

Termografia de infravermelhos para análise de humidade em paredes – ensaios preliminares e perspectivas futuras

Infrared thermography for moisture analysis in walls – preliminary tests and future perspectives

L.C.M. Dafico^{a†}, E. Barreira^a, R.M.S.F. Almeida^b, R.S. Vicente^c

^a *CONSTRUCT-LFC, Departamento de Engenharia Civil, Faculdade de Engenharia (FEUP), Universidade do Porto, Rua Dr Roberto Frias, s/n, 4200-465 Porto, Portugal*

^b *Departamento de Engenharia Civil, Instituto Politécnico de Viseu, Campus Politécnico de Repeses 3504-510 Viseu, Portugal*

^c *RISCO, Departamento de Engenharia Civil, Universidade de Aveiro, Campus Universitário de Santiago 3810-193 Aveiro, Portugal*

[†] *Autor para correspondência: up201911110@up.pt*

RESUMO

Defeitos relacionados à humidade representam 70% das patologias reportadas em edificações, comprometendo a durabilidade de soluções e componentes e a médio prazo o conforto dos utilizadores. A termografia de infravermelhos (TIV) é uma técnica que possui grande potencial para mapear a humidade em edificações, mas carece de critérios para análises quantitativas que correlacionem diferenças de temperatura superficial com o teor de humidade. Apesar dos recentes avanços na utilização de métodos computacionais e técnicas de ensaio para automatizar a deteção de defeitos em edificações, o uso destes para análise de problemas associados à presença de humidade não está consolidado. Este trabalho apresenta os resultados de ensaios preliminares realizados com a TIV e o método gravimétrico para avaliar a correlação entre o gradiente de temperatura e o teor de humidade de alvenarias e analisar o gradiente térmico de regiões húmidas em diferentes condições ambientais. Análises estatísticas mostraram que a ordem de magnitude do gradiente de temperatura que indica altos teores de humidade é substancialmente diferente nos cenários analisados. Também são apontadas as limitações do uso da técnica e as indicações de pesquisas futuras que podem ser conduzidas para automatizar a identificação de defeitos relacionados à humidade em edificações, reduzindo o grau de subjetividade no diagnóstico de defeitos.

ABSTRACT

Defects related to moisture problems represent 70% of reported building defects, hindering the long-term durability of building solutions and components and, in the medium term, users' comfort. Infrared thermography (IRT) is a technique that has great potential for mapping moisture in buildings but lacks criteria for quantitative analysis that correlate surface temperature differences with moisture content. Although the recent advances in the use of computational methods and testing techniques to automate the detection of defects in buildings, their use for moisture assessment is not consolidated. This work presents the results of preliminary tests carried out with the IRT and the gravimetric method to evaluate the correlation between the temperature gradient and the moisture content of masonry and to analyse the thermal gradient of moist areas in different environmental conditions. Statistical analysis showed that the order of magnitude of the temperature gradient that indicates high moisture content is substantially

Palavras-chave:

Termografia de Infravermelhos; humidade; diagnóstico automatizado.

Keywords:

Infrared Thermography; Moisture; Automated diagnosis.

different in the analysed scenarios. Limitations in the use of IRT and indications for future research that can be conducted to automate the identification of defects related to moisture in buildings, reducing the degree of subjectivity in the diagnosis of defects, are also pointed out.

1. Introdução

A humidade é uma das principais causas de degradação de elementos construtivos e a complexidade do fenómeno envolvido na humedificação e secagem dos materiais dificulta a interpretação dos resultados durante a inspeção de edificações. Um diagnóstico adequado de patologias relacionadas à humidade é importante para garantir a durabilidade das edificações e para assegurar o conforto dos usuários e a qualidade do ambiente interno, uma vez que altos teores de humidade podem levar à redução da performance térmica, à cristalização de sais e até mesmo à redução da resistência à compressão, bem como ao crescimento de mofo, aumentando o risco de infeções respiratórias dos usuários [1-6].

As técnicas escolhidas para detetar a presença de humidade devem proporcionar resultados rápidos e de fácil interpretação e permitir a definição da extensão do dano e a sua evolução ao longo do tempo [7]. O diagnóstico de defeitos relacionados à humidade pode ser feito com técnicas usuais, como o método gravimétrico, que consiste na extração de amostras, pesagem e secagem destas, fornecendo resultados altamente confiáveis [8], ou com métodos não destrutivos, como as técnicas baseadas na medição das propriedades elétricas dos materiais (método dielétrico, micro-ondas, tomografia de impedância elétrica), métodos químicos (método do papel indicador), método baseado na medição das propriedades térmicas (termografia infravermelha) e métodos com radiação (ressonância magnética nuclear e atenuação de raios gama) [2, 9].

A termografia de infravermelhos (TIV) pode ser utilizada para mapear a distribuição de humidade nos materiais de construção, pois mudanças no teor de humidade dos materiais estão relacionadas a mudanças em sua temperatura superficial, conforme três fenómenos físicos: resfriamento evaporativo, reduzida resistência térmica e elevada capacidade de armazenamento de calor [1].

O resfriamento evaporativo ocorre porque a evaporação superficial é uma reação endotérmica que reduz a temperatura da superfície. Quando o teor de humidade do material é superior à humidade do ambiente, ocorre a evaporação, o que leva à redução na temperatura superficial, logo, na ocorrência apenas desse fenómeno, áreas com altos teores de humidade aparecerão nas imagens térmicas com temperaturas menores do que áreas mais secas [10]. Os fatores que mais influenciam na evaporação superficial são a humidade relativa do ambiente próximo à superfície, a temperatura do ar e o teor de humidade, teor de sais solúveis e outras propriedades físico-químicas do material [11, 12].

Em relação à redução da resistência térmica, sabe-se que o calor específico e a condutibilidade térmica da água são superiores àqueles dos materiais secos. Portanto, quando há água nos poros dos materiais, sua densidade, calor específico e condutibilidade térmica aumentam [12] e a resistência térmica diminui. Quando há fluxo de calor, será criado um padrão térmico heterogêneo com diferentes temperaturas superficiais entre as regiões secas e húmidas [1].

Além disso, os materiais húmidos respondem mais devagar a mudanças na temperatura do ar do que os materiais secos. Com base nesse princípio, o aquecimento de uma superfície seca ocorre mais rapidamente do que o aquecimento de uma superfície húmida e a taxa de resfriamento na região seca também é maior do que em uma região húmida [1].

A TIV é uma técnica muito utilizada para identificar humidade e outros defeitos em edificações devido à facilidade de uso e ao baixo custo, tempo e esforço para a sua utilização [13]. Porém, apesar da sua aplicabilidade para detetar humidade, existe uma lacuna na literatura quanto à análise quantitativa que correlaciona diferenças na temperatura superficial com o teor de humidade devido à complexidade e variabilidade dos fenómenos envolvidos [11, 12, 14].

