Universidade de Lisboa

Faculdade de Medicina Dentária

Desenvolvimento de um Algoritmo baseado em Inteligência Artificial para Identificação de Cadáveres por Evidências Dentárias

Raquel Alexandra de Jesus Carvalho

Orientadores:

Professora Doutora Cristiana Maria Palmela Pereira

Professor Doutor Rui Filipe Vargas de Sousa Santos

Dissertação

Mestrado Integrado em Medicina Dentária

2024

Universidade de Lisboa

Faculdade de Medicina Dentária

Desenvolvimento de um Algoritmo baseado em Inteligência Artificial para Identificação de Cadáveres por Evidências Dentárias

Raquel Alexandra de Jesus Carvalho

Orientadores:

Professora Doutora Cristiana Maria Palmela Pereira

Professor Doutor Rui Filipe Vargas de Sousa Santos

Dissertação

Mestrado Integrado em Medicina Dentária

2024

Ao meu anjo da guarda,

por me permitir chegar até aqui.

AGRADECIMENTOS

À minha orientadora, Professora Doutora Cristiana Palmela Pereira, por todo o apoio, dedicação, exigência, profissionalismo e orientação tanto neste projeto desafiante como ao longo de todo o meu percurso na FMDUL. Acima de tudo, estou-lhe eternamente grata por partilhar comigo o seu querido projeto e todo o conhecimento e paixão pelo mundo da Medicina Dentária Forense – que tão especial e bonito é –, representando o maior exemplo do que é seguir a nossa grande vocação e trabalhar numa área pela qual nutrimos verdadeiro amor.

Ao meu coorientador, Professor Doutor Rui Santos, por toda a dedicação e tempo dispendidos para a concretização deste projeto.

Ao Professor Doutor Francisco Salvado, Diretor do Serviço de Estomatologia da Unidade Local de Saúde Santa Maria, por me facilitar o acesso e a recolha de dados para este estudo e por me receber sempre com um sorriso no rosto no seu Serviço.

À Diana Augusto, por toda a paciência sem fim para o meu *stress*, por tentar decifrar os meus mil e um dilemas e, acima de tudo, por cada segundo de apoio incansável e constante nos últimos meses. O teu pequeno génio conseguiu dar a volta à situação!

Ao meu amigo Zé, pela sua genialidade incomparável e ajuda desmedida, sem nunca esperar nada em troca. Obrigada por conseguires adaptar os teus vastos conhecimentos sobre inteligência artificial a uma versão "para totós" especificamente delineada para mim.

A todos os meus amigos, por lidarem com as minhas angústias, medos e preocupações, por reduzirem o *stress* associado a dias longos e cansativos e por tornarem a vida tão mais bela. Às minhas melhores amigas Lara e Joana. À Lara, por me permitir fugir à realidade vezes sem conta, romantizando a vida da forma mais bonita possível, e por atribuir um verdadeiro significado à expressão "até sermos velhinhas". À Joana, pela amizade de uma vida inteira, sempre igualmente especial e forte apesar dos encontros trimestrais.

Aos meus Caéticos, Inês, Soraia, Patrícia, Vitória, Mariana, Diogo, Chico, Gameiro, Diana, Cátia, Fábio, e Babuxa, os melhores amigos da faculdade que alguma vez poderia desejar. Por conseguirem sempre transformar lágrimas em sorrisos e gargalhadas, por tornarem o dia a dia na FMDUL numa rotina tão especial e dinâmica, da qual sinto tremendas saudades, e por criarmos juntos memórias únicas que guardarei sempre no meu coração. À minha dupla, Gameiro, por viver a rotina clínica comigo sempre com carinho e paciência, tanto nos dias bons

como nos menos bons. À Su, que em tão pouco tempo se tornou tanto para mim, refletindo um dos meus maiores apoios. À Inêzita, por ser o meu abrigo, o meu porto seguro e a voz do conforto e ternura. Obrigada por nunca largares a minha mão ao longo destes anos.

À minha família, por todo o amor e apoio incondicionais, perto ou longe. Ao meu irmão, por ser um grande exemplo de autodidatismo e pensamento crítico. Por me incentivar continuamente a fazer mais e melhor e a superar-me a mim própria, mesmo quando não acredito ser capaz. À minha cunhada Catarina, por se preocupar tanto comigo e querer procurar sempre o melhor para mim. Obrigada pela ajuda impagável.

Aos meus pais, por me darem todas as ferramentas e meios possíveis para seguir este percurso e concretizar o meu sonho. Por todo o amor, paciência, conforto e esforço desmedidos, sempre prontos a ajudar-me em qualquer circunstância. Um obrigada nunca será suficiente.

Ao João, por ser o meu maior pilar, o melhor abraço, a minha casa. Por saber sempre o que dizer e como me acalmar, por me ajudar a encontrar soluções para os problemas e por ser a voz da razão. Por nunca ter deixado o meu lado na fase mais negra da minha vida. Por todo o amor incondicional. Obrigada por partilhares a vida comigo.

E, por fim, à Faculdade de Medicina Dentária da Universidade de Lisboa, por ser a minha segunda casa durante estes cinco anos. Perante a impossibilidade de resumir tudo o que vivi lá, deixo somente a certeza de que foi uma das aventuras mais bonitas da minha vida.

A todos os que fizeram parte deste percurso, o meu mais sincero e grato

Obrigada.

Este estudo foi apoiado pela FCT (Fundação para a Ciência e Tecnologia – Portugal) no âmbito do projeto UIDB/00006/2020. https://doi.org/10.54499/UIDB/00006/2020.

Fundação para a Ciência e a Tecnologia

RESUMO

Introdução: A medicina dentária forense (MDF) é crucial em perícias médico-legais, possibilitando a identificação médico-legal através de evidências dentárias com base na exclusão e comparação *ante mortem* (AM) e *post mortem* (PM) de registos dentários, inclusive ortopantomografias (OPG). Pela complexidade e demora deste processo, surgiu a necessidade de otimizar a eficiência da análise imagiológica. Redes neuronais convolucionais (CNN) são estruturas de inteligência artificial (AI) promissoras na MDF pela sua eficiência e detalhe na análise de imagens, constituindo uma ferramenta útil na identificação médico-legal.

Objetivos: Este estudo teve como objetivo o desenvolvimento de um algoritmo de CNN para comparação de evidências dentárias AM e PM em OPG, para aplicação na identificação médico-legal de cadáveres desconhecidos recentes.

Materiais e Métodos: O presente estudo incluiu uma amostra total de 1.235 OPG pertencentes a 1.050 pacientes do Serviço de Estomatologia da Unidade Local de Saúde (ULS) Santa Maria, com idades compreendidas entre os 16 e os 30 anos. Foram desenvolvidos dois algoritmos – um para classificação de idade e outro para identificação positiva – com base no modelo pré-treinado VGG16, e o desempenho foi avaliado através de métricas preditivas e *heatmaps*.

Resultados: Ambos os modelos desenvolvidos sofreram *overfitting*, porém, alcançaram uma acurácia final de 85%, o que traduz um elevado desempenho geral. O modelo de classificação de idade obteve melhores resultados na classificação de OPG de indivíduos entre os 16 e os 23 anos. O modelo de identificação positiva foi particularmente eficaz na identificação de casos onde duas OPG pertencem a indivíduos diferentes.

Conclusões: O modelo de AI desenvolvido é útil na identificação médico-legal de cadáveres desconhecidos, com particular vantagem em contexto de identificação de vítimas de desastres em massa (DVI), através da comparação AM e PM de evidências dentárias em OPG de indivíduos com idades compreendidas entre os 16 e os 30 anos.

ABSTRACT

Introduction: Forensic dentistry (FD) plays a crucial role in forensic investigations, enabling legal identification through dental evidence based on the exclusion and comparison of a*nte mortem* (AM) and *post mortem* (PM) dental records, including orthopantomograms (OPG). Due to the complexity and time-consuming nature of this process, there is a urge to optimize the efficiency of imaging analysis. Convolutional neural networks (CNN) are promising artificial intelligence (AI) structures in FD for their efficiency and detail in image analysis, making them a useful tool in forensic identification.

Objectives: The purpose of this study was the development of a CNN algorithm to compare AM and PM dental evidence in OPG, with the aim of forensically identifying recently deceased unknown individuals.

Materials and Methods: The present study included a total sample of 1,235 OPG from 1,050 patients from the Stomatology Service of the Local Health Unit of Santa Maria, aged between 16 and 30 years. Two algorithms were developed – one for age classification and another for positive identification – based on the pre-trained VGG16 model, and performance was evaluated through predictive metrics and heatmaps.

Results: Both developed models experienced overfitting but achieved a final accuracy of 85%, reflecting high overall performance. The age classification model performed better in classifying OPG from individuals aged between 16 and 23 years. The positive identification model was particularly effective in identifying cases where two OPG belong to different individuals.

Conclusions: The developed AI model is useful in the forensic identification of unknown deceased individuals, with particular advantage in mass disaster victim identification context, by comparing AM and PM dental evidence in OPGs of individuals aged between 16 and 30 years.

PALAVRAS-CHAVE

Aprendizagem Profunda; Identificação Humana; Inteligência Artificial; Medicina Dentária Forense; Ortopantomografia.

KEYWORDS

Deep Learning; *Human Identification*; *Artificial Intelligence*; *Forensic Dentistry*; *Orthopantomography*.

ÍNDICE

AGRADECIMENTOS v

RESUMO vii

ABSTRACT viii

PALAVRAS-CHAVE ix

KEYWORDS x

ÍNDICE DE TABELAS E FIGURAS xv

LISTA DE ABREVIATURAS E SIGLAS xvi

1. INTRODUÇÃO 1

1.1. Considerações Finais 3

2. OBJETIVOS 4

2.1. Objetivos Primários 4

2.1.1. Classificação de Idade 4

2.1.2. Identificação Positiva 4

2.2. Objetivo Final 5

3. MATERIAIS E MÉTODOS 6

3.1. Delineamento Experimental 6

3.2. Amostra Populacional 6

3.2.1. Critérios de Inclusão 6

3.2.2. Critérios de Exclusão 6

3.3. Metodologia da Recolha de Dados 7

3.4. Tratamento Inicial da Amostra 8

3.5. Configurações Experimentais 8

3.5.1. Classificação de Idade 10

3.5.2. Identificação Positiva 10

3.6. Pré-Processamentos dos Dados 12

3.6.1. Classificação de Idade 12

3.6.2. Identificação Positiva 13

3.7. Otimização de Hiperparâmetros 13

3.7.1. Classificação de Idade 14

3.7.2. Identificação Positiva 15

3.8. Análise Estatística 15

3.9. *Heatmaps* 17

4. RESULTADOS 18

4.1. Análise Descritiva 18

4.2. Classificação de Idade 18

4.2.1. Avaliação de Desempenho em Treino e Validação 18

4.2.2. Avaliação de Desempenho Final em Teste 19

4.2.3. *Heatmaps* 20

4.3. Identificação Positiva 21

4.3.1. Avaliação de Desempenho em Treino e Validação 21

4.3.2. Avaliação de Desempenho Final em Teste 21

4.3.3. *Heatmaps* 22

5. DISCUSSÃO 23

5.1. Classificação de Idade 23

5.1.1. Caracterização da Amostra 23

5.1.2. Avaliação de Desempenho em Treino e Validação 23

5.1.3. Avaliação de Desempenho Final em Teste 24

5.1.4. Aplicação ao Contexto Médico-Legal 25

5.2. Identificação Positiva 25

5.2.1. Caracterização da Amostra 25

5.2.2. Avaliação de Desempenho em Treino e Validação 26

5.2.3. Avaliação de Desempenho Final em Teste 26

5.2.1. Aplicação ao Contexto Médico-Legal 27

6. CONCLUSÕES 30

6.1. Conclusões relativas aos Objetivos Primários 30

6.2. Conclusões relativas ao Objetivo Final 30

REFERÊNCIAS BIBLIOGRÁFICAS 31

ANEXOS 36

Anexo 1 – Cartas de Pedido de Autorização 37

Anexo 1, I – Carta para o Presidente da Comissão de Ética do CAML 38

Anexo 1, II – Questionário de Comissão de Ética do CAML 39

Anexo 1, III – Autorização do Diretor do Serviço de Estomatologia da ULS Santa Maria 47

Anexo 1, IV– Parecer Favorável da Comissão de Ética do CAML 48

Anexo 2 – Bases de Dados para Análise Estatística 49

Anexo 2, I – Abreviaturas e Códigos de Registo do Estudo 50

Anexo 2, II – Caderno de Recolha de Dados de *Microsoft Excel*® 51

Anexo 2, III – Editor de *IBM SPSS*® *Statistics* 29 68

Anexo 3 – Análise Estatística Descritiva 76

Anexo 3, I – Distribuição da Amostra por Sexo 77

Anexo 3, II – Distribuição da Amostra por Sexo e Intervalo de Idades 77

Anexo 4 – *Heatmaps* de Classificação de Idade 78

Anexo 4, I – *Heatmaps* de OPG da classe "16_23" classificadas como "16_23" 79

Anexo 4, II – *Heatmaps* de OPG da classe "16_23" classificadas como "24_30" 97

Anexo 4, III – *Heatmaps* de OPG da classe "24_30" classificadas como "24_30" 98

Anexo 4, IV – *Heatmaps* de OPG da classe "24_30" classificadas como "16_23" 112

Anexo 5 – *Heatmaps* de Identificação Positiva 117

Anexo 5, I – *Heatmaps* de OPG da classe "*Same*" classificadas como "*Same*" 118

Anexo 5, II – *Heatmaps* de OPG da classe "*Same*" classificadas como "*Different*" 133

Anexo 5, III – *Heatmaps* de OPG da classe "*Different*" classificadas como "*Different*" 140

Anexo 5, IV – *Heatmaps* de OPG da classe "*Different*" classificadas como "*Same*" 196

Anexo 6 – Trabalhos Científicos desenvolvidos na FMDUL entre 2020 e 2024 201

Anexo 6, I – Publicações Científicas 202

Anexo 6, II – Apresentações Científicas 203

ÍNDICE DE TABELAS E FIGURAS

I. ÍNDICE DE TABELAS

Tabela 1. Distribuição da amostra por sexo e por idade (em anos) 7

Tabela 2. Distribuição da amostra por nº de OPG no processo médico 7

Tabela 3. Divisão e distribuição das OPG para classificação de idade, por fase e classe 12

Tabela 4. Divisão e distribuição das OPG para identificação positiva, por fase e classe 13

Tabela 5. Valores de acurácia e perda do modelo de classificação de idade, por fase 19

Tabela 6. Valores de parâmetros métricos do modelo de classificação de idade, por classe ... 20

Tabela 7. Valores para acurácia e perda do modelo de identificação positiva, por fase 21

Tabela 8. Valores de parâmetros métricos do modelo de identificação positiva, por classe 22

II. ÍNDICE DE FIGURAS

Figura 1. Distribuição da amostra por sexo, em percentagem (%) 18

Figura 2. Distribuição da amostra por sexo e intervalo de idades (em anos) 18

Figura 3. Acurácia e perda durante treino e validação do modelo de classificação de idade .. 19

Figura 4. Matriz de confusão da amostra de teste do modelo de classificação de idade 19

Figura 5. *Heatmap* com previsão correta da classe "16_23" 20

Figura 6. *Heatmap* com previsão correta da classe "24_30" 20

Figura 7. Acurácia e perda durante treino e validação do modelo de identificação positiva .. 21

