de Movimento e esses foram comparados aos CVMs obtidos pelo algoritmo de FO de Horn & Schunck, alcançando resultados satisfatórios em termos de velocidade de processamento e qualidade dos vetores de deslocamento. Ao mesmo tempo, a segmentação semiautomática da área pulmonar foi realizada a partir de um limiar de intensidade geral dos pixels para toda a sequência analisada. Os CVMs, então, foram decompostos nas partes irrotacional, divergência nula e harmônica através da Decomposição Discreta de Helmholtz-Hodge para em seguida calcular os campos dos potenciais escalares irrotacional W e divergência nula E . Pontos críticos desses campos foram encontrados para cada CVM e mapas de frequência foram experimentados e obtidos como uma medida qualitativa baseada na hipótese. Por fim, os pontos de extremos dos mapas de frequências foram analisados por meio de uma correlação com base na magnitude e distância para se calcular um índice P_d de Pendelluft.

A aplicação do algoritmo de Farnebäck se mostrou eficiente pela qualidade dos CVMs gerados e pela velocidade dos cálculos (em média 1,37 ms por par de frames!), podendo muito bem ser empregado em uma análise em tempo real dos dados de TIE. Apesar disso, o grande gargalo temporal reside na extração dos campos dos potenciais escalares através da DDHH, que, em média, consumiu 1,90 segundos para cada CVM. Já a geração dos mapas de frequência é consideravelmente rápida e levou em média 4,82 ms por CVM! Esse dado é importante pois esse tempo “cabe” no intervalo entre dois frames e os mapas de frequência são de suma importância para a identificação de pontos diretamente relacionados aos fenômenos fisiológicos ocorrentes no pulmão. Em relação à qualidade dos mapas de frequência, foi possível estabelecer a significância do limiar de frequência mínima D para filtrar pontos menos relevantes do mapa e otimizar os cálculos e medidas que posteriormente são aplicados. A metodologia empregada para detecção de Pendelluft mostrou-se confiável, rápida (9,14 ms por mapa de frequência) e dependente da especificação correta de parâmetros nos estágios anteriores à sua aplicação. Seu comportamento, frente aos ajustes dos parâmetros, conseguiu expressar um índice decisivo para a identificação do fenômeno de Pendelluft.

A maior limitação enfrentada durante este trabalho está relacionada aos custos computacionais referentes ao tempo de processamento, especificamente devido à Decomposição Discreta de Helmholtz-Hodge para a extração dos campos de potenciais escalares. O

tempo consumido em sua aplicação em um conjunto de frames de uma sequência de TIE a uma taxa de amostragem de 50 Hz inviabiliza a utilização do algoritmo em tempo real, sendo necessário explorar a utilização de outros métodos para a aquisição dos campos de potenciais ou até a redução da taxa de amostragem para uma frequência compatível com a velocidade da DDHH.

A segmentação automática também tem um grau de importância elevado, já que é utilizada para definir a área de interesse onde as análises acontecerão. O método proposto utiliza de um algoritmo semiautomático baseando-se subjetivamente no estabelecimento manual de um limiar adequado para a geração da máscara pulmonar. Logo, a aplicação de uma máscara base universal para comparação e a implementação de métodos diferentes de segmentação representam direções importantes a serem seguidas para a total automatização do algoritmo de detecção de Pendelluft.

O método de fluxo óptico utilizado para a geração dos CVMs, apesar de rápido e já consolidado em outras áreas, carece de um estudo de sua influência nos resultados intermediários (mapas de frequência) e finais (índice de Pendelluft) e também da investigação objetiva de sua confiabilidade através de Ground Truths para, assim, determinar sua aptidão ou a necessidade de utilização de outro método.

É necessário enfatizar que a aplicação do método proposto para mais amostras de sujeitos saudáveis e sob Pendelluft é de suma importância para seu aprimoramento, cabendo ajustes às relações empregadas e aos parâmetros das análises anteriores à sua aplicação, a fim de expandir a interpretação de seus resultados e transformá-lo integralmente em um método robusto e flexível para seu uso proposto.