Nos últimos anos, a indústria da construção está vivenciando uma revolução tecnológica guiada pela digitalização e automação [15]. Vários estudos têm sido conduzidos para integrar os

resultados de tecnologias de inspeção em edificações com técnicas de machine learning e com softwares BIM, por meio do desenvolvimento de algoritmos que possibilitam automatizar a identificação de defeitos e da implementação dos resultados das técnicas de inspeção em modelos BIM, facilitando a visualização e identificação de defeitos e reduzindo a subjetividade na análise dos resultados das inspeções.

As técnicas baseadas em machine learning possuem grande potencial para análise e processamento de imagens térmicas [13, 16], contudo, apesar do aumento significativo do seu uso na engenharia civil, existem poucos estudos quanto ao uso dessas técnicas e ferramentas no campo de inspeções de edificações, especialmente em relação à análise de umidade.

Desta forma, este artigo tem como objetivos: (i) apresentar resultados preliminares de ensaios realizados com a TIV para a identificação de critérios indicativos de umidade em alvenarias de tijolos cerâmicos revestidos com argamassa em duas condições distintas de temperatura e umidade relativa ambiente; e (ii) apresentar os recentes avanços com o uso de machine learning para automatizar a identificação de defeitos em edificações e também os estudos sobre a integração dos resultados de técnicas de inspeção em modelos BIM para facilitar o diagnóstico e o monitoramento de defeitos em edificações.

2. Definição de critérios indicativos de umidade em alvenarias com a TIV

2.1. Materiais e métodos

Os experimentos laboratoriais para monitoramento de umidade com a TIV e o método gravimétrico (MG) foram conduzidos conforme as etapas constantes da Figura 1 - .

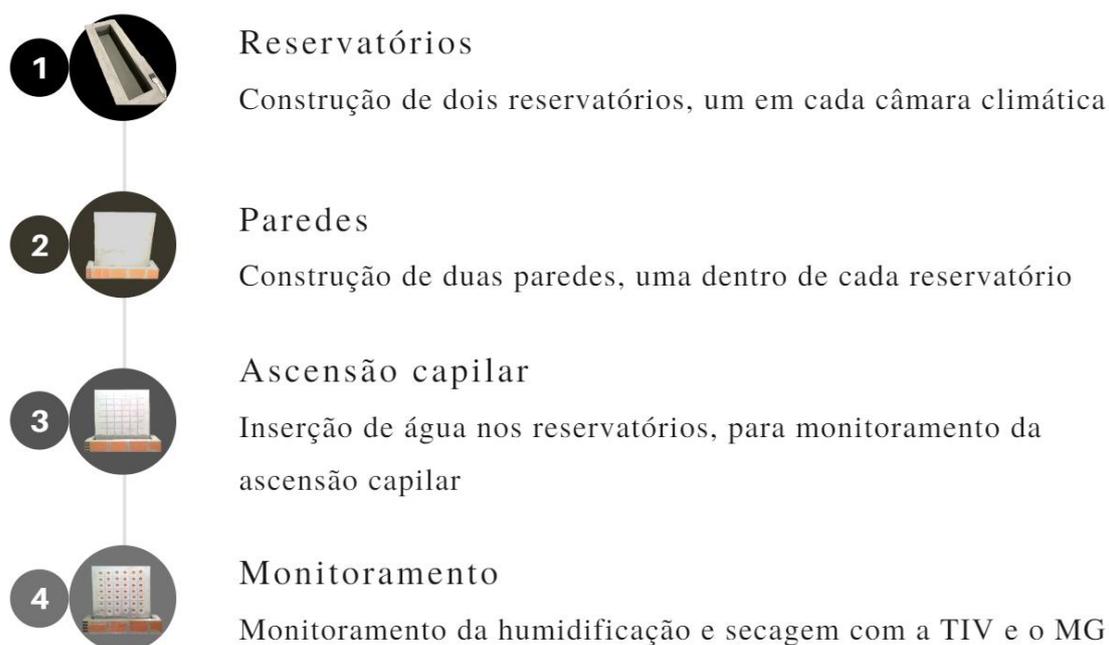


Figura 1 - Etapas dos experimentos laboratoriais.

Para esta campanha experimental, foram construídos e impermeabilizados dois reservatórios em duas câmaras climáticas diferentes. Em uma das câmaras, denominada de “câmara quente”, a temperatura e a umidade relativa foram ajustadas a aproximadamente 30°C e 60%, respectivamente. A outra câmara climática, denominada de “câmara fria”, foi ajustada com temperatura e umidade relativa de aproximadamente 15°C e 90%, respectivamente. Dentro de cada um dos reservatórios foi construída uma parede de dimensões de 0,93 m de largura por 0,99 m de altura, executada em tijolo cerâmico com dimensões de 9 x 19 x 29 cm³ e com revestimento feito em argamassa pré-doseada de espessura de 2 cm. As paredes não foram revestidas com argamassa até a cota de 13 cm, com o objetivo de acelerar a percolação da água por ascensão

capilar.

Em seguida, foram efetuados os ensaios para determinação da emissividade, segundo a norma ASTM E1933-99a [17], e para determinação da temperatura aparente refletida, conforme a ASTM E1862-97 [18]. Logo após, foram demarcados nas paredes os locais para monitoramento com a TIV e o MG e foi inserida água nos reservatórios para análise da percolação da água por ascensão capilar. Imediatamente após a fase de humidificação, iniciou-se a fase de secagem, nas mesmas condições ambientais. A Tabela 1 - contém o período total de monitoramento das fases de humidificação e secagem em cada uma das câmaras climáticas.

Tabela 1 - Período total de monitoramento em cada câmara.

	Câmara quente		Câmara fria	
	Humidificação	Secagem	Humidificação	Secagem
Tempo de monitoramento	359h	263h	387h	407h

Durante as fases de humidificação e secagem, foram efetuadas 12 e 11 medições, respetivamente, em ambas as paredes. No início de cada fase foram efetuadas medições com menor intervalo de tempo e com o decorrer do ensaio as medições ficaram mais espaçadas. Em cada tempo de monitoramento, foram tiradas uma imagem térmica e uma imagem digital e, em seguida, foram extraídos provetes de toda uma coluna (vertical), para análise da humidade com o MG.

A câmara de infravermelhos utilizada foi o modelo E40 da marca FLIR Systems, a qual possui resolução de infravermelhos de 160 x 120 pixels. Na Figura 2 - apresenta-se o esquema da realização dos ensaios dentro das câmaras climáticas. A metodologia de construção dos provetes, a especificação de equipamentos e materiais e o procedimento de realização dos experimentos laboratoriais constam de maneira mais detalhada em [19].