Figura 8. Matriz de confusão da amostra de teste do modelo de identificação positiva 21

Figura 9. Par de *heatmaps* com previsão correta da classe "*Same*" 22

Figura 10. Par de *heatmaps* com previsão correta da classe "*Different*" 22

LISTA DE ABREVIATURAS E SIGLAS

Adam – *Adaptive Moment Estimation*

AI – Inteligência Artificial (*Artificial Intelligence*)

AM – *Ante Mortem*

CAML – Centro Académico de Medicina de Lisboa

CNN – Redes Neuronais Convolucionais (*Convolutional Neural Networks*)

DL – *Deep Learning*

DVI – Identificação de Vítimas de Desastres em Massas (*Disaster Victim Identification*)

FN – Falsos Negativos

FP – Falsos Positivos

Grad-CAM – *Gradient-weighted Class Activation Mapping*

MDF – Medicina Dentária Forense

ML – *Machine Learning*

MONAI – *Medical Open Network for Artificial Intelligence*

NN – Redes Neuronais (*Neural Networks*)

OPG – Ortopantomografia(s)

PM – *Post Mortem*

RANSAC – *Random Sample Consensus*

ReLU – *Rectified Linear Unit*

RMSprop – *Root Mean Square Propagation*

SL – *Supervised Learning*

SURF – *Speeded-Up Robust Features*

TL – *Transfer Learning*

ULS – Unidade Local de Saúde

1. INTRODUÇÃO

A inteligência artificial (AI) constitui um tópico altamente emergente na atualidade. Esta área de estudo é focada na criação de sistemas capazes de executar tarefas que exijam um nível de inteligência humano, como a deteção de padrões. A AI integra a subárea *machine learning* (ML), cujo intuito se resume na capacidade de máquinas preverem ou tomarem decisões (para as quais não foram programadas) através da aprendizagem a partir de informação.[1-3]

Deep learning (DL) é uma área especializada e aprofundada de ML com foco em redes neuronais (NN) – estruturas cuja arquitetura é organizada em várias camadas de três diferentes tipos (*input*, *hidden* e *output*). As NN representam um conceito fundamental da AI, uma vez que o seu funcionamento se assemelha ao das redes neuronais biológicas do cérebro humano, mimetizando este último através de um modelo matemático não-linear, o que as torna capazes de aprender e tomar decisões.[1,3-7]

As redes neuronais convolucionais (CNN) são um dos tipos de NN atualmente mais utilizados, com particular eficiência na análise de imagem e deteção de padrões devido à sua arquitetura direcionada para o processamento de informação em estilo de matriz ou grelha (p. ex. uma imagem transformada numa grelha de pixels), baseada no processo matemático da convolução.[1-4,7-11]

Com a contínua evolução tecnológica nas Ciências da Saúde, o recurso a AI em áreas como a medicina dentária é cada vez mais demarcado, facilitando e acelerando determinados processos como o diagnóstico e delineamento de planos de tratamento em patologia oral, endodontia, ortodontia, entre muitos outros. Apesar da prevalência deste fenómeno de digitalização da medicina dentária, uma aplicação prática mais abrangente de AI na medicina dentária forense (MDF) ainda está por surgir.[1,6]

A MDF – ramo da medicina dentária e pertencente à medicina legal – apresenta um papel de extrema importância em inúmeras perícias médico-legais e forenses ao possibilitar a identificação médico-legal, fundamental nas vertentes criminal, cível e humanitária.[2,5,12-17] De acordo com a Lei n.º 45/2004, de 19 de agosto (alterada pelo Decreto-Lei n.º 53/2021, de 16 de junho), que define o regime jurídico da perícia médico-legal e forense, a identificação humana pode ser aplicada tanto em contexto de identificação de vítimas de desastres em massa (DVI), como na sala de autópsias, por uma equipa de peritos composta, inclusive, por médicos dentistas devidamente habilitados.[18]

A identificação humana é dividida em duas fases: reconstrutiva e comparativa. O processo de identificação é iniciado com a fase reconstrutiva, onde é traçado o perfil biológico básico do cadáver desconhecido (sexo, idade, estatura e afinidade populacional) através da recolha de dados *post mortem* (PM). De seguida, a fase comparativa tem como objetivo a comparação entre os dados PM previamente recolhidos e dados *ante mortem* (AM) de supostas vítimas, de modo a chegar à «identificação positiva» – ou seja, atribuir uma identidade ao cadáver. Esta é alcançada somente quando os perfis AM e PM coincidem.[2,15,17]

Paulo Otero afirma que cada indivíduo é dotado de «irrepetibilidade natural (...) assente na inexistência presente ou futura de dois seres humanos totalmente iguais».[19] É a presença de fatores individualizantes num indivíduo que possibilita o exercício de comparação no qual a identificação humana essencialmente se baseia. Estes fatores são classificados como primários (impressão digital, ADN e dentição) ou secundários (características pessoais como tatuagens ou *piercings*, patologia, antropologia, informação médica e documentos, vestuário e espólio). A identificação positiva é reconhecida pela comunidade forense internacional apenas quando obtida por, pelo menos, um dos fatores individualizantes primários, através da aplicação de métodos primários de identificação (lofoscopia, genética forense e MDF), como definido pelo Protocolo de DVI da INTERPOL[20]. Quando o recurso a estas metodologias é impossibilitado, a identificação do cadáver desconhecido é considerada somente uma convicção judiciária.[17,21]

Em situações de DVI (p. ex. desastres naturais e acidentes aéreos), caracterizadas comumente por um elevado número de vítimas mortais, a eficiência constitui um fator de grande peso. Assim, a adoção de medidas como a estimação da idade aparente numa fase inicial da identificação permite agilizar todo o processo de identificação por comparação dos cadáveres desconhecidos recentes. Por outro lado, devido às habituais circunstâncias de elevado grau de decomposição, mutilação ou esqueletização dos restos mortais achados neste contexto, a MDF é, muitas vezes, a única opção viável de identificação humana, visto que os dentes são a estrutura do corpo humano com maior durabilidade e resistência à destruição.[1-2,12,14-16]

Posto isto, o principal foco da MDF baseia-se na identificação humana através de evidências dentárias, ou seja, evidências presentes na cavidade oral, sendo descrita pela literatura como o método científico de identificação mais simples, rápido e económico, além de um dos mais fiáveis. Por cada indivíduo apresentar um padrão dentário singular, os princípios fundamentais da identificação humana por evidências dentárias baseiam-se na exclusão e na comparação AM e PM de registos dentários (registos clínicos, radiografias intra e extraorais, entre outros).[1-2,5,12-16]

A ortopantomografia (OPG) é um exame imagiológico extraoral que fornece informação sobre a dentição e estruturas anatómicas adjacentes, sendo comumente requisitada pelo seu tempo de aquisição e custo reduzidos e pela sua dose de radiação baixa. Na MDF, a OPG é utilizada para comparar dados AM e PM para identificação humana, constituindo um processo complexo e moroso quando executado manualmente, pelo que é necessário otimizá-lo.[11-13,15]

Por sua vez, as CNN têm vindo a ser apresentadas como solução para este problema, demonstrando um papel revolucionário na radiologia pela sua eficiência na análise de imagens. Este tipo de NN é ainda capaz de detetar padrões nos dados que, de outra forma, seriam impercetíveis.[1,5-6,12] Assim sendo, a AI é uma ferramenta útil e poderosa na MDF, auxiliando os profissionais da área na identificação humana, em investigações médico-legais, e levando a que estes trabalhem com maior exatidão e rapidez, atingindo assim melhores resultados.[1,4]

Devido ao rápido avanço da AI, foi necessário regulamentar o recurso a esta tecnologia na sociedade atual, inclusive nas áreas médicas, assegurando o seu uso seguro e ético. Deste modo, foi estabelecido pelo Parlamento Europeu e o Conselho da União Europeia, a 13 de junho de 2024, o Regulamento (UE) 2024/1689, que define a AI como uma tecnologia centrada no ser humano, devendo auxiliá-lo e proceder em prol do seu bem-estar. Mais especificamente, de acordo com os artigos 6.º e 7.º do Capítulo III e Anexo III, a AI constitui uma tecnologia de alto risco em contexto de perícias médico-legais. Isto implica que os sistemas de AI utilizados neste âmbito se encontram sujeitos a rigorosos requisitos de segurança e transparência.[22]

1.1. Considerações Finais

Dada a atualidade do tema abordado e a pertinência crescente de elaborar mais estudos na área, esta investigação teve por objetivo desenvolver um algoritmo baseado em AI, obtido através da aplicação de CNN em OPG, com a finalidade de alcançar a identificação médico-legal de cadáveres desconhecidos recentes por comparação de evidências dentárias AM e PM.

2. OBJETIVOS

2.1. Objetivos Primários

2.1.1. Classificação de Idade

Um dos objetivos primários desta investigação consistiu no desenvolvimento de um algoritmo baseado em AI, obtido através da aplicação de CNN em OPG, para a classificação de idade em dois distintos intervalos de idade – dos 16 aos 23 anos e dos 24 aos 30 anos – por evidências dentárias numa população dos 16 aos 30 anos.

2.1.1.1. Classificação dos intervalos de idades "16 a 23 anos " e "24 a 30 anos" por evidências dentárias nas OPG, através da aplicação do algoritmo de classificação de idade desenvolvido.

H0: O algoritmo desenvolvido permite classificar o intervalo de idades de indivíduos entre os 16 e 23 anos e entre os 24 e 30 anos, através das evidências dentárias presentes nas OPG.

H1: O algoritmo desenvolvido não permite classificar o intervalo de idades de indivíduos entre os 16 e 23 anos e entre os 24 e 30 anos, através das evidências dentárias presentes nas OPG.

2.1.2. Identificação Positiva

O outro objetivo primário desta investigação consistiu no desenvolvimento de um algoritmo baseado em AI, obtido através da aplicação de CNN em OPG, para identificação positiva por comparação de evidências dentárias entre duas OPG de uma população dos 16 aos 30 anos.

2.1.2.1. Identificação positiva de indivíduos com idades compreendidas entre os 16 e 30 anos, por comparação de evidências dentárias em diferentes OPG, através da aplicação do algoritmo de identificação positiva desenvolvido.

H0: O algoritmo desenvolvido permite identificar positivamente indivíduos com idades entre os 16 e os 30 anos, através da comparação de evidências dentárias de diferentes OPG.

H1: O algoritmo desenvolvido não permite identificar positivamente indivíduos com idades entre os 16 e os 30 anos, através da comparação de evidências dentárias de diferentes OPG.

2.2. Objetivo Final

O objetivo final deste estudo consistiu na identificação médico-legal de cadáveres desconhecidos, com idades compreendidas entre os 16 e os 30 anos, por comparação de evidências dentárias em OPG realizadas AM e PM, através da aplicação do algoritmo de identificação positiva desenvolvido com base em AI.

2.2.1. Identificação médico-legal de cadáveres desconhecidos recentes com idades entre os 16 e os 30 anos, por comparação de evidências dentárias AM e PM em OPG através do algoritmo de identificação positiva desenvolvido.

H0: O algoritmo de identificação positiva desenvolvido permite a identificação médico-legal de cadáveres desconhecidos, com idades compreendidas entre os 16 e os 30 anos, por comparação de evidências dentárias AM e PM presentes em OPG.

H1: O algoritmo de identificação positiva desenvolvido não permite a identificação médico--legal de cadáveres desconhecidos, com idades compreendidas entre os 16 e os 30 anos, por comparação de evidências dentárias AM e PM presentes em OPG.

3. MATERIAIS E MÉTODOS

3.1. Delineamento Experimental

O presente estudo decorreu na Unidade Local de Saúde (ULS) Santa Maria, tendo como população-alvo os pacientes do Serviço de Estomatologia da referida unidade hospitalar com ficha clínica disponível para consulta e com, pelo menos, um exame complementar de diagnóstico – nomeadamente uma OPG – associado ao respetivo processo.

Foi elaborado um protocolo experimental e o mesmo foi enviado – juntamente com a carta de pedido de autorização (Anexo 1, I) e com o questionário da Comissão de Ética do Centro Académico de Medicina de Lisboa (CAML) (Anexo 1, II) – para o Diretor do Serviço de Estomatologia da ULS Santa Maria e para o Presidente da Comissão de Ética do CAML, havendo sido obtido parecer favorável de ambas as partes (Anexo 1, III e IV).

3.2. Amostra Populacional

A amostra populacional foi selecionada, de entre a população-alvo, através de um processo de amostragem sistemática e com base nos seguintes critérios de inclusão e exclusão:

3.2.1. Critérios de Inclusão

- Processos com, pelo menos, uma OPG associada;
- Indivíduos com idade compreendida entre os 16 e os 30 anos na data de realização da OPG.

3.2.2. Critérios de Exclusão

- Presença de radiopacidades decorrentes da presença de materiais intra ou extraorais (p. ex. resina composta, amálgama, tratamento endodôntico, tratamento ortodôntico, acessórios metálicos como brincos e *piercings*);
- Erros substanciais de angulação na OPG.

3.3. Metodologia da Recolha de Dados

Através do *software* de visualização de imagens médicas *Sectra IDS7*®, foi consultada a listagem de pacientes do Serviço de Estomatologia da ULS Santa Maria com exames imagiológicos associados ao seu processo médico, realizados a partir do 4.º trimestre do ano de 2009. Após uma pesquisa avançada com o filtro «descrição contém "ortopantomografia"» no programa supramencionado e a análise de mais de 10.000 OPG, foi obtida, de acordo com os critérios de inclusão e exclusão, uma amostra de 1.050 OPG pertencentes a um total de 1.050 indivíduos, cuja distribuição por sexo e idade se encontra representada na Tabela 1.

Tabela 1. Distribuição da amostra por sexo e por idade (em anos). F – feminino. M – masculino.

	Idade														
Sexo	**16**	**17**	**18**	**19**	**20**	**21**	**22**	**23**	**24**	**25**	**26**	**27**	**28**	**29**	**30**
F	35	34	34	34	34	34	33	34	34	34	34	34	34	34	40
M	44	41	38	34	34	34	34	34	36	34	34	34	32	34	37

Num segundo momento, após consulta de todos os exames imagiológicos associados ao processo médico de cada paciente incluído neste estudo, foram recolhidas adicionalmente 185 OPG (independentemente dos critérios estabelecidos), perfazendo um total de 1.235 OPG. A Tabela 2 demonstra a distribuição dos indivíduos por número de OPG associadas a cada processo.

Tabela 2. Distribuição da amostra por número de OPG associadas ao processo médico.

Número de OPG						
1	**2**	**3**	**4**	**5**	**6**	**7**
928	84	23	8	5	1	1

Foi elaborado um caderno de recolha de dados no programa *Microsoft Excel*® (Anexo 2, I), onde foram introduzidos os seguintes dados – previamente consultados através do programa *Sectra IDS7*® – dos pacientes incluídos:

1. Número do processo;
2. Sexo;
3. Data de nascimento;
4. Data de realização da OPG;
5. Idade (em anos) do paciente na data de realização da OPG.