Portanto, no contexto deste estudo, a medida principal abordada, P_d , reforça a possibilidade de detectar e quantificar os fenômenos de Pendelluft. Sua otimização e aperfeiçoamento trazem à tona o potencial da aplicação desse método em tempo real, auxiliando a equipe médica em UTIs, aliviando a carga do monitoramento constante e oferecendo mais segurança aos pacientes acamados devido a doenças pulmonares.

Referências

- 1 EASTER, B. D. et al. The use of mechanical ventilation in the ed. *The American journal of emergency medicine*, v. 30, n. 7, p. 1183–1188, Sep 2012. Disponível em: <<https://doi.org/10.1016/j.ajem.2011.09.008>>. Citado na página 11.
- 2 ESTEBAN, A. et al. How is mechanical ventilation employed in the intensive care unit: An international utilization review. *The American journal of Respiratory and Critical Care Medicine*, v. 161, n. 5, p. 1183–1188, Feb 1999. Disponível em: <<https://doi.org/10.1164/ajrccm.161.5.9902018>>. Citado na página 11.
- 3 FRERICHS, I. et al. Monitoring regional lung ventilation by functional electrical impedance tomography during assisted ventilation. *Annals of the New York Academy of Sciences*, v. 873, n. 1, p. 493–505, Apr 1999. Disponível em: <<https://doi.org/10.1111/j.1749-6632.1999.tb09498.x>>. Citado na página 11.
- 4 COSTA, E. L. V. et al. Bedside estimation of recruitable alveolar collapse and hyperdistention by electrical impedance tomography. *Intensive Care Medicine*, v. 35, n. 6, p. 1132–1137, Mar 2009. Disponível em: <<https://doi.org/10.1007/s00134-009-1447-y>>. Citado na página 11.
- 5 LAWSON, J. D. The pendelluft sign. *The American Journal of the Medical Sciences*, v. 243, n. 4, p. 420–426, Apr 1962. Disponível em: <<https://doi.org/10.1097/0000441-196204000-00002>>. Citado na página 11.
- 6 SANG, L. et al. Qualitative and quantitative assessment of pendelluft: a simple method based on electrical impedance tomography. *Annals of Translational Medicine*, v. 8, n. 19, p. 1216, Oct 2020. Disponível em: <<https://doi.org/10.21037/atm-20-4182>>. Citados nas páginas 11, 12 e 13.
- 7 YOSHIDA, T. et al. Spontaneous effort causes occult pendelluft during mechanical ventilation. *American Journal of Respiratory and Critical Care Medicine*, v. 188, n. 12, p. 1420–1427, Dec 2013. Disponível em: <<https://doi.org/10.1164/rccm.201303-0539oc>>. Citados nas páginas 11 e 12.
- 8 FRERICHS, I. et al. Chest electrical impedance tomography examination, data analysis, terminology, clinical use, and recommendations: consensus statement of the translational eit development study group. *BMJ*, v. 72, n. 1, p. 83–93, Sep 2016. Disponível em: <<https://doi.org/10.1136/thoraxjnl-2016-208357>>. Citado na página 13.
- 9 WALSH, B. K.; SMALLWOOD, C. D. Electrical impedance tomography during mechanical ventilation. *Respiratory Care*, v. 61, n. 10, p. 1417–1424, Sep 2016. Disponível em: <<https://doi.org/10.4187/respcare.04914>>. Citado na página 13.
- 10 FOTI, G. et al. End-inspiratory airway occlusion: a method to assess the pressure developed by inspiratory muscles in patients with acute lung injury undergoing pressure support. *American Journal of Respiratory and Critical Care Medicine*, v. 156, n. 4 Pt 1, p. 1210–6, October 1997. ISSN 1073-449X. Citado na página 13.
- 11 HESS, D. R. Respiratory mechanics in mechanically ventilated patients. *Respiratory Care*, v. 59, n. 11, p. 1773–94, November 2014. ISSN 0020-1324. Copyright © 2014 by Daedalus. Citado na página 13.