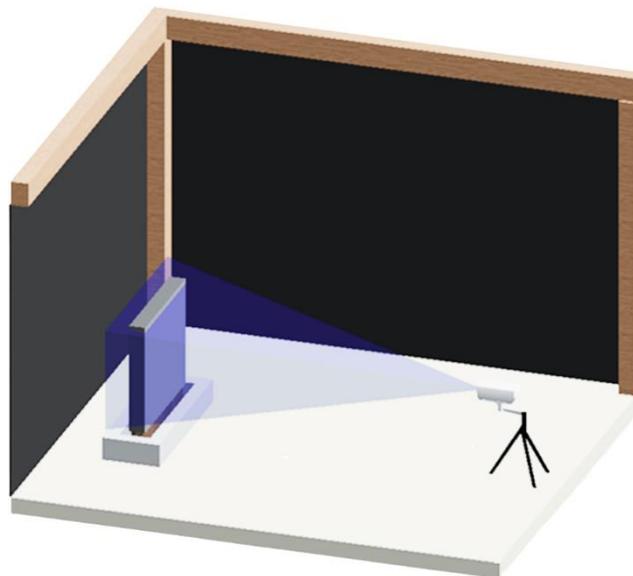


Figura 2 - Representação esquemática do layout dos experimentos laboratoriais

A análise da correlação entre o gradiente térmico identificado pela TIV entre as regiões húmidas e a região seca (ΔT) e o teor de humidade medido pelo método gravimétrico (u) foi feita por meio de uma análise de regressão. Em seguida, efetuou-se a análise da matriz de correlação entre as variáveis contínuas do ensaio, nomeadamente ΔT , “ u ” e fase. O objetivo da análise da correlação foi verificar se as variáveis são estatisticamente significativas entre si e qual é o grau da correlação linear entre estas. Posteriormente, fez-se a análise dos gráficos de dispersão dos pontos em cada uma das fases do ensaio (humidificação e secagem), com rótulo de dados de tempo, para analisar os valores de ΔT e “ u ” obtidos em cada momento do ensaio.

A análise de clusters de K-médias foi efetuada com o objetivo de agrupar os pontos de

acordo com as variáveis ΔT e “u”, para verificar os ΔT s indicativos de pontos com altos teores de humidade em cada um dos cenários de medição. A análise de clusters de K-médias foi precedida da análise de cluster hierárquico, para identificação do arranjo de clusters mais adequado.

2.2. Resultados e Discussão

Primeiramente, realizou-se a análise qualitativa dos resultados obtidos nos ensaios de humidificação e secagem das paredes situadas nas câmaras quente e fria. **A origem da referência não foi encontrada.** contém as imagens digitais e térmicas obtidas na fase de humidificação da parede situada na câmara quente com: (a) 2 horas; (b) 119 horas; e (c) 359 horas de ensaio. Com 2 horas de humidificação já foi possível visualizar um gradiente de temperatura entre a base da parede e a parte superior. Já com 119 horas de ensaio, o gradiente térmico foi superior àquele identificado ao final do ensaio, com 359 horas de medição. Ainda, ressalta-se que foram identificados gradientes térmicos em locais onde a humidade não era visível a olho nu nas fases de humidificação e secagem nas paredes localizadas em ambas as câmaras climáticas. As imagens digitais e térmicas referentes às demais etapas do ensaio constam de [19].

A análise de regressão efetuada para identificação do modelo mais adequado retornou os resultados de R^2 e os parâmetros das equações constantes da

e da **A origem da referência não foi encontrada.**, referentes aos ensaios com a parede da câmara quente e da câmara fria, respetivamente. **A origem da referência não foi encontrada.** contém os gráficos com as curvas de cada modelo de regressão. Os dados referentes às três primeiras medições efetuadas na humidificação da parede da câmara fria precisaram ser descartados devido a problemas de medição.

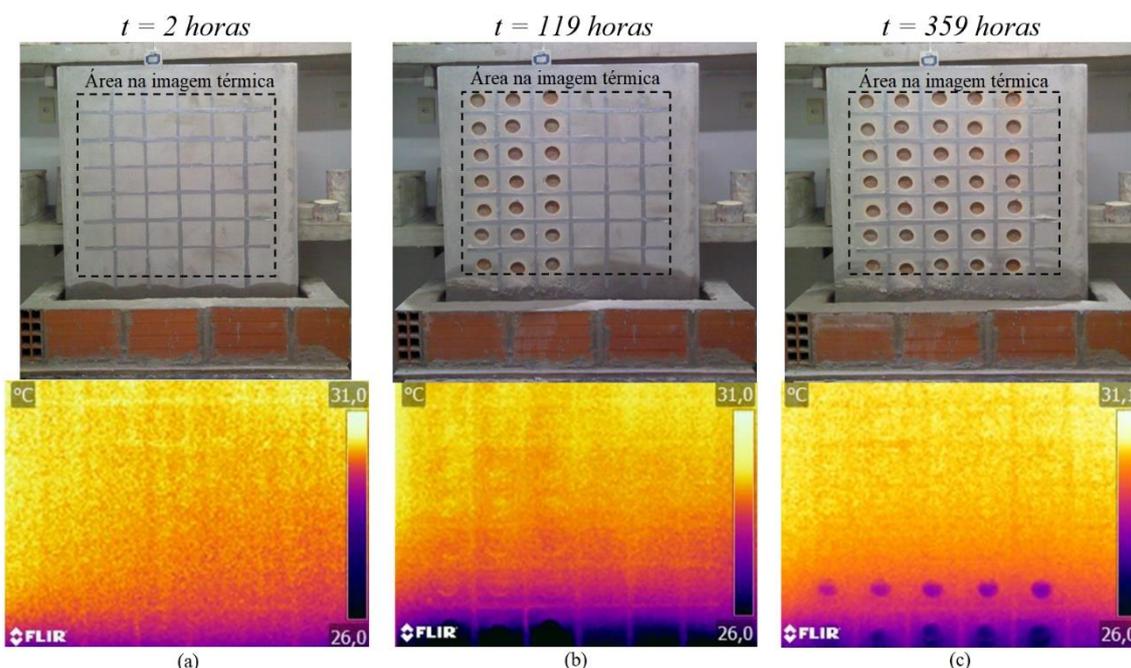


Figura 3 - Imagens digitais e térmicas da fase de humidificação da parede na câmara quente. (a) 2 horas de medição; (b) 119 horas de medição; (c) 359 horas de medição.

Tabela 2 - Valores de R^2 e estimativas de parâmetro para os modelos de regressão – parede câmara quente.

Modelo	Estimativas de parâmetro			
	R^2	Constante	b1	b2
Linear	0,689	-0,526	0,475	
Logarítmico	0,706	-0,992	1,837	
Quadrático	0,705	-1,522	1,052	-0,069
Potência	0,399	0,069	2,032	

Tabela 3 - Valores de R² e estimativas de parâmetro para os modelos de regressão – parede câmara fria.