Estes dados foram distribuídos em dois cadernos de recolha de dados distintos – o primeiro com uma só folha e o segundo com duas folhas, numeradas 1 e 2. No primeiro caderno, constou o número do processo do paciente associado ao número de projeto (atribuído aleatoriamente). No segundo caderno, a Folha 1 incluiu o número do projeto, o sexo e a data de nascimento do paciente. Na Folha 2 constaram o número do projeto, a data de realização da OPG e a idade do paciente nessa mesma data. Esta folha incluiu ainda os dados das 185 OPG recolhidas num segundo momento, pelo que lhes foi atribuído o número de projeto correspondente ao processo ao qual estão associadas, seguido de uma letra do alfabeto (p. ex. 16A, 16B e 16C). A proteção de dados foi assegurada ao longo do estudo, em conformidade com o artigo 89.º do Regulamento (UE) 2016/679 do Parlamento Europeu e do Conselho, de 27 de abril de 2016 (Regulamento Geral sobre a Proteção de Dados, RGPD).[23]

Todas as OPG incluídas foram guardadas diretamente do programa *Sectra IDS7*®, em formato JPG.

3.4. Tratamento Inicial da Amostra

Para uniformizar a informação presente nas OPG recolhidas, procedeu-se ao recorte de cada imagem de modo a incluir somente a área de interesse – delimitada bilateralmente pelos ramos ascendentes e côndilos da mandíbula. Para este fim, foi utilizada a ferramenta "Recorte" da aplicação Fotografias Microsoft, disponibilizada pelo sistema operativo *Microsoft Windows*® 10. Ainda através desta aplicação, recorreu-se à ferramenta "Retoque" para remover marcadores de orientação presentes nas OPG (p. ex. L, R, Esq. e 100%).

3.5. Configurações Experimentais

Para o desenvolvimento de dois algoritmos distintos – um para classificação de idade e um para identificação positiva – no presente estudo, recorreu-se à linguagem de programação *Python*, uma das mais populares e utilizadas a nível global. O seu amplo reconhecimento é justificado tanto pela sua sintaxe simples e clara, que permite uma aprendizagem e leitura fáceis, como pela sua versatilidade de utilização e dinamismo, possibilitando a correção de erros de forma rápida e descomplicada. Porém, a sua principal vantagem foca-se no facto de ser uma linguagem de código aberto, ou seja, de livre acesso para qualquer utilizador, associada a inúmeras bibliotecas prontas a exportar e programadas para executar tarefas específicas.[24]

As CNN deste estudo foram treinadas através de s*upervised learning* (SL), um dos principais ramos de ML baseado no treino de modelos através de uma amostra de um conjunto de dados rotulados, onde cada exemplo introduzido para treino consiste num par de dados composto por uma entrada (*feature*) e a sua respetiva saída (*label*) correta. Este processo tem por objetivo a aprendizagem de uma função que permita ao modelo mapear dados de entrada e saída e, deste modo, prever corretamente a saída correspondente a novas entradas não-treinadas. SL é um tipo de aprendizagem utilizado maioritariamente para tarefas como a classificação de imagens, e aborda algoritmos com problemas de: regressão, onde as saídas são contínuas; classificação, onde as saídas são categóricas.[24-26]

As CNN requerem treino com grandes quantidades de dados para alcançar um elevado desempenho. Uma vez que na área médica é difícil obter amostras tão substanciais – o que constitui um dos maiores desafios para a classificação de imagens médicas através de algoritmos de DL –, recorreu-se à técnica de *transfer learning* (TL) para ultrapassar o referido obstáculo. O conceito de TL traduz-se no uso de modelos pré-treinados com um elevado conjunto de dados como "esqueleto" do algoritmo em desenvolvimento, ocorrendo transferência de conhecimento previamente adquirido de uma tarefa para outra nova e semelhante. Para este estudo foram aplicadas duas distintas estratégias de TL: *fine-tunning* e *feature extraction*. Na primeira, os parâmetros vão sendo adaptados consoante o decorrer do ajuste do modelo pré-treinado de CNN. Na segunda, as camadas convolucionais das CNN – responsáveis pela deteção e aprendizagem de características de imagens como texturas, formas e limites – são congeladas, não sendo atualizadas/ensinadas durante o treino.[27-28]

De entre os vários modelos de CNN disponibilizados *online* e pré-treinados com a *ImageNet*, um conjunto de dados composto por 14 milhões de imagens naturais e um total de 1.000 classes, optou-se pelo modelo pré-treinado VGG16 (importado através da interface de programação de aplicações *Keras* da biblioteca *Tensorflow*). Desenhado especificamente para tarefas de classificação e reconhecimento de imagem, este modelo é constituído por uma série de NN com uma profundidade de 16 camadas (9 camadas convolucionais, 4 camadas *max--pooling* e 3 camadas totalmente conectadas), sendo amplamente estudado e utilizado para diagnóstico imagiológico na área médica por oferecer um bom equilíbrio entre complexidade e acurácia e comportar-se como um bom *feature extractor*.[27,29-30]

3.5.1. Classificação de Idade

O algoritmo desenvolvido para classificação de idade aborda um problema de classificação binária de idade. Uma amostra de 1.200 OPG foi selecionada a partir das 1.235 OPG recolhidas, sendo excluídas as OPG de indivíduos com idade inferior a 16 anos ou superior a 30 anos no momento da sua realização. De seguida, a amostra foi dividida em dois intervalos de idade – "16 a 23 anos" e "24 a 30 anos" –, posteriormente representados sob a forma de classes: classe positiva "**16_23**" (saída 1); classe negativa "**24_30**" (saída 0).

Sumariamente, a arquitetura final do modelo inclui:

- Camadas convolucionais do tipo Conv2D, cujas saídas são mapas de características;
- Camadas de *pooling* do tipo MaxPooling2D, responsáveis por reduzir a dimensionalidade dos dados, o tempo de computação e o risco de *overfitting*;
- Camadas de *Dropout*, que constituem técnicas de regularização baseadas em desligar aleatoriamente neurónios durante o treino para prevenir *overfitting*;
- Camadas totalmente conectadas, responsáveis por realizar previsões através das características aprendidas pelas camadas convolucionais.

A sua última camada totalmente conectada apresenta uma função de ativação sigmóide capaz de atribuir a determinada entrada um valor real do intervalo (0, 1] através do qual, considerando o ponto de corte 0.5, é associado uma única saída provável (0 ou 1) – neste caso, atribuir a uma OPG a classe "16_23" ou a classe "24_30". À exceção das camadas inicial (*input*) e final (*output*), foi aplicada às restantes camadas (*hidden*) a função de ativação ReLU (*Rectified Linear Unit*) para aprendizagem de padrões e características complexos.[29,31]

Overfitting constitui um dos maiores e mais comuns problemas em ML, ocorrendo quando um modelo falha ao generalizar de dados treinados para novos dados, levando a resultados de previsão incorretos. Este fenómeno dá-se quando um algoritmo é demasiado complexo ou aprende ruído e detalhes irrelevantes aquando do treino, o que o faz apresentar um desempenho excecional nesta fase e um desempenho fraco no teste.[32-35]

3.5.2. Identificação Positiva

O algoritmo desenvolvido para identificação médico-legal aborda um problema de classificação binária de identificação positiva, em contexto de redes siamesas, focado em determinar se duas imagens diferentes pertencem, ou não, a um único indivíduo. As 1.235 OPG

recolhidas foram combinadas entre si, através de uma função com base na fórmula combinatória*, para gerar dois tipos de pares de imagens: imagens do mesmo indivíduo; imagens de indivíduos diferentes. Foram gerados 287 pares positivos – ou seja, com imagens do mesmo indivíduo –, num total de 761.995 pares possíveis. Foram ainda definidas as seguintes classes: classe positiva "***Same***" (saída 1); classe negativa "***Different***" (saída 0).

*Fórmula Combinatória: $C_k^n = \frac{n!}{k!(n-k)!}$, com

n = n.º total de elementos de um conjunto (1.235);
k = n.º de elementos que pretendemos selecionar do conjunto (2, para formar um par de OPG).

A arquitetura do modelo consiste numa rede siamesa composta por dois ramos "gémeos" (ou seja, iguais entre si), escolhida com base no propósito de desenvolver um algoritmo capaz de comparar e determinar a semelhança entre duas imagens. Ambos os ramos integram o modelo pré-treinado VGG16, utilizando-o como *feature extractor*. Para isto, todas as camadas convolucionais e *pooling* do VGG16 foram "congeladas", assegurando a sua inalteração durante o treino do modelo e a retenção de todo o conhecimento previamente adquirido.[28,36] As camadas totalmente conectadas originais do VGG16 foram removidas, sendo substituídas por:

- Uma camada *pooling* do tipo GlobalAveragePooling2D, onde as dimensões espaciais dos mapas de características são reduzidas e estes são compilados num só valor, o "vetor de características", representativo da saída de cada ramo da rede siamesa;
- Uma camada de concatenação, responsável por combinar as duas saídas num único vetor, o que permite ao modelo considerar as características de ambas as imagens simultaneamente;
- Três camadas totalmente conectadas, onde as duas primeiras camadas apresentam, respetivamente, 512 e 128 neurónios associados à função de ativação ReLU, e a última camada apresenta somente um neurónio, associado à função de ativação sigmóide (responsável por atribuir a um par de OPG a classe "*Same*" ou a classe "*Different*").

Deste modo, o funcionamento do presente modelo resume-se no processamento paralelo e simultâneo de duas imagens (uma em cada ramo) pertencentes a um par, onde o modelo pré-treinado VGG16 extrairá características relevantes com base no que aprendeu no pré-treino com *ImageNet* e, após compilar todas as informações num único vetor de características, irá compará-las para determinar se as duas imagens de um mesmo par pertencem, ou não, ao mesmo indivíduo.

3.6. Pré-Processamentos dos Dados

Cada amostra de ambos os algoritmos desenvolvidos foi submetida a um pré--processamento de dados, com aplicação de técnicas como "redimensionamento", "normalização" e "*data augmentation*". A primeira técnica aplica uma mesma dimensão (em pixels) para toda a amostra, assegurando a uniformização dos dados de entrada – passo este obrigatório em CNN como o VGG16. Por sua vez, a segunda técnica foca-se na normalização dos dados introduzidos através do ajuste da escala de cada característica presente, atribuindo a todas estas uma única escala uniforme (habitualmente de 0 a 1).[34,36] Por fim, na terceira técnica, a quantidade de dados a utilizar para treino é aumentada pela criação de variações artificiais dos dados originais através da aplicação de transformações (p. ex. rotação, espelhamento, *zoom*, alteração de brilho/contraste, desfocagem), com o intuito de colmatar a escassez de dados disponíveis na fase de treino. Todo este processo visa aumentar a generalização e robustez do modelo, contribuindo para o seu melhor desempenho.[28,32,34,37]

3.6.1. Classificação de Idade

Com a ferramenta ImageDataGenerator, a amostra do modelo de classificação de idade foi inicialmente redimensionada para 128x128 pixels – de modo a diminuir os recursos computacionais e evitar *overfitting* –, sendo seguidamente normalizada através da redução dos valores dos pixels de cada imagem (originalmente compreendidos entre 0 e 255) para uma única escala de 0 a 1. Os dados foram aumentados com a aplicação de um vasto leque de transformações – variação de brilho, rotação, espelhamento horizontal e/ou vertical, mudança de posição e acrescento de distorção – e a amostra foi aleatoriamente dividida em três partes e distribuída de acordo com as fases treino, validação e teste, como demonstrado na Tabela 3.

Tabela 3. Divisão e distribuição das OPG para classificação de idade, por fase e por classe.

Treino		**Validação**		**Teste**	
840 (70%)		210 (17,5%)		150 (12,5%)	
"16_23"	**"24_30"**	**"16_23"**	**"24_30"**	**"16_23"**	**"24_30"**
420	420	105	105	75	75

3.6.2. Identificação Positiva

Por o modelo VGG16 ter sido utilizado como *feature extractor*, o pré--processamento dos dados de entrada do modelo de identificação positiva seguiu a formatação definida no pré-treino do VGG16 com *ImageNet*, recorrendo às funções manuais da biblioteca *Tensorflow*. Como todas as imagens pertencentes ao conjunto de dados *ImageNet* são imagens coloridas em formato RGB, estas apresentam 3 canais de cores (vermelho, verde e azul), cada um com o seu próprio valor médio de pixels. Contrariamente, as OPG incluídas no presente estudo são imagens com um único canal representativo de uma escala de cinzentos, pelo que foi necessário ajustar e normalizar os dados através da subtração das médias de pixels de cada canal de RGB e redução dos pixels para valores próximos de 0. As imagens foram ainda redimensionadas para 214x214 pixels e aumentadas com recurso à transformação por espelhamento horizontal e/ou vertical. Denote-se que, devido à acentuada escassez de dados da classe positiva (par do mesmo indivíduo) em relação à classe negativa (par de indivíduos diferentes), foi aplicada a técnica *random undersampling* para equilibrar a discrepância de dados disponíveis entre classes, sendo selecionados aleatoriamente 800 pares de OPG da classe negativa com base numa proporção de aproximadamente 1:3. De seguida, a amostra foi dividida e distribuída aleatoriamente pelas fases treino, validação e teste, representada na Tabela 4.

Tabela 4. Divisão e distribuição dos pares de OPG para identificação positiva, por fase e por classe.

Treino		**Validação**		**Teste**	
760 (70%)		163 (15%)		164 (15%)	
"Same"	***"Different"***	***"Same"***	***"Different"***	***"Same"***	***"Different"***
201	559	43	120	43	121

3.7. Otimização de Hiperparâmetros

Os hiperparâmetros consistem em configurações das quais o processo de aprendizagem de um modelo de AI depende, estabelecidas previamente à fase de treino. No contexto particular de CNN, estes parâmetros definem características do modelo como a sua arquitetura, o seu processo de aprendizagem durante o treino e a sua capacidade de generalizar e evitar *overfitting*, condicionando, assim, a sua acurácia final. A otimização de hiperparâmetros (*hyperparameter tunning*) representa, deste modo, uma etapa crucial no desenvolvimento de algoritmo de CNN, permitindo o alcance de um elevado desempenho quando são conseguidas as configurações mais adequadas para a resolução do problema que determinado modelo aborda.[31,38-39]

3.7.1. Classificação de Idade

Para o modelo de classificação de idade, de acordo com os melhores resultados obtidos após avaliação de diferentes combinações de hiperparâmetros, foi definido um tamanho de lote (*batch size*) igual a 8, o que significa que são processadas simultaneamente oito entradas de cada vez durante a fase de treino, permitindo uma iteração (ou seja, atualização dos parâmetros do modelo) mais regular e evitar sobrecarga computacional e possíveis erros por falta de memória. Foram ainda testados tamanhos de lote iguais a 16 e 32. O número de épocas (*n-epochs*) estabelecido foi 200, determinando o número de vezes em que o algoritmo percorre o conjunto de dados na sua totalidade (para trás e para a frente) durante o treino. Este valor é crucial para a capacidade de generalização do modelo e, quando desadequado, pode levar a *overfitting*. Para prevenir este fenómeno, foi implementado um mecanismo de *early stopping* com *patience* igual a 10, onde o treino do modelo é interrompido quando não são registadas melhorias no seu desempenho após dez épocas consecutivas.[31]

É igualmente pertinente referir que foi testada a dimensão 224x224 pixels, referente ao redimensionamento das imagens aquando da fase de pré-processamentos dos dados.