- 12 COPPADORO, A. et al. Occurrence of pendelluft under pressure support ventilation in patients who failed a spontaneous breathing trial: an observational study. *Annals of Intensive Care*, v. 10, n. 1, p. 39, April 2020. ISSN 2110-5820. Disponível em: <<https://doi.org/10.1186/s13613-020-00654-y>>. Citado na página 13.
- 13 CHI, Y. et al. Prevalence and prognosis of respiratory pendelluft phenomenon in mechanically ventilated icu patients with acute respiratory failure: a retrospective cohort study. *Annals of Intensive Care*, v. 12, n. 1, p. 22, March 2022. ISSN 2110-5820. Disponível em: <<https://doi.org/10.1186/s13613-022-00995-w>>. Citado na página 13.
- 14 FIDELIS, V. J. *Directional analysis of lung motion in Pendelluft from electrical impedance tomography images*. Monografia (Trabalho de Conclusão de Curso) — Universidade Federal do ABC, UFABC, São Bernardo do Campo, SP - Brazil, 2022. Disponível em: <http://dx.doi.org/10.1007/978-3-030-70601-2_289>. Citados nas páginas 14, 18, 19, 24, 28, 29, 35, 37, 38, 39, 50, 63 e 64.
- 15 OTSU, N. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 9, n. 1, p. 62–66, 1979. Citado na página 14.
- 16 HORN, B. K.; SCHUNCK, B. G. Determining optical flow. *Artificial Intelligence*, v. 17, n. 1, p. 185–203, 1981. ISSN 0004-3702. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0004370281900242>>. Citados nas páginas 15, 16 e 28.
- 17 BAKER, S. et al. A database and evaluation methodology for optical flow. *International Journal of Computer Vision*, v. 92, n. 1, p. 1–31, March 2011. ISSN 1573-1405. Disponível em: <<https://doi.org/10.1007/s11263-010-0390-2>>. Citados nas páginas 15 e 36.
- 18 FARNEB"ACK, G. Two-frame motion estimation based on polynomial expansion. In: BIGUN, J.; GUSTAVSSON, T. (Ed.). *Image Analysis*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003. p. 363–370. ISBN 978-3-540-45103-7. Citados nas páginas 15, 28 e 29.
- 19 NEMADE, N.; GOHOKAR, V. V. Comparative performance analysis of optical flow algorithms for anomaly detection. In: *Proceedings of International Conference on Communication and Information Processing (ICCIP) 2019*. [s.n.], 2019. Disponível em: <<https://ssrn.com/abstract=3419775>>. Citados nas páginas 16, 28 e 35.
- 20 ORTIZ, T. d. A. *PEEP titration guided by Electrical impedance tomography by fast and slow maneuver and pulmonary stability with protective mechanical ventilation strategy in a swine model of Acute Respiratory Distress Syndrome*. Tese (Doutorado) — Universidade de São Paulo (USP), Faculdade de Medicina (FM/SBD), São Paulo, 2017. Citado na página 19.
- 21 GRYCHTOL, B. et al. Towards lung EIT image segmentation: automatic classification of lung tissue state from analysis of EIT monitored recruitment manoeuvres. *Physiological Measurement*, v. 31, n. 8, p. S31–S43, Aug 2010. ISSN 1361-6579 (Electronic) and 0967-3334 (Linking). Disponível em: <<https://doi.org/10.1088/0967-3334/31/8/S03>>. Citado na página 22.