Modelo	Estimativas de parâmetro			
	R ²	Constante	b1	b2
Linear	0,911	-0,368	0,125	
Logarítmico	0,905	-0,765	0,658	
Quadrático	0,913	-0,494	0,175	-0,004
Potência	0,710	0,001	3,579	

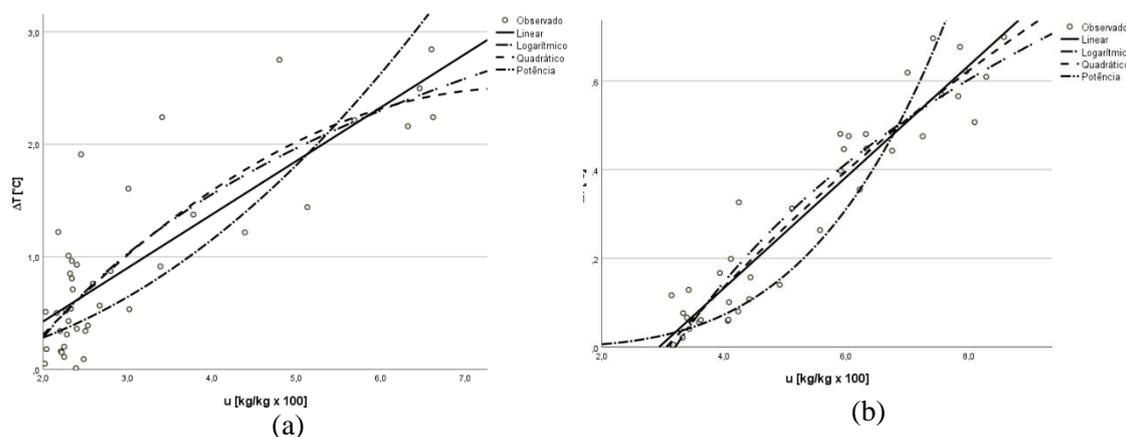


Figura 4 - Curvas de regressão. (a) Parede câmara quente; (b) Parede câmara fria.

Os modelos linear, logarítmico e quadrático apresentaram valores elevados de R² nos dois ensaios, sendo os resultados ligeiramente superiores para a parede localizada na câmara fria. Este facto pode estar relacionado com um eventual maior impacto da temperatura e humidade relativa do ar nos resultados. Para seleccionar, dos três modelos de regressão, qual o que melhor se ajusta às medições efetuadas, foi calculada a raiz do erro quadrático médio (RMSE) para análise da diferença entre os valores fornecido por cada modelo em relação aos valores observados. **A Erro! A origem da referência não foi encontrada.** contém as equações dos modelos que apresentaram os maiores valores de R² com menores valores de erro em cada um dos ensaios. Como o gradiente térmico depende das propriedades dos materiais e das condições ambiente (temperatura, humidade relativa, vento, dentre outras), ressalva-se que as equações apresentadas restringem-se às condições específicas desta campanha experimental.

Tabela 4 - Equação e parâmetros dos modelos de regressão seleccionados.

Parede	Modelo de melhor ajuste	Equação	R ²	RMSE
Câmara quente	Logarítmico	$\Delta T = 1,837\ln(u) - 0,992$	0,71	0,45
Câmara fria	Linear	$\Delta T = 0,125u - 0,368$	0,91	0,07

A Erro! A origem da referência não foi encontrada. e a

contêm as matrizes de correlações dos resultados nas câmaras quente e fria, respetivamente, efetuada com as variáveis contínuas do experimento. São apresentados o coeficiente de correlação de pearson (r) e o p-value. Os valores marcados com “***” indicam uma correlação linear estatisticamente significativa entre as duas variáveis, logo, constata-se que o ΔT apresentou uma correlação linear estatisticamente significativa e com altos valores com o “u” em todos os ensaios. A fase apresentou correlação estatisticamente significativa com o ΔT na parede da câmara quente, entretanto, com um baixo valor, o que indica que os valores de ΔT durante a fase humedificação divergiram ligeiramente dos valores de ΔT durante a fase de secagem nesta câmara.

Tabela 5 - Matriz de correlações das variáveis com coeficiente de pearson (r) e p-value – parede câmara quente.

		ΔT	u	Fileira	Coluna	Fase
ΔT	r	1				
	p-value	-				
u	r	0,83**	1			
	p-value	<0,001	-			
Fase	r	0,385**	0,264	-0,589**	0,034	1
	p-value	<0,001	0,091	<0,001	0,564	-

Tabela 6 - Matriz de correlações das variáveis com coeficiente de pearson (r) e p-value – parede câmara fria.

		ΔT	u	Fileira	Coluna	Fase
ΔT	r	1				
	p-value	-				
u	r	0,955**	1			
	p-value	<0,001	-			
Fase	r	-0,08	0,032	0,000	-0,134	1
	p-value	0,196	0,806	1,000	0,010	-

A **Erro! A origem da referência não foi encontrada.**(a) retrata o gráfico de dispersão com os resultados da parede da câmara quente, separados conforme a fase (humidificação e secagem) e com rótulos do tempo de medição, em horas. Com 7 horas de humidificação, os valores de ΔT já haviam ultrapassado 1,0°C, mas o valor máximo de ΔT (2,8°C) foi obtido com 119 horas de ensaio, a partir de quando passou a diminuir, chegando a um valor ligeiramente inferior ao final do ensaio de humidificação (2,2°C). Em relação ao ensaio efetuado na parede situada na câmara fria (**Erro! A origem da referência não foi encontrada.**(b)), como as três primeiras medições foram descartadas, monitorou-se o ΔT a partir de 23 horas, momento em que este já apresentava valores superiores a 0,4°C. O ΔT máximo nesta câmara foi identificado também com 119 horas de medição (0,7°C), seguindo o mesmo padrão identificado na câmara quente e reduzindo ligeiramente até o final do ensaio de humidificação, chegando a 0,57°C ao final.