Durante o treino, recorreu-se ainda à função de perda de entropia cruzada binária, amplamente utilizada para resolver problemas de classificação binária em combinação com a função de ativação sigmóide, por esta determinar a capacidade do modelo de prever classes corretamente através da perda (*loss*) – parâmetro métrico que calcula a diferença entre as classes previstas e as classificações verdadeiras durante as fases treino e validação, sendo crucial para perceber se o modelo é, ou não, bom a prever resultados e se sofreu *overfitting*.[31]

Os otimizadores são algoritmos cujo papel é essencial para o treino de CNN, uma vez que são responsáveis por ajustar parâmetros como a taxa de aprendizagem do modelo e os seus pesos de modo a minimizar gradualmente a função de perda e, por conseguinte, melhorar as previsões obtidas e o desempenho geral do modelo. Para este estudo, foi selecionado o otimizador RMSprop (*Root Mean Square Propagation*) com uma taxa de aprendizagem igual a 0,0001, sendo altamente vantajoso por adaptar de forma dinâmica a taxa de aprendizagem ao longo do treino, regulando a frequência de revisão e atualização dos parâmetros do modelo. Foram igualmente testadas taxas de aprendizagem iguais a 0,01 e 0,001.[31]

3.7.2. Identificação Positiva

Para o modelo de identificação positiva, foi definido um tamanho de lote igual a 8 e um número de épocas igual a 50. Além da implementação de *early stopping* com uma *patience* igual a 10, foi também adicionado um mecanismo de redução da taxa de aprendizagem (ReduceLROnPlateau) com *patience* igual a 5 e um fator igual a 0,2 – o que implica uma redução da taxa de aprendizagem para 20% do seu valor inicial. Este mecanismo é aplicado automaticamente quando o modelo para de melhorar, com o objetivo de ajustar os pesos do modelo e otimizar o desempenho através de uma abordagem de aprendizagem mais lenta. Foi ainda atribuído à classe positiva "*Same*" um peso três vezes maior ao da classe negativa "*Different*", para compensar a diferença acentuada entre o número de dados de cada classe.[31]

Considerando o problema de classificação binária com CNN, foi selecionada, à semelhança do modelo de classificação de idade, a função de perda de entropia cruzada binária. Porém, foi escolhido o otimizador Adam (*Adaptive Moment* Estimation) em detrimento de outras opções mais convencionais devido à sua robustez, capacidade de lidar com ruído, e eficácia e rapidez em memorizar e convergir informação, associado a uma taxa de aprendizagem inicial de 0,001.[31]

3.8. Análise Estatística

Os dados inseridos no *Microsoft Excel*® foram exportados diretamente para o *software* de análise estatística de dados *IBM SPSS*® *Statistics* 29, onde foi criada uma base de dados (Anexo 2, II) para análise estatística descritiva dos dados.

O desempenho de cada modelo foi avaliado através da comparação das classificações verdadeiras dos dados (entradas) com as previsões de classificação geradas pelos modelos (saídas) na fase teste, sob a forma de matrizes de confusão. Deste modo, determinou-se:

- Verdadeiros positivos (VP): previsão correta da classe positiva;
- Verdadeiros negativos (VN): previsão correta da classe negativa;
- Falsos positivos (FP): previsão da classe positiva quando a classe verdadeira é negativa;
- Falsos negativos (FN): previsão da classe negativa quando a classe verdadeira é positiva.

Com estes dados, foram aplicados a cada classe os seguintes parâmetros métricos, específicos para avaliação do desempenho preditivo de modelos de ML: acurácia, precisão, sensibilidade e F_1 *Score*.[40-42]

A acurácia representa o desempenho geral de um modelo, determinado pela razão entre o número de previsões corretas (positivas e negativas) e o total de previsões realizadas pelo modelo, de acordo com a seguinte fórmula:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}.$$

A precisão – igualmente designada por "valor preditivo positivo" para a classe positiva e por "valor preditivo negativo" para a classe negativa – quantifica a confiabilidade do modelo na previsão de uma classe, a partir da razão entre o número de previsões corretas nessa classe e o total de previsões para essa classe. O cálculo da precisão para as classes positiva e negativa traduz-se nas seguintes fórmulas:

$$Precisão\ (classe\ positiva) = \frac{VP}{VP + FP}.$$

$$Precisão\ (classe\ negativa) = \frac{VN}{VN + FN}.$$

A sensibilidade (*recall,* referente à classe positiva) e a especificidade (referente à classe negativa) determinam a capacidade do modelo de identificar corretamente a respetiva classe, ao calcular a razão entre o número de previsões corretas para essa classe e o número total de elementos que verdadeiramente pertencem a essa classe. O cálculo da sensibilidade e da especificidade traduz-se nas seguintes fórmulas:

$$Sensibilidade = \frac{VP}{VP + FN}.$$

$$Especificidade = \frac{VN}{VN + FP}.$$

O F_1 *Score* traduz o equilíbrio entre a precisão e a sensibilidade num único valor, calculado através da média harmónica destas duas métricas e obtido pela fórmula:

$$F_1\ Score = 2 \times \frac{Precisão \times Sensibilidade}{Precisão + Sensibilidade}.$$

3.9. *Heatmaps*

O processo de tomada de decisão de ambos os modelos de classificação foi estudado a partir de *heatmaps* (mapas de calor) – representações gráficas obtidas através do método baseado em gradientes Grad-CAM (*Gradient-weighted Class Activation Mapping*). Em contexto de CNN, estes mapas utilizam cores para quantificar a contribuição de cada área/região de uma imagem de entrada para a previsão de classificação de um modelo, onde cores frias (azul e verde) representam áreas com menor interesse e cores quentes (vermelho e laranja) representam áreas com maior influência e peso na tomada de decisão. Deste modo, os *heatmaps* contribuem para uma melhor interpretação e compreensão do comportamento dos modelos de CNN durante a classificação de imagens, sendo comumente utilizados em áreas médicas.[43-44]

Neste estudo, foram gerados *heatmaps* somente para o conjunto de dados utilizado na fase de teste, específico para cada um dos modelos.

4. RESULTADOS

4.1. Análise Descritiva

Do total de 1.050 indivíduos incluídos no presente estudo, 516 (49,14%) pertencem ao sexo feminino e 534 (50,86%) pertencem ao sexo masculino, como demonstrado na Figura 1 (Anexo 3, I). A Figura 2 demonstra que não existem diferenças significativas entre o número de indivíduos dos dois intervalos de idade estabelecidos (16 a 23 e 24 a 30 anos) (Anexo 3, II).

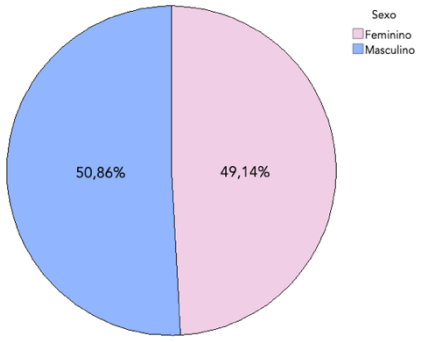


Figura 1. Distribuição dos indivíduos da amostra por sexo, em percentagem (%).

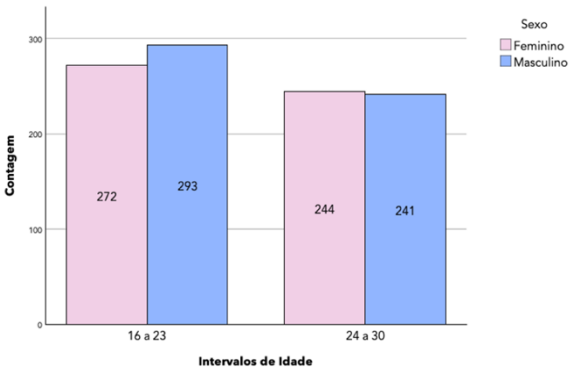


Figura 2. Distribuição dos indivíduos da amostra por sexo e por intervalo de idades (em anos).

4.2. Classificação de Idade

4.2.1. Avaliação de Desempenho em Treino e Validação

Os valores de acurácia e de perda foram registados, por época, ao longo do treino e da validação do modelo de classificação de idade, sendo possível observar o seu comportamento durante estas duas fases na Figura 3. Na Tabela 5 constam os valores finais e a variação máxima e mínima das duas métricas.

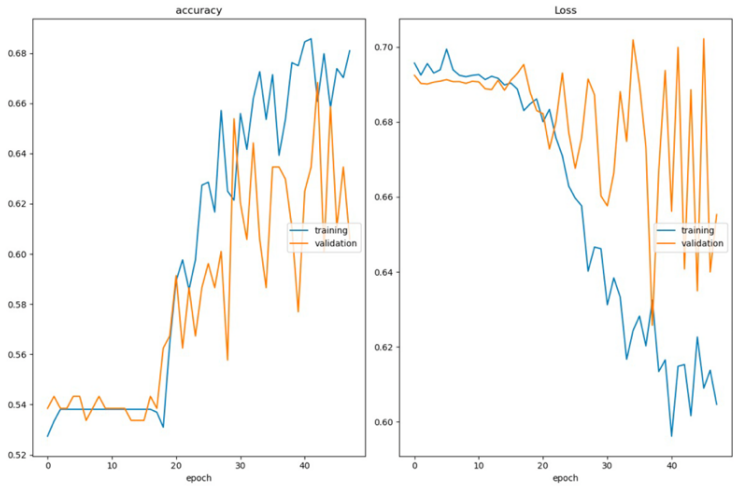


Figura 3. Acurácia (esquerda) e função de perda (direita) durante o treino e a validação do modelo de classificação de idade.

Tabela 5. Valores mínimo, máximo e final para acurácia e função de perda do modelo de classificação de idade, por fase.

	Acurácia			Perda		
Fase	**Mínimo**	**Máximo**	**Valor Final**	**Mínimo**	**Máximo**	**Valor Final**
Treino	0,53	0,69	0,68	0,60	0,70	0,61
Validação	0,53	0,67	0,61	0,63	0,70	0,66

4.2.2. Avaliação de Desempenho Final em Teste

Os resultados da fase teste para cada classe foram apresentados sob a forma de matriz de confusão, representada na Figura 4, traduzindo-se em 72 VP, 55 VN, 20 FP e 3 FN de um total de 150 previsões realizadas pelo modelo de classificação de idade.

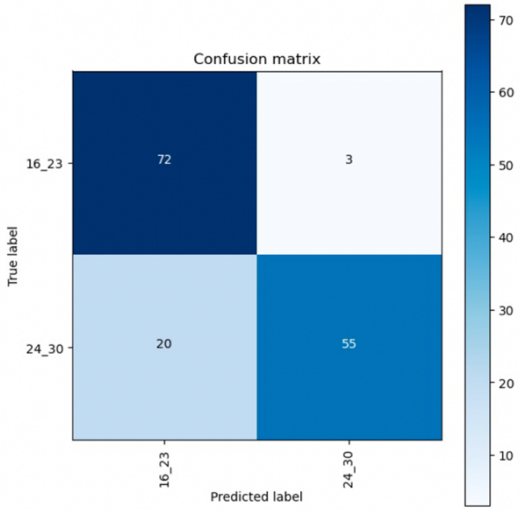


Figura 4. Matriz de confusão aplicada à amostra de teste do modelo de classificação de idade.

Por sua vez, após a aplicação dos parâmetros métricos previamente mencionados, foram obtidos como valores médios: precisão igual a 87%; sensibilidade igual a 85%; *F_1 Score* igual a 84%. Os valores de precisão, sensibilidade e *F_1 Score* discriminados por classe constam na Tabela 6. Assim, o modelo de classificação de idade em estudo alcançou, na fase teste, uma acurácia final igual a 85%.

Tabela 6. Valores de precisão, sensibilidade e *F_1 Score* do modelo de classificação de idade, por classe.

Classe	Precisão	Sensibilidade	*F_1 Score*
16_23	0,78	0,96	0,86
24_30	0,95	0,73	0,83

4.2.3. *Heatmaps*

Os resultados deste estudo foram ainda apresentados sob a forma de *heatmaps* (Anexo 4). Na Figura 5 é exemplificado um caso de previsão correta da classe "16_23", com uma probabilidade igual a 90,12% de pertencer à classe "16_23" (logo com probabilidade 9,88% de pertencer à classe "24_30"). Na Figura 6 é exemplificado um caso de previsão correta da classe "24_30", com uma probabilidade igual a 12,69% de pertencer à classe "16_23" (logo com probabilidade 87,31% de pertencer à classe "24_30"). É de salientar que, como o modelo estima a probabilidade de o indivíduo pertencer, ou não, à classe "16_23", valores superiores a 50% são previstos como pertencentes à classe positiva "16_23", enquanto valores inferiores são previstos como pertencentes à classe negativa "24_30" uma vez que, neste caso, a probabilidade de pertencer à classe negativa é superior à de pertencer à classe positiva.

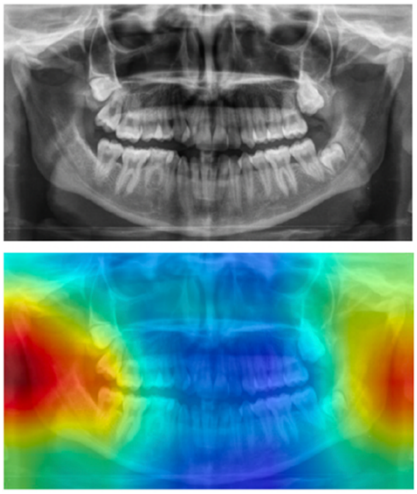


Figura 5. *Heatmap* com previsão correta da classe "16_23".

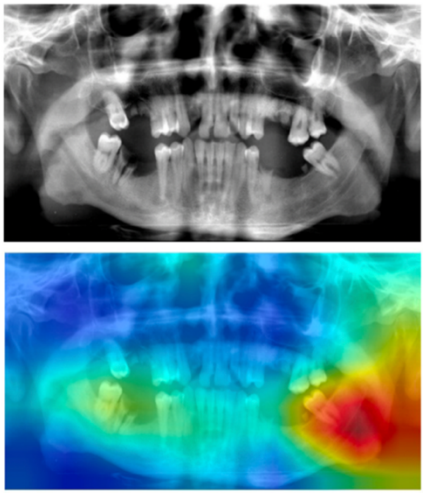


Figura 6. *Heatmap* com previsão correta da classe "24_30".

4.3. Identificação Positiva

4.3.1. Avaliação de Desempenho em Treino e Validação

Os valores da acurácia e da função de perda foram registados, por época, ao longo do treino e da validação do modelo de identificação positiva, sendo possível observar o seu comportamento durante estas duas fases na Figura 7. A Tabela 7 inclui os valores finais e a variação máxima e mínima das duas métricas.

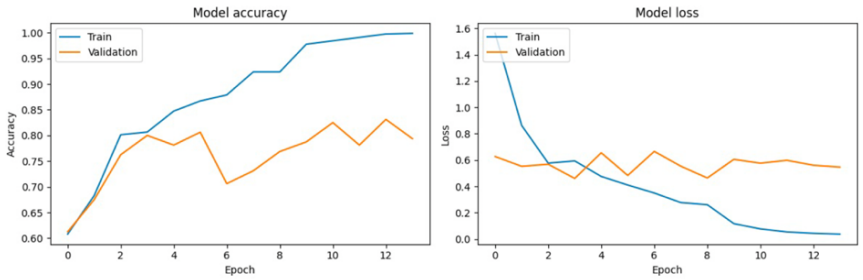


Figura 7. Acurácia (esquerda) e função de perda (direita) durante o treino e a validação do modelo de identificação positiva.