- 22 ZIFAN, A.; LIATSI, P.; CHAPMAN, B. E. The use of the kalman filter in the automated segmentation of eit lung images. *Physiological Measurement*, IOP Publishing, v. 34, n. 6, p. 671, may 2013. Disponível em: <<https://dx.doi.org/10.1088/0967-3334/34/6/671>>. Citado na página 22.
- 23 KO, Y.-F.; CHENG, K.-S. U-net-based approach for automatic lung segmentation in electrical impedance tomography. *Physiological Measurement*, v. 42, n. 2, p. 025002, Mar 2021. ISSN 1361-6579 (Electronic) and 0967-3334 (Linking). Disponível em: <<https://doi.org/10.1088/1361-6579/abe021>>. Citado na página 22.
- 24 SHAH, S. T. H.; XUEZHI, X. Traditional and modern strategies for optical flow: an investigation. *SN Applied Sciences*, v. 3, n. 3, p. 289, February 2021. ISSN 2523-3971. Disponível em: <<https://doi.org/10.1007/s42452-021-04227-x>>. Citado na página 28.
- 25 BRADSKI, G. The OpenCV Library. *Dr. Dobb's Journal of Software Tools*, 2000. Citados nas páginas 28 e 29.
- 26 MENDES, L. P. N. et al. A comparative study of optical flow methods for fluid mechanics. *Experiments in Fluids*, v. 63, n. 1, p. 7, 2021. ISSN 1432-1114. Disponível em: <<https://doi.org/10.1007/s00348-021-03357-7>>. Citado na página 28.
- 27 SPURK, J.; AKSEL, N. *Fluid Mechanics*. Springer International Publishing, 2019. ISBN 9783030302597. Disponível em: <<https://books.google.com.br/books?id=617BDwAAQBAJ>>. Citado na página 37.
- 28 GUO, Q.; MANDAL, M. K.; LI, M. Y. Efficient hodge–helmholtz decomposition of motion fields. *Pattern Recognition Letters*, v. 26, n. 4, p. 493–501, 2005. ISSN 0167-8655. ICAPR 2003. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167865504001886>>. Citados nas páginas 37 e 39.
- 29 POLTHIER, K.; PREUSS, E. Identifying vector field singularities using a discrete hodge decomposition. In: *Mathematics and Visualization*. Springer Berlin Heidelberg, 2003. p. 113–134. Disponível em: <https://doi.org/10.1007/978-3-662-05105-4_6>. Citados nas páginas 39 e 40.
- 30 HAUSDORFF, F. *Set Theory*. American Mathematical Society, 2005. (AMS Chelsea Publishing Series). ISBN 9780821838358. Disponível em: <<https://books.google.com.br/books?id=yvVIH16k0YC>>. Citado na página 41.

A Software Desenvolvido

A seguir encontram-se quatro seções que descrevem o funcionamento dos códigos e arquivos empregados e desenvolvidos nesta pesquisa. O intuito é utilizar como referência caso deseje executá-los ou esclarecer algum funcionamento durante a leitura deste estudo. Disponíveis em <https://github.com/ma-x-om/pendelluft>.

A.1 Códigos principais

Códigos que serão rodados sequencialmente para realizar as análises de pendelluft. Todos estão em *Python* e a maioria necessita dos códigos associados (seção abaixo) para funcionar.

1. *Code_1.py*: carrega o vídeo de TIE em formato de texto (.txt), aplica o algoritmo de fluxo óptico de Farnebäck, salva no arquivo “Imagens_U_V.mat” todos os frames do arquivo carregado e os vetores u e v do campo vetorial de movimento calculado pelo fluxo óptico, por fim, faz a renderização das imagens e da soma vetorial dos vetores e salva as imagens em uma pasta.
 - carrega: arquivo de texto com vídeo de TIE;
 - salva: “Imagens_U_V.mat”;
 - substitui: Gera_Imagens_E_Campos_Vetoriais.m, HSOptical.m e quiversDHHD2D.m.

2. *Code_2.py*: carrega o arquivo “.mat” salvo em “Code_1.py” e usa os vetores u e v para extrair os potenciais Curl-Free (potW) e Divergence-Free (potE) através da decomposição discreta de Helmholtz-Hodge. Por fim, salva no arquivo “potenciaisE_W.mat” os potenciais extraídos e em “time_log.txt” o tempo levado para a execução da decomposição.
 - importa: runDHHD.py (por Prof. Dr. John A. Sims) e Automatic_Segmentation.py;
 - carrega: “Imagens_U_V.mat”;
 - salva: “LungMask.mat”, “potenciaisE_W.mat” e “time_log.txt”;
 - substitui: Gera_Potenciais.m, potential_calculation2.m e quiversDHHD2D.m.