A análise de clusters foi efetuada com o objetivo de agrupar os dados de ΔT e “u” com características semelhantes, conforme consta da Figura 6. Foi definido o agrupamento em três clusters. Em seguida, efetuou-se uma análise descritiva exploratória para identificação dos valores de ΔT e “u” de cada cluster. A análise dos boxplots gerados possibilitou a identificação de outliers e, após a eliminação dos outliers, foram encontrados os resultados constantes da **Erro! A origem da referência não foi encontrada.**

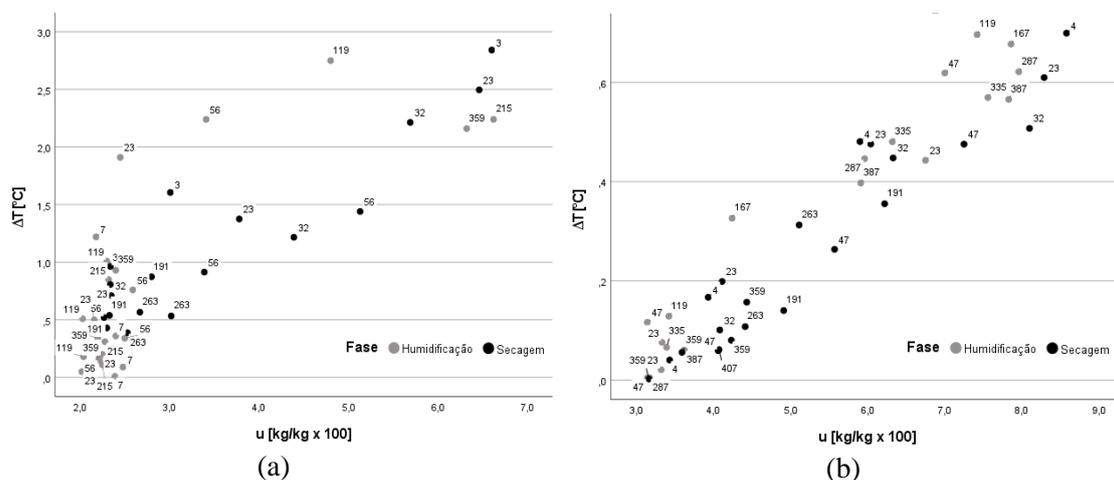


Figura 5 - Gráficos de dispersão dos pontos com rótulo de tempo [h]. (a) Parede câmara quente; (b) Parede câmara fria.

A

contém o limite inferior e superior de ΔT e “u” para cada um dos clusters, para um intervalo de confiança de 95%. Os valores sombreados em vermelho (cluster 1) indicam os valores de ΔT para pontos com teor de humidade elevado, enquanto os valores sombreados em amarelo (cluster 2) indicam os valores de ΔT para humidade intermédia e os valores sombreados em verde (cluster 3) indicam valores de ΔT para teores de humidade mais baixos. Para a parede na câmara quente, ΔT s acima de $1,06^{\circ}\text{C}$ indicam pontos com humidade intermédia e acima de $1,95^{\circ}\text{C}$ com humidade elevada, enquanto na câmara fria ΔT s acima de $0,40^{\circ}\text{C}$ já indicam humidade intermédia e acima de $0,55^{\circ}\text{C}$ indicam humidade elevada, o que mostra a grande influência das condições ambientais no gradiente térmico que indica locais húmidos. Como a humidade relativa na câmara fria era muito elevada (90%), ressalta-se que os provetes extraídos das regiões secas nesta câmara (sem humidade proveniente da água em ascensão capilar) apresentaram teores de humidade superiores àqueles identificados nos provetes das regiões secas na câmara quente.

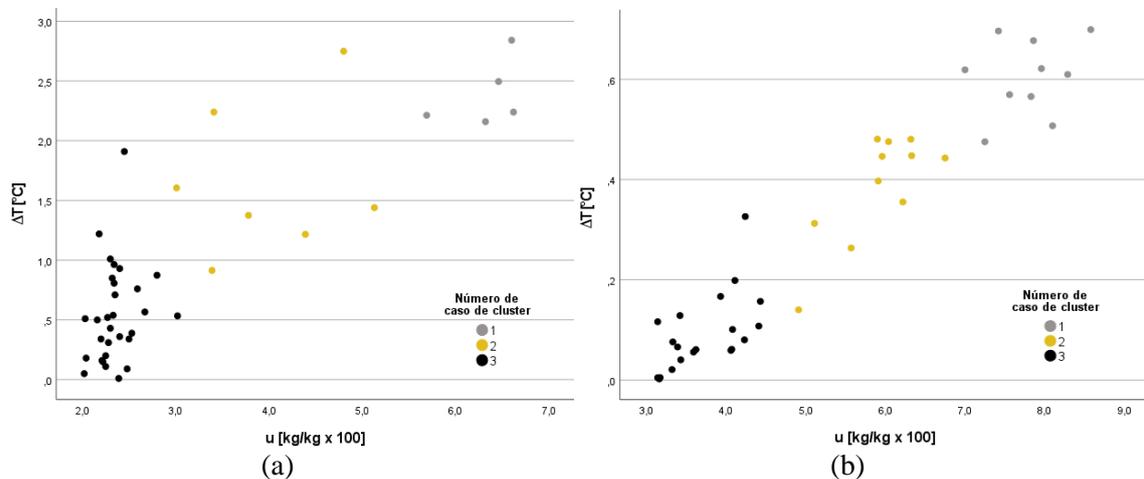


Figura 6 - Gráfico de dispersão dos clusters. (a) Parede câmara quente; (b) Parede câmara fria.

Tabela 7 - Limite inferior e superior do ΔT e “u” de cada cluster

Cluster		Parede câmara quente		Parede câmara fria	
		Limite inferior	Limite superior	Limite inferior	Limite superior
1	ΔT	1,95	2,92	0,55	0,66
	u	6,28	6,72	7,44	8,13
2	ΔT	1,06	1,65	0,40	0,48
	u	3,25	3,99	5,94	6,42
3	ΔT	0,34	0,61	0,05	0,11
	u	2,24	2,35	3,47	3,90

3. Automatização da identificação de defeitos e integração em modelos BIM

Na última década, o aumento do número de bases de dados com imagens, aliado ao avanço das ferramentas computacionais, contribuiu para o rápido desenvolvimento de técnicas de machine learning aplicadas à deteção de objetos e/ou determinadas características em imagens, abrindo caminho para a automatização do processo de inspeção visual de edifícios [20, 21]. As técnicas de machine learning permitem que o computador realize uma determinada tarefa de forma autónoma e automatizada, após um processo de aprendizagem, que pode ser supervisionado ou não supervisionado [16], o que justifica a grande tendência observada de pesquisas nessa área. Algumas das técnicas de machine learning atualmente utilizadas na área de inspeções na

engenharia civil são gradient boosting, SVM (support vector machines), redes neurais, modelos de análise de regressão e também abordagens mais recentes de deep learning [21-23].

Quanto às imagens térmicas obtidas com a TIV, o desenvolvimento de algoritmos de processamento de dados é de fundamental importância para mitigar o ruído das imagens e possibilitar a extração de informações que evidenciem os defeitos existentes [16]. Os algoritmos podem ser baseados tanto em parâmetros térmicos e princípios físicos de transferência de calor (como Pixel Algorithm for Time-Derivative of Temperature (PATDT), Partial Least Square Thermography (PLST), Pulse Phase Thermography (PPT) e Thermography Signal Reconstruction (TSR)), quanto em procedimentos matemáticos e analíticos (como Principal Component Thermography (PCT) e Dynamic Thermal Tomography (DTT)) [16]. Contudo, apesar dos bons resultados obtidos com esses algoritmos, nem todos são automatizados. A possibilidade de se conduzir inspeções de forma online e com interpretação automatizada dos dados é de grande interesse, visto que elimina a subjetividade e a dependência da experiência do operador [16, 24].