Tabela 7. Valores mínimo, máximo e final para acurácia e perda do modelo de identificação positiva, por fase.

	Acurácia			Perda		
Fase	**Mínimo**	**Máximo**	**Valor Final**	**Mínimo**	**Máximo**	**Valor Final**
Treino	0,56	0,99	0,99	0,04	2,78	0,04
Validação	0,61	0,83	0,79	0,46	0,67	0,55

4.3.2. Avaliação de Desempenho Final em Teste

Os resultados da fase de teste para cada classe foram apresentados sob a forma de matriz de confusão, representada na Figura 8, tendo sido obtidos 29 VP, 111 VN, 10 FP e 14 FN de um total de 164 previsões realizadas pelo modelo de identificação positiva.

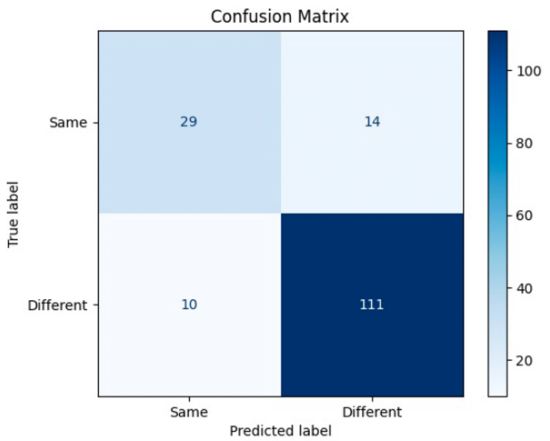


Figura 8. Matriz de confusão aplicada à amostra de teste do modelo de identificação positiva.

Com a aplicação dos parâmetros métricos previamente definidos, foi obtido um valor médio igual a 85% para a precisão, a sensibilidade e o F_1 *Score*, de acordo com os pesos de cada classe inicialmente estabelecidos. Os valores de precisão, sensibilidade e F_1 *Score* discriminados por classe constam na Tabela 8. Assim, o modelo de identificação positiva em estudo alcançou, na fase teste, uma acurácia final igual a 85%.

Tabela 8. Valores de precisão, sensibilidade e F_1 *Score* do modelo de identificação positiva, por classe.

Classe	Precisão	Sensibilidade	F_1 Score
Same	0,74	0,67	0,71
Different	0,89	0,92	0,90

4.3.3. *Heatmaps*

Também os resultados deste modelo foram apresentados sob a forma de *heatmaps* (Anexo 5). Na Figura 9 é exemplificado um caso de previsão correta da classe "*Same*", com uma probabilidade igual a 89,38% de pertencer a esta classe. Na Figura 10 é exemplificado um caso de previsão correta da classe "*Different*", com uma probabilidade igual a 1,21% de pertencer à classe "*Same*" – logo, uma probabilidade igual a 98,79% de pertencer à classe "*Different*"). Denota-se que valores superiores a 50% são previstos como pertencentes à classe positiva "*Same*", enquanto valores inferiores são previstos como pertencentes à classe negativa "*Different*".

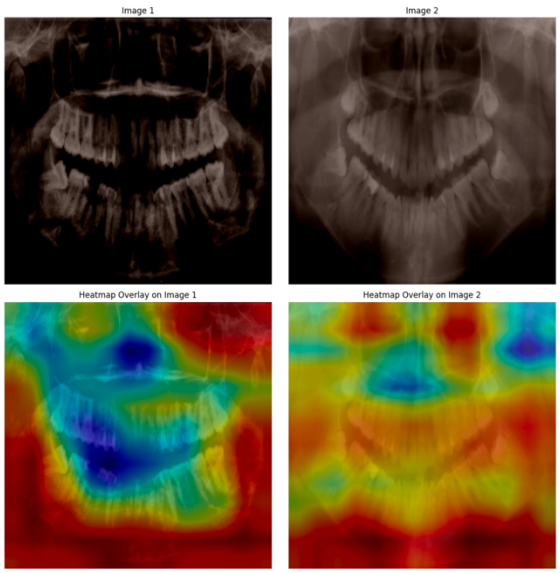


Figura 9. Par de *heatmaps* com previsão correta da classe "*Same*".

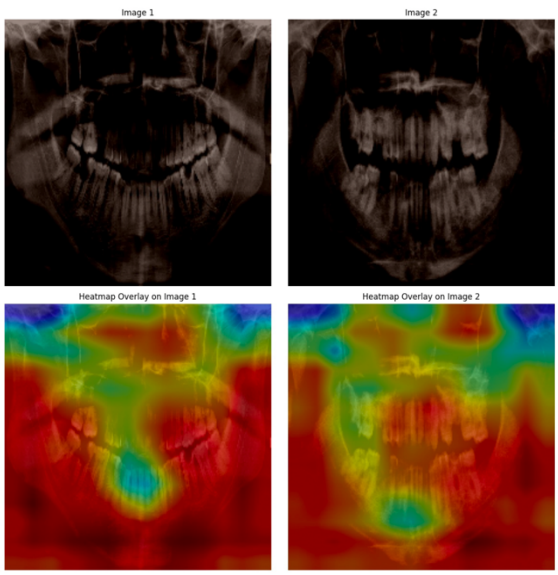


Figura 10. Par de *heatmaps* com previsão correta da classe "*Different*".

5. DISCUSSÃO

5.1. Classificação de Idade

5.1.1. Caracterização da Amostra

Para o desenvolvimento do modelo de classificação de idade do presente estudo, foi utilizada uma amostra total de 1.235 OPG pertencentes a 1.050 indivíduos de ambos os sexos (feminino e masculino), com idades compreendidas entre os 16 e os 30 anos. Foi incluída nas amostras de treino, validação e teste o mesmo número de OPG de cada classe, numa proporção 1:1, para evitar que possíveis discrepâncias entre classes na quantidade de dados disponíveis influenciem negativamente o modelo em questão.

5.1.2. Avaliação de Desempenho em Treino e Validação

Após o treino e a validação, foi obtida uma acurácia final igual a 68% e 61%, respetivamente. Para este parâmetro métrico, é esperado de um modelo com bom desempenho que a curva de acurácia aumente progressivamente ao longo do treino, significando isto que o modelo está a aprender as características e padrões presentes nos dados de entrada e, por sua vez, a realizar mais previsões corretas para cada classe. Durante a validação, é expectável que a curva de acurácia aumente inicialmente – apesar de não tão acentuadamente como em contexto de treino – e estabilize até ao final desta fase, revelando que o modelo consegue prever corretamente novos dados, ou seja, que tem boa capacidade de generalização.[31]

Os resultados do modelo de classificação de idade deste estudo demonstraram que a acurácia aumentou progressivamente durante o treino, como expectável, o que traduz uma boa aprendizagem dos dados introduzidos nesta fase e melhorias nas previsões realizadas. Em contrapartida, durante a validação, apesar de a acurácia aumentar inicialmente até estabilizar, é registada uma descida ligeira nas últimas cinco épocas. Este comportamento sugere que o modelo poderá apresentar algum *overfitting*, com possível memorização de características específicas como o ruído, levando a uma pior generalização do modelo perante novos dados na fase de validação.[32-35]

Relativamente à função de perda, foram registados valores iguais a 0.61 e 0.66 após treino e validação, respetivamente. Para este parâmetro métrico, um valor inferior é sinónimo de melhores resultados, pelo que o comportamento expectável de um bom modelo se baseia na

diminuição progressiva da perda durante o treino e a validação, seguida de estabilização nesta última fase. Este padrão traduz uma boa capacidade de previsão dos dados de treino e uma boa generalização do modelo perante novos dados, introduzidos na fase de validação.[31] No presente modelo de classificação, verificou-se a diminuição progressiva da perda ao longo de todo treino, verificando-se o mesmo comportamento durante as primeiras épocas da validação. A partir desse ponto, a função de perda estabilizou e, por fim, voltou a subir ligeiramente. Este comportamento, aliado a um valor final de perda na validação superior ao obtido no treino, sugere o início de *overfitting*.[32-35]

O modelo de classificação de idade apresentou, portanto, resultados razoáveis nas fases de treino e validação, demonstrando um comportamento adequado até determinado ponto, a partir do qual surgiram indícios de *overfitting*.

5.1.3. Avaliação de Desempenho Final em Teste

A classe positiva "16_23" obteve uma precisão de 78%, uma sensibilidade de 96% e um F_1 *Score* de 86%. Isto significa que o modelo não é tão confiável quando prevê a classe "16_23", errando 22% das vezes em que atribui esta classificação a uma OPG (o que se traduziu em 20 FP num total de 150 previsões). Por outro lado, a sensibilidade para esta classe é muito elevada, o que se traduz numa maior capacidade do modelo em identificar corretamente OPG pertencentes a "16_23".[40-42]

Já a classe negativa "24_30" obteve uma precisão de 95%, uma sensibilidade de 73% e um F_1 *Score* de 83%. Isto significa que o modelo é altamente confiável a prever a classe "24_30", errando somente 3 vezes (FN) – nas quais atribuiu esta classe a uma OPG pertencente a "16_23". Por sua vez, a capacidade do modelo em identificar corretamente OPG pertencentes a "24_30" é inferior, classificando-as como "16_23" em 27% dos casos (20 FP) e, por conseguinte, levando a uma sensibilidade mais baixa para a classe negativa.[40-42]

Os valores de F_1 *Score* obtidos revelam uma ligeira discrepância entre classes, existindo maior equilíbrio entre a precisão e a sensibilidade para a classe "16_23" do que para a classe "24_30". Logo, o modelo apresenta desempenho geral superior para a classe positiva.[40-42]

Noutra vertente, foi obtida uma acurácia final igual a 85%, o que traduz um bom desempenho geral por parte do modelo – uma vez que este classificou corretamente 85% das OPG da fase de teste –, porém com espaço para evolução. Como mencionado previamente, os resultados obtidos durante o treino e a validação evidenciaram *overfitting* nas últimas épocas.

Assim, é relevante otimizar os hiperparâmetros definidos para evitar este fenómeno e aumentar a generalização do modelo.[31] Além disto, após análise dos resultados obtidos sob a forma *heatmaps*, é possível afirmar que o modelo não se focou em áreas relevantes da OPG para o processo de decisão, sugerindo novamente que foram memorizados detalhes demasiado específicos, inclusive ruído, durante a fase de treino. Deste modo, é importante testar outras possíveis arquiteturas, como ResNet50 e VGG19, e técnicas de processamento de imagem e visão computacional (p. ex. *feature extraction* e segmentação de imagem), com o intuito de desenvolver a capacidade do modelo de deteção e aprendizagem de padrões e características importantes.[27-30]

5.1.4. Aplicação ao Contexto Médico-Legal

Num contexto médico-legal, o modelo de classificação de idade apresentou melhores resultados na identificação de indivíduos dos 16 aos 23 anos, em comparação com indivíduos dos 24 aos 30 anos. Este estudo é particularmente relevante para situações de DVI, uma vez que a classificação de idade possibilita a divisão de cadáveres de acordo com intervalos de idade pré-definidos, contribuindo para uma maior eficiência na triagem das vítimas mortais e consequente agilização do processo de identificação médico-legal neste contexto.

Este estudo é pioneiro em contexto de DVI, sendo que outras investigações realizadas neste âmbito recorrem a AI para realizar a estimativa de idade em crianças, através da avaliação do desenvolvimento dentário em OPG. O estudo de Mohammad et al. (2024) estimou a idade de uma população de 1.892 crianças malaias a partir da avaliação do desenvolvimento dos pré-molares inferiores em OPG, com recurso a um modelo de CNN e à técnica de segmentação de imagem, para aplicação em situações de DVI.[45]

5.2. Identificação Positiva

5.2.1. Caracterização da Amostra

Dos pares formados a partir das 1.235 OPG recolhidas, somente 287 são pares positivos (pertencentes à classe "*Same*"), devido à escassez de indivíduos com mais do que uma OPG associada ao seu processo médico (122 num total de 1.050 indivíduos) incluídos neste estudo.

Para tentar contornar esta discrepância, foram incluídos 800 pares negativos (pertencentes à classe negativa "*Different*"), estabelecendo uma proporção aproximada de 1:3

e perfazendo um total de 1.087 pares em estudo, e foi definido como hiperparâmetro um peso igual a três para a classe positiva. Deste modo, durante todo o processo de aprendizagem e previsão, o modelo considera que cada erro de classificação da verdadeira classe positiva é três vezes mais prejudicial para os resultados do que erros da verdadeira classe negativa.[31]

Apesar disto, a escassez de dados representa uma provável causa para *overfitting*, pelo que é imperativo integrar um maior conjunto de dados em estudos futuros neste âmbito.[32-35]

5.2.2. Avaliação de Desempenho em Treino e Validação

Os resultados do modelo de identificação positiva deste estudo demonstraram uma acurácia final de treino e de validação igual a 99% e 79%, respetivamente. O comportamento deste parâmetro foi semelhante durante as primeiras duas épocas do treino e da validação, caracterizado por um aumento acentuado. Posteriormente, a acurácia continuou a aumentar progressivamente durante o treino, atingindo excelentes resultados, enquanto durante a validação foram observadas flutuações com tendência para estabilização. Relativamente à função de perda, o modelo registou valores iguais a 0.04 e 0.55 após o treino e a validação, respetivamente, o que constitui uma discrepância muito acentuada. Enquanto a perda diminuiu progressivamente durante o treino, esta manteve-se entre os mesmos valores durante a validação, com oscilações contínuas, estabilizando nas últimas épocas.

O comportamento combinado dos dois parâmetros métricos durante estas duas fases – principalmente a função de perda – demonstrou que o modelo aprendeu muito bem os dados de treino, começando a sobreajustar-se a estes nas últimas épocas, porém não foi capaz de generalizar as características e padrões que aprendeu durante a validação, evidenciando *overfitting*.[31-35]

5.2.3. Avaliação de Desempenho Final em Teste

A classe positiva "*Same*" obteve uma precisão de 74%, uma sensibilidade de 67% e um F_1 *Score* de 71%, enquanto a classe negativa "*Different*" alcançou uma precisão de 89%, uma sensibilidade de 92% e um F_1 *Score* de 90%. Estes resultados comprovam que o modelo é muito mais preciso e sensível à classe "*Different*", visto que previu corretamente 89% dos casos (111 VN de entre 125 previsões para esta classe) e demonstrou uma capacidade ainda mais elevada de identificar corretamente pares de OPG pertencentes a esta classe, errando somente em 8% dos casos (10 FP). Os valores F_1 *Score* obtidos reafirmam o distinto desempenho entre classes,

verificando um melhor desempenho para a classe "*Different*" – resultado do maior equilíbrio entre precisão e sensibilidade nesta classe, comparativamente à classe "*Same*".[40-42]

Assim, o modelo de identificação positiva alcançou, à semelhança do modelo de classificação de idade, uma acurácia final igual a 85%. Este resultado traduz um bom desempenho geral por parte do modelo, onde somente 15% da amostra (24 num total de 164 previsões realizadas) foi incorretamente classificada. Por sua vez, após interpretação dos *heatmaps* obtidos para as OPG de teste, é possível afirmar que o modelo se focou em estruturas de grande relevância – principalmente na dentição e nos ossos maxila e mandíbula – para tomar as suas decisões, porém pouco específicas. A região perinasal constituiu a área menos interativa.[40-44] Deste modo, é possível concluir que o modelo pré-treinado VGG16 funcionou de forma eficaz como *feature extractor*, sendo capaz de reter características e padrões importantes para o bom desempenho do modelo.[27]

Apesar disto, ainda existem alguns aspetos importantes a aperfeiçoar neste modelo de classificação. Primeiramente, o modelo revelou sinais claros de *overfitting* durante o treino e a validação – dos quais se destaca a discrepância acentuada entre os valores finais de perda destas duas fases. Também a escassez de dados "*Same*" constituiu um provável potenciador deste fenómeno, uma vez que a existência de poucos dados leva a que o modelo tenha de aprender a partir de um conjunto de exemplos com pouca variabilidade – justificando, portanto, a menor capacidade de generalização observada para a classe positiva. Posto isto, é recomendado aumentar a quantidade de pares de OPG do mesmo indivíduo, otimizar os hiperparâmetros do modelo (p. ex. tamanho de lote e número de épocas) e testar outras arquiteturas, com diferentes técnicas e/ou algoritmos, tais como ResNet50 e VGG19 (algoritmos de CNN), SURF (*Speeded--Up Robust Features*) e RANSAC (*Random Sample Consensus*).[30-35,46-47]

5.2.1. Aplicação ao Contexto Médico-Legal

Num contexto médico-legal, o modelo de identificação positiva demonstrou um desempenho notável na classificação de pares de OPG de indivíduos distintos. Para pares de OPG pertencentes a um único indivíduo, porém, o modelo demonstrou um desempenho inferior.