3. *Code_3.py*: carrega os arquivos “.mat” salvo em “Code_2.py” e usa os potenciais escalares e a máscara para identificar os pontos críticos de cada potencial através de um mapa de frequência analisando os máximos e mínimos de cada potencial, mostrando um gráfico ao final. Também calcula o índice ϕ de Pendelluft descrito em

(14) por Fidelis *et al* e mostra sua representação gráfica. Ao fim, salvam-se os cálculos realizados em 3 arquivos específicos, que podem ser acessados posteriormente pelo código auxiliar “Loader.py” para recriar os gráficos exibidos.

- importa: `posicoes.py` e `freqmap.py`;
 - carrega: “`potenciaisE_W.mat`” e “`LungMask.mat`”;
 - salva: “`calculos_phi.mat`”, “`calculos_pos.mat`” e “`calculos_freqmap.mat`”;
 - substitui: `Principal.m`, `Posicoes.m` e `freqmap.m`.
4. *Code_4.py*: carrega os arquivos “`calculos_freqmap.mat`”, salvo em “`Code_3.py`”, e “`LungMask.mat`” e usa o mapa de frequência para calcular um índice inovador para identificação de `pendelluft`.
- carrega: “`calculos_freqmap.mat`” e “`LungMask.mat`”.

A.2 Códigos associados

Por ordem alfabética, são os códigos importados pelos códigos principais e precisam estar no mesmo diretório que eles.

- *Automatic_Segmentation.py*: realiza a segmentação automática da área pulmonar de uma dada sequência de frames de TIE através de um valor de limiar informado. Salva a máscara em um arquivo “`LungMask.mat`”.
 - argumentos: arquivo de imagens “.mat”, diretório para salvar máscara, valor de limiar e valor booleano para exibir ou não a máscara calculada.
- *freqmap.py*: gera o mapa de frequências necessário para os cálculos dos índices de `Pendelluft`. Convertido e otimizado de MATLAB para Python pelo autor.
 - argumentos: índices dos pontos de interesse, limiar de frequência para cada pixel (D), raio para determinação do extremo local (rad), número de linhas e número de colunas;
 - retorna: lista com índices dos pontos importantes do mapa e mapa de frequência.
- *posicoes.py*: convertido e otimizado de MATLAB para Python pelo autor.
 - argumentos: matriz de potencial escalar e matriz booleana indicando os pontos com máximo ou mínimo;
 - retorna: em nosso contexto, retorna uma lista com os índices para os pontos de máximo e mínimo de cada potencial.

- *potential_calculation2.py*: por Prof. Dr. John A. Sims.
 - argumentos: matrizes x e y (meshgrids de u), vetor u do campo vetorial de movimento, vetor v e informações do nó;
 - retorna: em nosso contexto, retorna uma lista com os índices para os pontos de máximo e mínimo de cada potencial.
- *runDHHD.py*: por Prof. Dr. John A. Sims e otimizado para o contexto pelo autor.
 - importa: *potential_calculation2.py*;
 - argumentos: vetor u do campo vetorial de movimento, vetor v e valor booleano para ativar a exibição do tempo de processamento;
 - retorna: potenciais escalares irrotacional e divergence-free.

A.3 Códigos auxiliares

- *Loader.py*
- *Mask_tester.py*
- *matlab_img_gen.py*
- *OF_time_comparison.py*
- *OF_UVs_comparison.py*
- *OF_visual_comparison.py*
- *UV_trial.py*
- *video_maker_from_array.py*

A.4 Arquivos adicionais

- *LungMask.mat*: máscara do pulmão manualmente segmentada por Fidelis *et al* (14);
- *genyfirmin_0_21870_imagens.txt*: sequência de imagens de TIE do humano alternando entre momentos de ausência e presença de Pendelluft. Disponível em repositório Google Drive do autor;
- *teste1_pendelluft.txt*: sequência de imagens de TIE de suíno com Pendelluft (Porco P);
- *teste2_sem_pendelluft.txt*: sequência de imagens de TIE de suíno sem patologias pulmonares detectadas (Porco N).