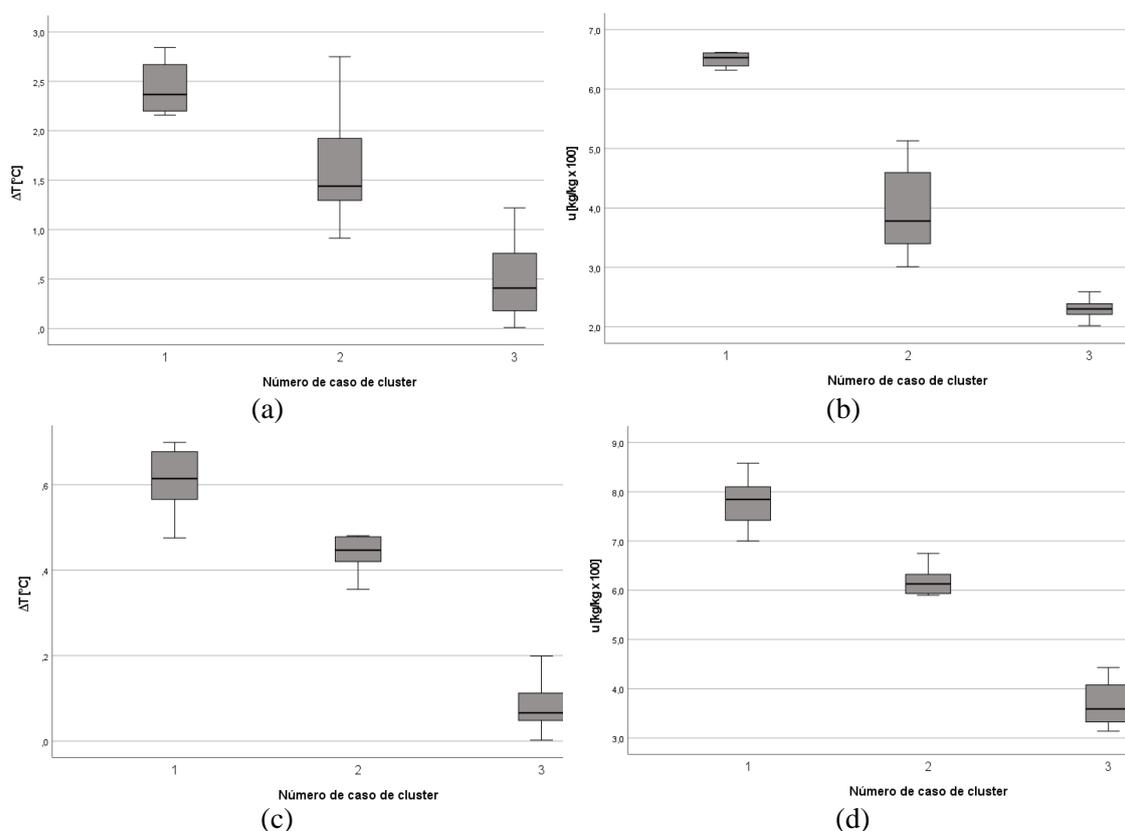


Figura 7 - Boxplots dos clusters. (a) ΔT clusters parede câmara quente; (b) "u" clusters parede da câmara quente; (c) ΔT clusters parede câmara fria; (d) "u" clusters parede câmara fria.

A Tabela 8 contempla algumas das pesquisas publicadas nos últimos anos com a utilização de algoritmos de processamento de dados e de machine learning para o diagnóstico de edificações e infraestruturas, bem como a informação da técnica utilizada para levantamento dos dados e a patologia ou característica estudada.

Os algoritmos, técnicas de processamento de imagens e técnicas de machine learning aplicados como ferramentas de diagnóstico já foram utilizados na detecção de defeitos como fissuras [20], fragmentações em betão [23], vazios [16, 25], na avaliação da eficiência energética das edificações [13, 26], no estudo de danos relacionados com a cor e geometria dos materiais [27, 28] e também na análise de humidade [22, 29, 30, 31]. Também foram identificados estudos que contemplaram a integração dos resultados provenientes das técnicas de inspeção em modelos BIM [27, 32].

Apesar de terem sido encontrados estudos cujo objetivo era a avaliação automatizada de

problemas relacionados com a humidade, grande parte destes aplicam-se a situações específicas, não podendo ser generalizados. Também não foram encontrados estudos que integrem em modelos BIM os algoritmos para automatização da identificação de humidade, para facilitar a inspeção e o monitoramento das edificações.

Tabela 8 - Trabalhos recentes com a utilização de *machine learning* e algoritmos de processamento de dados para inspeções na engenharia civil

Artigo	Técnica para levantamento dos dados	Algoritmos de processamento de dados/técnicas de <i>machine learning</i>	Patologia
[22]	<ul style="list-style-type: none"> Impedância Tomográfica Elétrica 	<ul style="list-style-type: none"> Regressão linear com SVM (LR-SVM) Regressão linear com mínimos quadrados (LR-LS) Rede neural artificial (ANN) 	Humidade
[29]	<ul style="list-style-type: none"> Método dielétrico, de micro-ondas e gravimétrico 	<ul style="list-style-type: none"> Rede neural artificial (ANN) 	Humidade
[30]	<ul style="list-style-type: none"> Impedância Tomográfica Elétrica 	<ul style="list-style-type: none"> Variação total (TV) Regressão de menor ângulo (LARS) Rede elástica (EN) Rede neural artificial (ANN) 	Humidade
[20]	<ul style="list-style-type: none"> Imagens obtidas com <i>drones</i> 	<ul style="list-style-type: none"> Rede neural convolucional (CNN) para classificação de imagens com e sem fissuras Rede Neural U-Net para segmentação semântica de pixels de fissuras 	Fissuras
[23]	<ul style="list-style-type: none"> Imagens RGB 	<ul style="list-style-type: none"> Algoritmo para retirar ruídos da imagem e evidenciar defeitos Modelo de análise de regressão com técnicas de processamento de imagens 	Fragmentações em betão
[27]	<ul style="list-style-type: none"> GPR, imagens obtidas com drones, escaneamento a laser e TIV 	<ul style="list-style-type: none"> OBIA (<i>object-based image analysis</i>) KNN (<i>k-nearest neighbor</i>) 	Pátina, humidade, etc.
[28]	<ul style="list-style-type: none"> Escaneamento a laser e fotogrametria 	<ul style="list-style-type: none"> Algoritmo de regressão logística de classificação multi-classe 	Danos quanto à cor e geometria
[25]	<ul style="list-style-type: none"> Fotogrametria (SfM) Imagens obtidas com drone Termografia de Infravermelhos 	<ul style="list-style-type: none"> Transformação da matriz de temperatura em uma escala de cinzento Uso de ponderação de intensidade local (LIW) Método do Limite Otsu para dividir a imagem em fundo e primeiro plano (redução de pixels para análise) 	Defeitos sob a superfície
[13]	<ul style="list-style-type: none"> Termografia de Infravermelhos Imagens obtidas com drones 	<ul style="list-style-type: none"> Método Canny para deteção das bordas das regiões com defeitos CED (<i>canny based Edge Detection</i>) e DCI (<i>dominant color isolation</i>) <i>Mask</i> R-CNN para computar os valores de transmitância térmica 	Eficiência energética
[26]	<ul style="list-style-type: none"> Termografia de Infravermelhos 	<ul style="list-style-type: none"> Conversão das imagens térmicas para o formato pgm Algoritmo de deteção de linhas (<i>Line Segment Detector</i>) Conversão da imagem térmica em uma escala de cinzento 	Eficiência energética
[31]	<ul style="list-style-type: none"> Termografia de Infravermelhos 	<ul style="list-style-type: none"> Aplicação de técnica de filtragem bilateral Aplicação do Método do Limite Otsu Técnica de deteção de contornos (filtro termal e geométrico) 	Humidade
[16]	<ul style="list-style-type: none"> Termografia de Infravermelhos 	<ul style="list-style-type: none"> <i>Deep learning</i> - <i>Mask</i> R-CNN 	Vazios sob a superfície