Em situações de DVI, o principal objetivo das equipas de atuação é a identificação médico-legal dos cadáveres encontrados. Considerando que o número de vítimas mortais de desastres em massa é habitualmente elevado, surge a necessidade de otimizar os recursos disponíveis para identificação médico-legal, garantindo tanto a rapidez e precisão do processo

como a proteção da dignidade e respeito pela vítima. Apesar dos resultados obtidos neste estudo na classificação de pares de OPG de um mesmo indivíduo, o modelo de identificação positiva constitui uma ferramenta com grande utilidade em contexto DVI, pela sua elevada capacidade em determinar que duas OPG (AM e PM) não pertencem a um mesmo indivíduo – o que contribui amplamente para a exclusão de possíveis identidades de um cadáver. Esta etapa de exclusão de possíveis combinações de OPG é crucial para uma triagem de vítimas mortais mais rápida, representado um avanço significativo no processo de identificação médico-legal.[21]

Outras investigações desenvolvidas no âmbito médico-legal procuraram, tal como o presente estudo, identificar indivíduos através da comparação de evidências dentárias em diferentes OPG, com recurso a AI. No estudo de Kim et al. (2022), uma amostra de 2.760 OPG pertencentes a 746 indivíduos foi analisada com uma versão modificada pelos autores do modelo pré-treinado VGG16 para *feature extraction*, que gerou uma pontuação de confiança para cada indivíduo, sendo alcançada uma acurácia final de, aproximadamente, 83%.[48] Chen et al. (2022), por sua vez, propuseram um modelo de CNN com dois ramos, um responsável por extração de características da OPG original e outro por extração do contorno dos dentes, com posterior fusão destas informações. O estudo contemplou uma amostra de 23.715 OPG de 10.113 indivíduos e atingiu uma acurácia final de 89%.[49]

A literatura apresenta ainda dois estudos desenvolvidos com os algoritmos SURF e RANSAC, utilizados para identificar pontos correspondentes entre OPG AM e PM e remover *outliers*: Heinrich et al. (2018), que contemplou 43.467 OPG pertencentes a 24.545 indivíduos, alcançando após o teste com 40 indivíduos (selecionados aleatoriamente) uma acurácia final de 85%[50]; Heinrich et al. (2020) incluiu no seu estudo uma amostra com 61.545 OPG de 33.206 indivíduos, apresentando um desempenho perfeito com acurácia final de 100% no teste, onde contou com 43 indivíduos.[51]

É possível, assim, concluir que o modelo desenvolvido apresentou um desempenho elevado, semelhante aos estudos supramencionados – à exceção de Heinrich et al. (2020). A comparação deste modelo com outras arquiteturas abordadas na literatura reforça a importância de testar novas arquiteturas e hiperparâmetros, de modo a obter o melhor desempenho possível.

Mais especificamente, a escolha do modelo VGG16 constituiu uma limitação para este estudo, uma vez que este modelo foi pré-treinado com imagens genéricas a cores, não sendo indicado para o processamento de OPG e outras imagens médicas como é, por exemplo, a MONAI (*Medical Open Network for Artificial Intelligence)* – biblioteca de código aberto

dedicada ao desenvolvimento de modelos de AI na área da saúde, inclusive para classificação de imagens médicas, amplamente utilizada por médicos e médicos dentistas maioritariamente para diagnóstico imagiológico.[52]

É importante denotar ainda que a utilização de AI em contexto de perícias médico-legais requer o cumprimento obrigatório de normas éticas e legais estabelecidas pela Convenção Europeia dos Direitos Humanos e pela Convenção 108+ para a Proteção das Pessoas relativamente ao Tratamento Automatizado de Dados Pessoais, assim como o respeito pelos princípios definidos pela Comissão Europeia para a Eficácia da Justiça, presentes na Carta Ética Europeia sobre a Utilização da Inteligência Artificial nos Sistemas Judiciários e no seu Ambiente, sendo estes: princípio do respeito pelos direitos fundamentais; princípio da não-discriminação; princípio da qualidade e segurança; princípio da transparência, imparcialidade e equidade; princípio "sob controlo do utilizador". O recurso a AI em contexto médico-legal deverá ter igualmente em consideração as normas definidas pela *American Dental Association* (2020) e pelo Regulamento (UE) 2024/1689, que caracteriza a AI como uma tecnologia de alto risco. É ainda enfatizada a pertinência em proteger a integridade das perícias médico-legais e os direitos humanos através da obrigação de informar as partes envolvidas sobre o uso de AI na perícia, possibilitando a sua contestação e solicitação de intervenção humana.[22,53-56]

6. CONCLUSÕES

6.1. Conclusões relativas aos Objetivos Primários

Com base nos resultados obtidos e tendo em conta as diversas hipóteses experimentais formuladas, é possível retirar as seguintes conclusões:

- **Classificação de Idade:** o algoritmo desenvolvido permite classificar a idade tanto de indivíduos com idade compreendida entre os 16 e 23 anos como de indivíduos com idade entre os 24 e 30 anos, através das evidências dentárias presentes em OPG.
- **Identificação Positiva:** o algoritmo desenvolvido permite identificar positivamente indivíduos com idades entre os 16 e os 30 anos, através da comparação de evidências dentárias de diferentes OPG.

6.2. Conclusões relativas ao Objetivo Final

Com base nos resultados obtidos, é possível concluir que o presente estudo confirmou a hipótese experimental nula formulada no objetivo final. Isto significa que o algoritmo de identificação positiva desenvolvido permite a identificação médico-legal de cadáveres desconhecidos, com idades compreendidas entre os 16 e os 30 anos, por comparação de evidências dentárias AM e PM presentes em OPG.

Uma vez que o modelo de identificação positiva desenvolvido apresentou um elevado desempenho na comparação AM e PM de evidências dentárias em OPG, com acurácia final de 85%, conclui-se ainda que este constitui uma ferramenta útil para a identificação médico-legal de cadáveres desconhecidos nomeadamente em situações de DVI. Porém, é recomendado o teste de novas arquiteturas e algoritmos e a otimização de hiperparâmetros, de modo a alcançar o melhor desempenho possível para identificação médico-legal com recurso a AI.

REFERÊNCIAS BIBLIOGRÁFICAS

1. Vodanović M, Subašić M, Milošević DP, Galić I, Brkić H. Artificial intelligence in forensic medicine and forensic dentistry. J Forensic Odontostomatol. 2023 Aug 27;41(2):30-41.

2. Mohammad N, Ahmad R, Kurniawan A, Mohd Yusof MYP. Applications of contemporary artificial intelligence technology in forensic odontology as primary forensic identifier: A scoping review. Front Artif Intell. 2022 Dec 6;5:1049584. doi:10.3389/frai.2022.1049584.

3. Traore BB, Kamsu-Foguem B, Tangara F. Deep convolution neural network for image recognition. Ecol Inform. 2018;48:257-268. ISSN 1574-9541. doi:10.1016/j.ecoinf.2018.10.002.

4. Ossowska A, Kusiak A, Świetlik D. Artificial Intelligence in Dentistry-Narrative Review. Int J Environ Res Public Health. 2022 Mar 15;19(6):3449. doi: 10.3390/ijerph19063449.

5. Khanagar SB, Vishwanathaiah S, Naik S, A Al-Kheraif A, Devang Divakar D, Sarode SC, Bhandi S, Patil S. Application and performance of artificial intelligence technology in forensic odontology - A systematic review. Leg Med (Tokyo). 2021 Feb;48:101826. doi: 10.1016/j.legalmed.2020.101826.

6. Anwar SM, Majid M, Qayyum A, et al. Medical Image Analysis using Convolutional Neural Networks: A Review. J Med Syst. 2018;42:226. doi:10.1007/s10916-018-1088-1.

7. Li Q, Cai W, Wang X, Zhou Y, Feng DD, Chen M. Medical image classification with convolutional neural network. In: Proceedings of the 2014 13th International Conference on Control Automation Robotics & Vision (ICARCV); 2014 Nov 10-12; Singapore. p. 844-848. doi:10.1109/ICARCV.2014.7064414.

8. Thurzo A, Kosnáčová HS, Kurilová V, Kosmeľ S, Beňuš R, Moravanský N, Kováč P, Kuracinová KM, Palkovič M, Varga I. Use of Advanced Artificial Intelligence in Forensic Medicine, Forensic Anthropology and Clinical Anatomy. Healthcare (Basel). 2021 Nov 12;9(11):1545. doi: 10.3390/healthcare9111545.

9. Sharma N, Jain V, Mishra A. An Analysis Of Convolutional Neural Networks For Image Classification. Procedia Comput Sci. 2018;132:377-384. ISSN 1877-0509. doi:10.1016/j.procs.2018.05.198.

10. Sun Y, Xue B, Zhang M, Yen GG. Evolving Deep Convolutional Neural Networks for Image Classification. IEEE Trans Evol Comput. 2020 Apr;24(2):394-407. doi:10.1109/TEVC.2019.2916183.

11. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, Sveshnikov MM, Bednenko GB. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. Dentomaxillofac Radiol. 2019 May;48(4):20180051. doi: 10.1259/dmfr.20180051.

12. Mohammed F, Fairozekhan AT, Bhat S, Menezes RG. Forensic Odontology. 2023 Aug 14. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2023 Jan.

13. Yazdanian M, Karami S, Tahmasebi E, Alam M, Abbasi K, Rahbar M, Tebyaniyan H, Ranjbar R, Seifalian A, Yazdanian A. Dental Radiographic/Digital Radiography Technology along with Biological Agents in Human Identification. Scanning. 2022 Jan 18;2022:5265912. doi: 10.1155/2022/5265912.

14. Thurzo A, Jančovičová V, Hain M, Thurzo M, Novák B, Kosnáčová H, Lehotská V, Varga I, Kováč P, Moravanský N. Human Remains Identification Using Micro-CT, Chemometric and AI Methods in Forensic Experimental Reconstruction of Dental Patterns after Concentrated Sulphuric Acid Significant Impact. Molecules. 2022 Jun 23;27(13):4035. doi: 10.3390/molecules27134035.

15. Jayakrishnan JM, Reddy J, Vinod Kumar RB. Role of forensic odontology and anthropology in the identification of human remains. J Oral Maxillofac Pathol. 2021 Sep-Dec;25(3):543-547. doi: 10.4103/jomfp.jomfp_81_21.

16. Prajapati G, Sarode SC, Sarode GS, Shelke P, Awan KH, Patil S. Role of forensic odontology in the identification of victims of major mass disasters across the world: A systematic review. PLoS One. 2018 Jun 28;13(6):e0199791. doi: 10.1371/journal.pone.0199791.

17. Corte Real F, Santos A, Cunha E, Cainé L. Tratado de Medicina Legal. Lisboa: Pactor; 2022.

18. Lei n.º 45/2004, Diário da República Série I-A, n.º 195 (Ago. 19, 2004). Com as alterações introduzidas pelo Decreto-Lei n.º 53/2021.

19. Otero P. Personalidade e Identidade Pessoal e Genética do Ser Humano: Um perfil constitucional da Bioética. Coimbra: Almedina; 1999. p. 65.

20. INTERPOL. Disaster Victim Identification Guide [Internet]. 2023 [citado a 2024 Set 4]. 110 p. Disponível em: https://www.interpol.int/How-we-work/Forensics/Disaster-Victim-Identification-DVI

21. Black S, Ferguson E, editores. Forensic Anthropology: 2000 to 2010. 1ª ed. Boca Raton (FL): CRC Press; 2011.

22. Regulamento (UE) 2024/1689 do Parlamento Europeu e do Conselho, de 13 de junho de 2024.

23. CEIC - Comissão de Ética para a Investigação Clínica. Documento CEIC sobre o Regulamento Geral de Proteção de Dados (RGPD) no contexto da Investigação Clínica. 2018;1–14.

24. Shaveta. A review on machine learning. International Journal of Science and Research Archive. 2023. Disponível em: https://api.semanticscholar.org/CorpusID:259050490.

25. Sen PC, Hajra M, Ghosh M. Supervised classification algorithms in machine learning: a survey and review. Advances in Intelligent Systems and Computing. 2019. doi: 10.1007/978-981-13-7403-6_11.

26. Katyayan S, Singh I. Using supervised learning to estimate the acceptance of research papers by conferences. 2022 IEEE Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI); 2022. p. 1-6. doi: 10.1109/IATMSI56455.2022.10119439.

27. Kim HE, Cosa-Linan A, Santhanam N, Jannesari M, Maros ME, Ganslandt T. Transfer learning for medical image classification: a literature review. BMC Med Imaging. 2022 Apr 13;22(1):69. doi: 10.1186/s12880-022-00793-7.

28. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, van der Laak JAWM, van Ginneken B, Sánchez CI. A survey on deep learning in medical image analysis. Med Image Anal. 2017 Dec;42:60-88. doi: 10.1016/j.media.2017.07.005.

29. Wang J, Lin J, Wang Z. Efficient hardware architectures for deep convolutional neural network. IEEE Trans Circuits Syst I Regul Pap. 2018;65(6):1941-1953. doi: 10.1109/TCSI.2017.2767204.

30. Mascarenhas S, Agarwal M. A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for image classification. In: 2021 International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications (CENTCON); 2021. p. 96-99. doi: 10.1109/CENTCON52345.2021.9687944.

31. Raiaan MA, Sakib S, Fahad NM, Mamun AA, Rahman MA, Shatabda S, Mukta MSH. A systematic review of hyperparameter optimization techniques in convolutional neural networks. Decision Analytics Journal. 2024;11:100470. doi: 10.1016/j.dajour.2024.100470.

32. Ying X. An overview of overfitting and its solutions. J Phys Conf Ser. 2019;1168:022022. doi: 10.1088/1742-6596/1168/2/022022.

33. Mutasa S, Sun S, Ha R. Understanding artificial intelligence based radiology studies: What is overfitting? Clin Imaging. 2020 Sep;65:96-99. doi: 10.1016/j.clinimag.2020.04.025. Epub 2020 Apr 23.

34. Maharana K, Mondal S, Nemade B. A review: data pre-processing and data augmentation techniques. Glob Transit Proc. 2022;3(1):91-99. doi: 10.1016/j.gltp.2022.04.020.

35. Xu Y, Goodacre R. On splitting training and validation set: a comparative study of cross-validation, bootstrap and systematic sampling for estimating the generalization performance of supervised learning. J Anal Test. 2018;2:249-262. doi: 10.1007/s41664-018-0068-2.

36. Tian Y, Zhao X, Huang W. Meta-learning approaches for learning-to-learn in deep learning: a survey. Neurocomputing. 2022;494:203-223. doi: 10.1016/j.neucom.2022.04.078.

37. Kotsiantis S, Kanellopoulos D, Pintelas P. Data preprocessing for supervised learning. Int J Comput Sci. 2006;1:111-117.

38. Shaziya H, Zaheer R. Impact of hyperparameters on model development in deep learning. In: Proceedings of International Conference on Computational Intelligence and Data Engineering. 2021. p. 57-67. doi: 10.1007/978-981-15-8767-2_5.

39. Nazir S, Patel S, Patel D. Model optimisation techniques for convolutional neural networks. In: Handbook of Research on New Investigations in Artificial Life, AI, and Machine Learning. 2022. p. 269-298. doi: 10.4018/978-1-7998-8686-0.ch011.

40. Deepak S, Ameer PM. Brain tumor classification using deep CNN features via transfer learning. Comput Biol Med. 2019 Aug;111:103345. doi: 10.1016/j.compbiomed.2019.103345.

41. Erickson BJ, Kitamura F. Magician's Corner: 9. Performance Metrics for Machine Learning Models. Radiol Artif Intell. 2021 May 12;3(3):e200126. doi: 10.1148/ryai.2021200126.

42. Obi JC. A comparative study of several classification metrics and their performances on data. World J Adv Eng Technol Sci. 2023;8(1):308-314. doi: 10.30574/wjaets.2023.8.1.0054.

43. Huff DT, Weisman AJ, Jeraj R. Interpretation and visualization techniques for deep learning models in medical imaging. Phys Med Biol. 2021 Feb 2;66(4):04TR01. doi: 10.1088/1361-6560/abcd17.

44. Xiao M, Zhang L, Shi W, Liu J, He W, Jiang Z. A visualization method based on the Grad-CAM for medical image segmentation model. In: 2021 International Conference on Electronic Information Engineering and Computer Science (EIECS); 2021. p. 242-247. doi: 10.1109/EIECS53707.2021.9587953.

45. Mohammad N, Ahmad R, Gaus MHA, Kurniawan A, Yusof MYPM. Accuracy of automated forensic dental age estimation lab (F-DentEst Lab) on large Malaysian dataset. Forensic Sci Int. 2024 Aug;361:112150. doi: 10.1016/j.forsciint.2024.112150.

46. Bay H, Ess A, Tuytelaars T, Van Gool L. Speeded-up robust features (SURF). Comput Vis Image Underst. 2008 Mar;110(3):346-59. doi: 10.1016/j.cviu.2007.09.014.

47. Fischler MA, Bolles RC. Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. In: Fischler MA, Firschein O, editors. Readings in computer vision. San Francisco (CA): Morgan Kaufmann; 1987. p. 726-40. doi: 10.1016/B978-0-08-051581-6.50070-2.

48. Kim YH, Ha EG, Jeon KJ, Lee C, Han SS. A fully automated method of human identification based on dental panoramic radiographs using a convolutional neural network. Dentomaxillofac Radiol. 2022 May 1;51(4):20210383. doi: 10.1259/dmfr.20210383. Epub 2021 Dec 2.

49. Chen H, Sun C, Liao P, Lai Y, Fan F, Lin Y, Deng Z, Zhang Y. A fine-grained network for human identification using panoramic dental images. Patterns (N Y). 2022 Apr 1;3(5):100485. doi: 10.1016/j.patter.2022.100485.

50. Heinrich A, Güttler F, Wendt S, Schenkl S, Hubig M, Wagner R, Mall G, Teichgräber U. Forensic Odontology: Automatic Identification of Persons Comparing Antemortem and Postmortem Panoramic Radiographs Using Computer Vision. Rofo. 2018 Dec;190(12):1152-1158. English. doi: 10.1055/a-0632-4744.

51. Heinrich A, Güttler FV, Schenkl S, Wagner R, Teichgräber UK. Automatic human identification based on dental X-ray radiographs using computer vision. Sci Rep. 2020 Mar 2;10(1):3801. doi: 10.1038/s41598-020-60817-6.

52. MONAI Consortium. MONAI: Medical Open Network for AI [Internet]. Disponível em: https://monai.io

53. Conselho da Europa. Convenção Europeia dos Direitos Humanos, conforme alterada pelos Protocolos n.ºs 11, 14 e 15, complementada pelos Protocolos n.ºs 1, 4, 6, 7, 12, 13 e 16. Estrasburgo: Conselho da Europa; 2021.

54. Conselho da Europa. Convenção 108+ para a proteção das pessoas no que diz respeito ao tratamento de dados pessoais. Estrasburgo: Conselho da Europa; 2018.

55. Conselho da Europa. Comissão Europeia para a Eficácia da Justiça (CEPEJ): Carta Ética Europeia sobre a Utilização da Inteligência Artificial nos Sistemas Judiciários e no seu Ambiente. Estrasburgo: Conselho da Europa; 2019.

56. American Dental Association (ADA). Overview of Artificial and Augmented Intelligence Uses in Dentistry. SCDI White Paper No. 1106. Chicago, IL: American Dental Association; 2022.

ANEXOS

Anexo 1 – Cartas de Pedido de Autorização

I – Carta para o Presidente da Comissão de Ética do CAML

II – Questionário de Comissão de Ética do CAML

III – Autorização do Diretor do Serviço de Estomatologia da ULS Santa Maria

IV– Parecer Favorável da Comissão de Ética do CAML

Anexo 2 – Bases de Dados para Análise Estatística

I – Abreviaturas e Códigos de Registo do estudo

II – Caderno de Recolha de Dados de *Microsoft Excel*®

III – Editor de *IBM SPSS*® *Statistics* 29

Anexo 3 – Análise Estatística Descritiva

I – Distribuição da Amostra por Sexo

II – Distribuição da Amostra por Sexo e Intervalo de Idades

Anexo 4 – *Heatmaps* de Classificação de Idade

I – *Heatmaps* de OPG da classe "16_23" classificadas como "16_23"

II – *Heatmaps* de OPG da classe "16_23" classificadas como "24_30"

III – *Heatmaps* de OPG da classe "24_30" classificadas como "24_30

IV – *Heatmaps* de OPG da classe "24_30" classificadas como "16_23"

Anexo 5 – *Heatmaps* de Identificação Positiva

I – *Heatmaps* de OPG da classe "*Same*" classificadas como "*Same*"

II – *Heatmaps* de OPG da classe "*Same*" classificadas como "*Different*"

III – *Heatmaps* de OPG da classe "*Different*" classificadas como "*Different*"

IV – *Heatmaps* de OPG da classe "*Different*" classificadas como "*Same*"

Anexo 6 – Trabalhos Científicos desenvolvidos na FMDUL entre 2020 e 2024

I – Publicações Científicas

II – Apresentações Científicas

Anexo 1 – Cartas de Pedido de Autorização

I – Carta para o Presidente da Comissão de Ética do CAML

II – Questionário de Comissão de Ética do CAML

III – Autorização do Diretor do Serviço de Estomatologia da ULS Santa Maria

IV – Parecer Favorável da Comissão de Ética do CAML

Anexo 1, I – Carta para o Presidente da Comissão de Ética do CAML

Exmo. Senhor

Professor Doutor João Forjaz Lacerda

Presidente da Comissão de Ética do CAML

Lisboa, 12 de outubro de 2023

Assunto: Projeto **"Desenvolvimento de um Algoritmo baseado em Inteligência Artificial para Identificação de Cadáveres por Evidências Dentárias"**

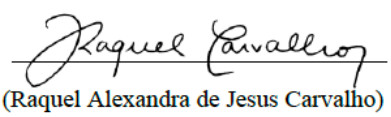
Venho por este meio submeter à apreciação da Comissão de Ética para a Saúde o estudo acima identificado a realizar no âmbito do Mestrado Integrado em Medicina Dentária.

É um estudo observacional retrospetivo, que irá decorrer no *Serviço de Estomatologia do Hospital de Santa Maria do CHLN* e tem como objetivo desenvolver um algoritmo, obtido através da aplicação de redes neurais convolucionais (CNN) em radiografias panorâmicas, para comparação de evidências dentárias de modo a estabelecer a identificação em cadáveres desconhecidos.

Com os melhores cumprimentos,

Pel'O Investigador Principal

Estudante do Mestrado Integrado em Medicina Dentária



(Raquel Alexandra de Jesus Carvalho)

Anexo 1, II – Questionário de Comissão de Ética do CAML

CENTRO ACADÉMICO DE MEDICINA DE LISBOA | CENTRO HOSPITALAR LISBOA NORTE, EPE | HOSPITAL DE SANTA MARIA | Hospital Pulido Valente | LISBOA UNIVERSIDADE DE LISBOA | FACULDADE DE MEDICINA LISBOA | MM Instituto de Medicina Molecular João Lobo Antunes

COMISSÃO DE ÉTICA

ESTUDOS NÃO ENVOLVENDO EXPERIMENTAÇÃO HUMANA (OBSERVACIONAL, INQUÉRITOS)

1. IDENTIFICAÇÃO DO PROJECTO

a) Título do projecto (do estudo, investigação, etc.)

Desenvolvimento de um Algoritmo baseado em Inteligência Artificial para Identificação de Cadáveres por Evidências Dentárias

a) Autores / Promotor

a. Promotor (Indivíduo ou entidade responsável pela execução do estudo)

Professora Doutora Cristiana Maria Palmela Pereira

b. Investigador Principal (juntar resumo CV)

Raquel Alexandra de Jesus Carvalho

c. Colaboradores (juntar resumo CV)

Professor Doutor Rui Filipe Vargas de Sousa Santos
Professor Doutor Francisco Salvado e Silva
Dr. Francisco Azevedo Coutinho
Dr.ª Diana Isabel Marques Augusto

d. Há algum Investigador/Colaborador pertencente ao Centro Hospitalar Lisboa Norte, E.P.E.?

Professor Doutor Francisco Salvado e Silva
Dr. Francisco Azevedo Coutinho

c) Natureza do estudo:

Inquérito isolado		Estudo Observacional	X	Estudo retrospectivo com colheita de dados pessoais	
Inquéritos seriados		Outro			

COMISSÃO DE ÉTICA DO CHLN E DO CAML

Avenida Professor Egas Moniz
1649-035 LISBOA
Tel. - 21 780 54 05; Fax - 21 780 56 90
ana.pimentel@chln.min-saude.pt

Alameda das Linhas de Torres, 117
1769-001 LISBOA
Tel: 217 548 000 - Fax: 217 548 215
www.chln.pt

Qual?

Estudo Observacional Retrospetivo

d) **Local onde decorre o estudo** (Departamento, Instituto, Laboratório, etc):

Serviço de Estomatologia do Hospital de Santa Maria do Centro Hospitalar Lisboa Norte

e) **Existem outros centros, onde a mesma investigação será feita?**

Sim, Nacionais ☐ Sim, Internacionais ☐ Outro ☐

Em caso afirmativo indique-os

Descreva sucintamente o (s) objectivo (s) da investigação:

O presente estudo observacional retrospetivo tem como objetivo o desenvolvimento de um algoritmo, obtido através da aplicação de redes neurais convolucionais (CNN) em radiografias panorâmicas, para comparação de evidências dentárias de modo a estabelecer a identificação em cadáveres desconhecidos.

Avenida Professor Egas Moniz
1649-035 LISBOA
Tel. - 21 780 54 05; Fax - 21 780 56 90
ana.pimentel@chln.min-saude.pt

Alameda das Linhas de Torres, 117
1769-001 LISBOA
Tel: 217 548 000 - Fax: 217 548 215
www.chln.pt

f) **Encargos e situações especiais** (se a investigação proposta envolve):

i) Envolvimento de pessoal administrativo - indique o tipo, frequência e duração prevista. Especifique se o tempo ocupado com a sua colaboração se destina especialmente para esta investigação ou se seria executado no âmbito dos cuidados assistenciais habituais a prestar ao doente.

O presente estudo não envolve pessoal administrativo.

ii) Consultas / entrevistas de seguimento – Especifique se as consultas são feitas especialmente para esta investigação ou se seriam executadas no âmbito dos cuidados médicos habituais a prestar ao doente.

Especifique se os entrevistadores estão obrigados ao segredo médico ou - em alternativa - se assinaram um acordo de confidencialidade com a Instituição.

O presente estudo não envolve consultas/entrevistas de seguimento.

g) **Caderno de recolha de dados** (CRF):

i) Como serão recolhidos os dados? (Nota: junte um exemplar do caderno de recolha de dados)

Os dados serão recolhidos pelo investigador principal e serão introduzidos num caderno de recolha de dados, em formato Excel, que se encontra em anexo.

ii)

O caderno de recolha de dados dividir-se-á em 3 folhas de Excel. Na primeira folha constará o número de processo do paciente, ao qual será atribuído um número aleatório – designado por número de projeto. Esta folha não tem como função identificar o paciente, pelo que se procederá à sua posterior eliminação de modo a preservar a confidencialidade dos dados recolhidos. Na segunda folha constará o número de projeto associado ao sexo, data de nascimento e nacionalidade do paciente. Por fim, na terceira folha, o número de projeto encontrar-se-á associado aos restantes dados recolhidos, sendo estes a data de realização da radiografia panorâmica e a idade do paciente nesse respetivo momento.

COMISSÃO DE ÉTICA DO CHLN E DO CAML
Avenida Professor Egas Moniz
1649-035 LISBOA
Tel. - 21 780 54 05; Fax - 21 780 56 90
ana.pimentel@chln.min-saude.pt
Alameda das Linhas de Torres, 117
1769-001 LISBOA
Tel: 217 548 000 - Fax: 217 548 215
www.chln.pt

h) **Comentários adicionais** (por favor indicar a alínea a que se referem)

2. JUSTIFICAÇÃO CIENTÍFICA DA INVESTIGAÇÃO

Descreva sucintamente os fundamentos científicos da investigação. Indique em particular:

- Se a investigação já foi feita anteriormente com seres humanos, qual o motivo que justifica a sua repetição; no caso de a investigação nunca ter sido realizada em seres humanos, se o problema foi devidamente estudado a nível experimental em animais de modo a optimizar os aspectos analíticos e técnicos e avaliar os possíveis danos.

O presente estudo é observacional e retrospetivo, pelo que não será feita qualquer intervenção em seres humanos.