4. Conclusões

Os resultados da campanha experimental permitiram concluir que existe uma forte correlação entre o teor de humidade dos provetes e o gradiente térmico entre o provete e a zona seca da parede. Os modelos linear, logarítmico e quadrático garantiram bons ajustes em ambos os ensaios (na câmara quente e na câmara fria), com coeficientes de determinação (R^2) superiores a 0,69, contudo, a equação do modelo de regressão que melhor se ajustou aos resultados obtidos na câmara quente foi completamente distinta da equação que melhor se ajustou aos resultados da câmara fria.

Com a análise de clusters, identificaram-se três grupos distintos em cada um dos ensaios: um com teores de humidade mais elevados, outro com teores intermédios e outro com valores mais baixos. O agrupamento dos pontos apontou que, na câmara quente, pontos com altos teores de humidade apresentaram gradientes térmicos entre 2,0 e 3,0°C, mas que gradientes a partir de 1,0°C já indicaram locais com teores de humidade intermédios (superiores àqueles verificados na região não atingida pela percolação da água por ascensão capilar). Na câmara fria, os gradientes térmicos referentes aos pontos com elevados teores de humidade atingiram valores entre 0,5 e 0,7°C, mas gradientes acima de 0,4°C já indicaram regiões com teores de humidade intermédios. Em face do exposto, verifica-se uma diferença substancial entre os resultados encontrados, indicando a grande influência das condições ambientais nos resultados obtidos com a TIV.

Em face do grande potencial da TIV para inspeção de defeitos relacionados à humidade, mas considerando a grande variabilidade dos resultados obtidos com essa técnica e a subjetividade inerente às inspeções, foram também citadas neste artigo as técnicas que possibilitam o processamento dos dados provenientes das imagens térmicas, permitindo a redução do ruído e o realce das regiões com defeitos. Ainda, foram citados trabalhos publicados na área da engenharia civil para inspeção e monitoramento de defeitos em edificações e infraestrutura com a utilização de técnicas de machine learning, como redes neurais (ANN, CNN), regressões (LR-SVM, LR-LS, LARS), redes elásticas e clustering (KNN), além de técnicas de deep learning, como Mask R-CNN.

A incorporação de soluções que envolvem inteligência artificial tem sido cada vez mais comum na indústria da construção e o desenvolvimento dessas tecnologias digitais podem auxiliar na obtenção de diagnósticos mais confiáveis e na redução da dependência da experiência do operador. Portanto, pesquisas futuras devem considerar o uso dessas ferramentas aplicadas à análise de humidade e também a integração destas em modelos BIM, para automatizar e facilitar o monitoramento de defeitos em edificações.

Agradecimentos

Este trabalho foi financiado por: Financiamento Base - UIDB/04708/2020 da Unidade de Investigação CONSTRUCT - Instituto de I&D em Estruturas e Construções - financiada por fundos nacionais através da FCT/MCTES (PIDDAC).

Referências

- [1] E. Barreira, R. M. S. F. Almeida, *Infrared Thermography for Building Moisture Inspection*, Springer, Suíça, 2019.
- [2] C. Morón, D. Ferrández, P. Saiz, E. Yedra, Measuring system of capillary rising damp in cement mortars, *Measurement*, 135 (2019) 252–259. <https://doi.org/10.1016/j.measurement.2018.11.071>.
- [3] F. M. A. Henriques, *Humidade em paredes*, Laboratório Nacional de Engenharia Civil, Lisboa 1994.
- [4] L. Kempton, G. Kokogiannakis, P. Cooper, Mould risk evaluations in residential buildings via site audits and longitudinal monitoring, *Build. and environ.*, 191 (2021) 107584. <https://doi.org/10.1016/j.buildenv.2020.107584>.

- [5] B. Vásárhelyi. Statistical Analysis of the Influence of Water Content on the Strength of the Miocene Limestone, *Rock Mech. and Rock Engineering.*, Springer Nature, Austria, 38 (2005) 69-76. <https://doi.org/10.1007/s00603-004-0034-3>.
- [6] N. Sathiparan, U. Rumeskumar, Effect of moisture condition on mechanical behavior of low strength brick masonry, *J. of Build. Engineering*, 17 (2018) 23-31. <https://doi.org/10.1016/j.jobe.2018.01.015>.
- [7] E. Rosina. When and how reducing moisture content for the conservation of historic building. A problem solving view or monitoring approach?, *J. of Cultural hérit.*, 31 (2018) S82–S88. <https://doi.org/10.1016/j.culher.2018.03.023>.
- [8] N. P. Avdelidis, A. Moropoulou, P. Theoulakis, Detection of water deposits and movement in porous materials by infrared imaging, *Infrared phys. & Technology*, 44 (2003) 189-190. [https://doi.org/10.1016/S1350-4495\(02\)00212-8](https://doi.org/10.1016/S1350-4495(02)00212-8).
- [9] A. Hola, Measuring of the moisture content in brick walls of historical buildings – the overview of methods, *IOP Conference Series: Materials Science and Engineering*, 251 (2017) 012067.
- [10] T. S. Jing, M. A. Othuman Mydina, N. Utaberta, Appraisal of moisture problem of inheritance building envelope assemblies via visible and infrared thermography methods, *J. Teknologi*, 75:5 (2015), 1–6. <https://doi.org/10.11113/jt.v75.4951>.
- [11] E. Grinzato, N. Ludwig, G. Cadelano, M. Bertucci, M. Gargano, P. Bison, Infrared thermography for moisture detection: A laboratory study and in-situ test, *Mater. Evaluation*, 69(1) (2011), 97–104.
- [12] E. Rosina, N. Ludwig, Optimal thermographic procedures for moisture analysis in building materials, In: *Proceedings SPIE – Diagnostic Imaging Technologies and Industrial Applications*, 3827 (1999). <https://doi.org/10.1117/12.361015>.
- [13] D. Sadhukhana, S. Peri, N. Sagunaraj, A. Biswas, D. F. Selvaraj, K. Koiner, A. Rosener, M. Dunlevy, N. Goveas, D. Flynn, P. Ranganathan, Estimating surface temperature from thermal imagery of buildings for accurate thermal transmittance (U-value): A machine learning perspective, *J. of Build. Engineering*, 32 (2020) 101637. <https://doi.org/10.1016/j.jobe.2020.101637>.
- [14] E. Barreira, R. M. S. F. Almeida, J. M. P. Q. Delgado, Infrared thermography for assessing moisture related phenomena in building components, *Construction and Build. Mater.*, 110 (2016), 251-269. <https://doi.org/10.1016/j.conbuildmat.2016.02.026>.
- [15] M. Q. Huang, J. Ninié, Q. B. Zhang, BIM, machine learning and computer vision techniques in underground construction: Current status and future perspectives, *Tunn. and Undergr. Space Technology* 108 (2021) 103677. <https://doi.org/10.1016/j.tust.2020.103677>.
- [16] I. Garrido, J. Erazo-Aux, S. Laguela, S. Sfarra, C. Ibarra-Castanedo, E. Pivarciova, G. Gargiulo, X. Maldague, P. Arias, Introduction of Deep Learning in Thermographic Monitoring of Cultural Heritage and Improvement by Automatic Thermogram Pre-Processing Algorithms, *Sensors*, 21 (2021). <https://doi.org/10.3390/s21030750>.
- [17] American Society for Testing and Materials (ASTM). ASTM E1933-99a: Standard Test Method for Measuring and Compensating for Emissivity Using Infrared Imaging Radiometers. Estados Unidos, 1999, 3p.
- [18] American Society for Testing and Materials (ASTM). ASTM E1862-97: Standard Test Method for Measuring and Compensating for Reflected Temperature Using Infrared Imaging Radiometers. Estados Unidos, 1997, 3p.
- [19] L. C. M. Dafico, E. Barreira, R. M. S. F. Almeida, H. Carasek, Comparison of Infrared Thermography and Other Traditional Techniques to Assess Moisture Content of Wall Specimens, *Sensors*, 22 (2022). <https://doi.org/10.3390/s22093182>.
- [20] K. Chen, G. Reichard, X. Xu, A. Akanmu, Automated crack segmentation in close-range building façade inspection images using deep learning techniques, *J. of Build. Engineering*, 43 (2021) 102913. <https://doi.org/10.1016/j.jobe.2021.102913>.
- [21] A. Sawhney, M. Riley, J. Irizarry, *Construction 4.0 – An Innovation Platform for the Built Environment*, Routledge Taylor & Francis Group, Londres e Nova York, 2020.

- [22] T. Rymarczyk, G. Klosowski, A. Hola, J. Sikora, T. Wolowiec, Comparison of machine learning methods in electrical tomography for detecting moisture in building walls, *Energies*, 14 (2021) 2777. <https://doi.org/10.3390/en14102777>.
- [23] T. Dawood, Z. Zhu, T. Zayed, Machine vision-based model for spalling detection and quantification in subway networks, *Automation in Construction*, 81 (2017) 149-160. <https://doi.org/10.1016/j.autcon.2017.06.008>.
- [24] I. G. Garrido. Automation of the thermographic inspection: Development of thermogeometric algorithms for detection of pathologies supported by machine learning strategies, Tese de Doutoramento, Universidade Vigo, Vigo, Espanha, 2021.
- [25] M. Puliti, G. Montaggioli, A. Sabato, Automated subsurface defects' detection using point cloud reconstruction from infrared images, *Automation in Construction*, 129 (2021), 103829. <https://doi.org/10.1016/j.autcon.2021.103829>.
- [26] S. Laguela, L. Díaz-Vilariño, J. Martínez, J. Armesto, Automatic thermographic and RGB texture of as-built BIM for energy rehabilitation purposes, *Automation in Construction*, 31 (2013) 230-240. <https://doi.org/10.1016/j.autcon.2012.12.013>.
- [27] M. Solla, L. M. S. Gonçalves, G. Golçalves, C. Francisco, I. Puente, P. Providência, F. Gaspar, H. Rodrigues, A Building Information Modeling Approach to Integrate Geomatic Data for the Documentation and Preservation of Cultural Heritage, *Remote Sens.*, 12 (2020), 4028. <https://doi.org/10.3390/rs12244028>.
- [28] E. Valero, A. Forster, F. Bosché, E. Hyslop, L. Wilson, A. Turmel, Automated defect detection and classification in ashlar masonry walls using machine learning, *Automation in Construction*, 106 (2019) 102846. <https://doi.org/10.1016/j.autcon.2019.102846>.
- [29] A. Hola, L. Sadowski, Non-destructive in situ identification of the moisture content in saline brick walls using artificial neural networks, In: *Proceedings of the Creative Construction Conference*, (2019) 012. <https://doi.org/10.3311/CCC2019-012>.
- [30] T. Rymarczyk, G. Klosowski, A. Hola, J. Hola, J. Sikora, P. Tchórzewski, L. Skowron, Historical buildings dampness analysis using electrical tomography and machine learning algorithms, *Energies*, 14 (2021), 1307. <https://doi.org/10.3390/en14051307>.
- [31] I. Garrido, S. Laguela, S. Sfarra, F. J. Madruga, P. Arias, Automatic detection of moistures in different construction materials from thermographic images, *J. of Therm. Analysis and Calorim.*, 138 (2019), 1649-1668. <https://doi.org/10.1007/s10973-019-08264-y>.
- [32] Y. H. Tsai, J. Wang, W. T. Chien, C. Y. Wei, X. Wang, S. H. Hsieh, A BIM-based approach for predicting corrosion under insulation, *Automation in Construction*, 107 (2019) 102923. <https://doi.org/10.1016/j.autcon.2019.102923>.

ORCID

L. C. M. Dafico	0000-0003-3650-7818 (https://orcid.org/0000-0003-3650-7818)
E. Barreira	0000-0002-1343-5578 (https://orcid.org/0000-0002-1343-5578)
R. M.S.F. Almeida	0000-0002-9846-6081 (https://orcid.org/0000-0002-9846-6081)
R. S. Vicente	0000-0002-5456-1642 (https://orcid.org/0000-0002-5456-1642)