3. SUJEITOS

Número de indivíduos previstos incluir: 1020

Critérios inclusão/exclusão :

COMISSÃO DE ÉTICA DO CHLN E DO CAML

Avenida Professor Egas Moniz
1649-035 LISBOA
Tel. - 21 780 54 05; Fax - 21 780 56 90
ana.pimentel@chln.min-saude.pt

Alameda das Linhas de Torres, 117
1769-001 LISBOA
Tel: 217 548 000 - Fax: 217 548 215
www.chln.pt

As mulheres grávidas são excluídas?	Sim		Não	X
As crianças são excluídas?	Sim		Não	X

Os doentes com perturbações psíquicas são excluídos?	Sim		Não	X
Os indivíduos com compreensão comprometida são excluídos?	Sim		Não	X

4. DESCRIÇÃO RESUMIDA DO PLANO DA INVESTIGAÇÃO

Data prevista do início: Outubro de 2023

Data prevista da conclusão: Setembro de 2024

5. RISCO / BENEFÍCIO

a) **Potenciais benefícios para o doente pela participação no estudo**

Não aplicável.

Avenida Professor Egas Moniz
1649-035 LISBOA
Tel. - 21 780 54 05; Fax - 21 780 56 90
ana.pimentel@chln.min-saude.pt

Alameda das Linhas de Torres, 117
1769-001 LISBOA
Tel: 217 548 000 - Fax: 217 548 215
www.chln.pt

b) **Precauções que julga dever serem observadas na realização do estudo**

Assegurar a confidencialidade dos dados, do modo descrito no ponto 1- g) ii).

c) **Questões previsíveis**

Não aplicável.

d) **Considera que os meios utilizados no estudo podem violar a privacidade do doente?**

Sim [ ] Não [X]

Em caso afirmativo, indique que medidas serão tomadas para assegurar a confidencialidade

e) **Pagamento aos doentes**

Pelas deslocações	Sim	[ ]	Não	[X]
Pelas faltas ao serviço	Sim	[ ]	Não	[X]
Por danos resultantes da sua participação no estudo	Sim	[ ]	Não	[X]

COMISSÃO DE ÉTICA DO CHLN E DO CAML
Avenida Professor Egas Moniz
1649-035 LISBOA
Tel. - 21 780 54 05; Fax - 21 780 56 90
ana.pimentel@chln.min-saude.pt
Alameda das Linhas de Torres, 117
1769-001 LISBOA
Tel: 217 548 000 - Fax: 217 548 215
www.chln.pt

6. CONSENTIMENTO ESCLARECIDO (Junte cópia)

a) A investigação ou estudo envolve:

- Menores Sim [ ] Não [X]
- Incapazes Sim [ ] Não [X]

Em caso afirmativo, juntar folha de consentimento para os representantes legais.
Caso o menor disponha de capacidade de entendimento e manifestação de vontade é necessário também o seu consentimento (recomendável a partir dos 7 anos, obrigatório a partir dos 16 anos).

7. BENEFÍCIOS PARA O INVESTIGADOR / INSTITUIÇÃO

a) Que tipo de benefícios resultarão do estudo, para o investigador e/ou instituição?

Especifique

- Desenvolvimento de uma nova técnica de identificação humana através da comparação de radiografias panorâmicas *ante-mortem* e *post-mortem*, baseada em Inteligência Artificial com elevada eficiência na análise de imagens médicas radiológicas.

- Expansão da utilização de Inteligência Artificial na Medicina Dentária Forense, de modo a desenvolver novas técnicas de identificação humana que funcionem como ferramentas de auxílio para os profissionais da área.

- Promoção de melhores resultados em investigações médico-legais por aplicação de método de Inteligência Artificial que proporciona um processo de identificação humana mais rápido e exato.

Se apropriado junte cópia do acordo financeiro.

b) **Os dados obtidos constituirão propriedade exclusiva do promotor?** Sim [ ] Não [X]

Avenida Professor Egas Moniz
1649-035 LISBOA
Tel. - 21 780 54 05; Fax - 21 780 56 90
ana.pimentel@chln.min-saude.pt

Alameda das Linhas de Torres, 117
1769-001 LISBOA
Tel: 217 548 000 - Fax: 217 548 215
www.chln.pt

Se não, que outras entidades têm acesso aos dados

Investigador e colaboradores.

c) A publicação dos resultados do estudo será da exclusiva responsabilidade do promotor?

Sim [ ] Não [X]

8. TERMO DE RESPONSABILIDADE

Data do pedido de submissão (DD / MM / AAAA): 12 / 10 / 2023

Eu abaixo assinado, na qualidade de investigador principal, declaro por minha honra que as informações prestadas neste questionário são verdadeiras. Mais declaro que, durante o estudo, serão respeitadas as recomendações constantes das Declarações de Helsínquia a de Tóquio, da Organização Mundial de Saúde e da Comunidade Europeia, respeitando os imperativos refletidos no Regulamento Geral de Proteção de Dados (RGPD) entrado em vigor em 25 de Maio de 2018, por força do disposto no novo regulamento de proteção dos dados pessoais (Regulamento (UE) 2016/679 do Parlamento Europeu e do Conselho de 27/04/16), publicado no dia 4 de Maio de 2016, no que se refere à experimentação que envolva seres humanos, bem como o constante na Lei Nº 21/14 de 16 de Abril, DR Iª Série.

Lisboa, 12 de outubro de 2023

Raquel Cavalheiro

Avenida Professor Egas Moniz
1649-035 LISBOA
Tel. - 21 780 54 05; Fax - 21 780 56 90
ana.pimentel@chln.min-saude.pt

Alameda das Linhas de Torres, 117
1769-001 LISBOA
Tel: 217 548 000 - Fax: 217 548 215
www.chln.pt

Anexo 1, III – Autorização do Diretor do Serviço de Estomatologia da ULS Santa Maria

CENTRO HOSPITALAR LISBOA NORTE, EPE

HOSPITAL DE SANTA MARIA

Hospital Pulido Valente

AUTORIZAÇÃO DO DIRECTOR DE SERVIÇO

Título da Tese

Desenvolvimento de um Algoritmo baseado em Inteligência Artificial para Identificação de Cadáveres por Evidências Dentárias

Protocolo

Promotor: Professora Doutora Cristiana Palmela Pereira

O Serviço de Estomatologia deste hospital possui as infra-estruturas e os equipamentos necessários à realização deste estudo observacional e a equipa deste serviço apresenta a competência técnica necessária para a realização deste estudo em cumprimento com as Boas Práticas Clínicas.

Confirmo que o Investigador Principal (Raquel Alexandra de Jesus Carvalho) deste estudo tem conhecimento das Boas Práticas Clínicas.

O Serviço dispõe de capacidade de arquivo e armazenamento de toda a documentação relativa à realização do estudo.

A monitorização será realizada em espaço adequado à verificação dos dados do ensaio, nomeadamente em salas de reunião deste serviço, sob supervisão dos investigadores e/ou pessoal do centro delegado pelo Investigador Principal para o efeito.

Perante o que ficou exposto, e na qualidade de Director do Serviço de Estomatologia do Centro Hospitalar Universitário de Lisboa Norte, E.P.E. – Hospital de Santa Maria, venho afirmar que autorizo a realização do referido estudo observacional.

Ressalvo, no entanto, que a minha autorização está condicionada à autorização / parecer exigidos, respetivamente da Direção Clínica do Centro Hospitalar Universitário de Lisboa Norte, E.P.E. – Hospital de Santa Maria, e da Comissão de Ética do CHULN e do Centro Académico de Medicina de Lisboa – CAML

Lisboa, 18 de outubro de 2023

Francisco Salvado e Silva
n.º mec. [illegible]
Director do Serviço de Estomatologia

Prof. Doutor Francisco Salvado e Silva

Director do Serviço de Estomatologia do Centro Hospitalar Universitário de Lisboa Norte, E.P.E. – Hospital de Santa Maria

1/1

Anexo 1, IV– Parecer Favorável da Comissão de Ética do CAML

REPÚBLICA PORTUGUESA SAÚDE | SNS SERVIÇO NACIONAL DE SAÚDE | UNIDADE LOCAL DE SAÚDE SANTA MARIA

UNIDADE LOCAL DE SAÚDE SANTA MARIA | CAML CENTRO ACADÉMICO DE MEDICINA DE LISBOA

+Presidente
Prof. Doutor João Forjaz de Lacerda

Vice-Presidente
Profª. Doutora Ana Isabel Lopes

Membros
Doutora Carla Fonseca
Profª. Doutora Claudia Sofia Oliveira Dias Monge
Prof. Doutor Daniel Caldeira
Profª Doutora Cláudia Faria
Mestre Enfermeira. Graça Roldão
Prof. Doutor João Lavinha
Profª. Doutora Maria do Céu Patrão Neves
Profª. Doutora Patrícia Canhão

Exma. Senhora

Dra. Raquel Alexandra de Jesus Carvalho

Lisboa, 20 de Maio de 2024

Nossa Refª. Nº 271/23

Assunto: Estudo **"Desenvolvimento de um Algoritmo baseado em Inteligência Artificial para Identificação de Cadáveres por Evidências Dentárias"**

Pela presente se informa que o projeto citado em epígrafe obteve, em Maio de 2024, **parecer favorável da Comissão de Ética**, considerando-se observados os imperativos que fundeiam as Boas práticas clínicas, os preceitos internacionalmente reconhecidos de qualidade ética e científica que devem ser respeitados na conceção e na realização dos estudos clínicos que envolvam a participação de seres humanos.

No uso das competências próprias constantes do disposto no Decreto-Lei. N.º 97/95 de 10 de Maio, e no exercício das suas funções em observância ao deliberado na Lei n.º 21/2014 de 16 de Abril, que aprova a lei da investigação clínica, na sua atual redação alterada pela Lei n.º 73/2015 de 27/07/15, complementada pelo Decreto-Lei n.º 80/2018 (DR n.º 198-2018, Série I de 2018/10/15) que reforça o papel das comissões de ética no contexto da instituição em que se integram, na sua missão de contribuir para o cumprimento de princípios da ética e da bioética, na prestação de cuidados de saúde e na realização de investigação clínica, e ainda em harmonia com os regulamentos internos do CHULN, os códigos deontológicos, as convenções, e as recomendações constantes das declarações e diretrizes internacionais, designadamente as Declarações de Helsínquia a de Tóquio, da Organização Mundial de Saúde e da União Europeia, a Comissão de Ética avaliou o estudo que considera obedecerem aos requisitos éticos fundamentais que devem ser respeitados, refletindo o primado da dignidade e da integridade humanas.

Encontra-se assegurado o direito à integridade moral e física do participante, cumpre as precauções essenciais, cujo desígnio visa minimizar eventuais danos para os seus direitos de personalidade, bem como o direito à privacidade e à proteção dos dados pessoais que lhe dizem respeito, respeitando os imperativos refletidos no Regulamento Geral sobre a Proteção de Dados (RGPD) entrado em vigor em 25 de Maio de 2016 e plenamente aplicável a partir de 25 de Maio de 2018, (Regulamento (UE) 2016/679 do Parlamento Europeu e do Conselho de 27/04/16), de 27 de abril, publicado no Jornal Oficial da União Europeia, no dia 4 de Maio de 2016, e na Lei n.º 58/2019, de 8 de Agosto

Com os melhores cumprimentos,

O Presidente da Comissão de Ética do CAML

Prof. Doutor João Forjaz de Lacerda

COMISSÃO DE ÉTICA DO CAML
AVENIDA PROFESSOR EGAS MONIZ
1649-035 LISBOA
TEL. – 21 780 54 05; FAX – 21 780 56 90
ana.pimentel@chln.min-saude.pt

ALAMEDA DAS LINHAS DE TORRES, 117
1769-001 LISBOA
Tel: 217 548 000 – Fax: 217 548 215
www.chln.pt

1

Anexo 2 – Bases de Dados para Análise Estatística

I – Abreviaturas e Códigos de Registo do estudo

II – Caderno de Recolha de Dados de *Microsoft Excel*®

III – Editor de *IBM SPSS*® *Statistics* 29

Anexo 2, I – Abreviaturas e Códigos de Registo do Estudo

1. Abreviaturas do Caderno de Recolha de Dados de *Microsoft Excel*®

F – Feminino

M – Masculino

2. Códigos de Registo do Editor de *IBM SPSS*® *Statistics* 29

2.1. Sexo

1 – Feminino

2 – Masculino

2.2. Intervalo de Idades

1 – 16 a 23 anos

2 – 24 a 30 anos

Anexo 2, II – Caderno de Recolha de Dados de *Microsoft Excel*®

Folha 1

Nº Projeto	Sexo	Data de Nascimento
1	F	2003/03/03
2	F	2002/09/28
3	F	1996/03/30
4	M	1996/05/29
5	F	1997/12/01
6	M	2005/01/05
7	F	1995/01/18
8	M	1995/07/25
9	M	2001/05/22
10	M	1993/12/19
11	F	2005/09/10
12	F	1997/02/01
13	M	1998/01/15
14	M	1998/09/20
15	F	2004/09/22
16	F	1994/01/24
17	F	2004/04/16
18	F	1995/10/28
19	F	2006/12/20
20	F	1995/07/05
21	F	1993/11/25
22	F	2005/12/31
23	M	1998/09/06
24	F	1996/07/04
25	F	2005/02/21
26	F	2001/01/12
27	F	2007/02/02
28	F	2007/07/21
29	M	2005/03/15
30	M	1996/11/06
31	F	1998/05/11
32	F	2005/06/22
33	M	1996/01/05
34	M	2003/02/15
35	M	2003/01/27
36	F	2005/06/18
37	M	1997/07/21
38	M	1997/07/22
39	F	2002/06/19
40	F	1995/02/13
41	M	2005/07/08
42	M	2000/02/20
43	F	1994/05/27
44	M	1996/05/12
45	F	1994/10/08
46	M	1994/06/18
47	M	1996/01/09
48	F	1994/09/13
49	M	1996/08/05
50	M	2000/02/12
51	M	1997/08/08
52	M	1995/09/16
53	M	2000/01/01
54	M	1995/08/20
55	M	1997/09/17
56	M	1996/12/11
57	F	1995/03/17
58	M	1996/02/28
59	M	1994/12/04
60	M	1997/12/21
61	M	1998/12/03
62	M	2000/05/23
63	F	2000/01/21
64	F	1999/04/12
65	F	1996/09/26
66	F	1998/03/25
67	M	2006/09/02
68	M	2001/10/14
69	F	2004/12/05
70	M	2004/02/22

Nº Projeto	Sexo	Data de Nascimento
71	F	2001/04/12
72	M	2006/10/19
73	F	2004/12/19
74	F	1996/07/19
75	M	2002/06/22
76	F	2004/10/19
77	M	2001/04/20
78	M	2007/02/09
79	M	2006/09/18
80	F	1996/04/18
81	M	2005/09/11
82	F	2004/11/09
83	F	2001/12/01
84	F	1994/10/31
85	M	2003/09/21
86	M	2005/11/13
87	F	2006/06/09
88	M	2006/12/07
89	M	2002/05/03
90	M	2005/07/28
91	M	2005/10/20
92	F	2003/06/09
93	F	1995/05/16
94	F	2001/02/01
95	M	2001/06/19
96	M	2005/02/14
97	M	2004/02/02
98	M	2001/12/11
99	F	2002/04/09
100	M	2005/09/28
101	F	2002/11/08
102	M	2003/02/12
103	M	2004/01/06
104	F	2005/10/29
105	F	2001/03/22
106	F	1994/01/24
107	M	1995/01/18
108	F	1979/11/21
109	F	1996/07/13
110	F	1994/11/09
111	F	1999/03/07
112	M	2000/11/11
113	M	1997/09/11
114	M	1996/02/03
115	F	1998/03/05
116	M	1998/01/19
117	M	1997/02/28
118	F	1994/08/13
119	F	1994/03/08
120	M	1999/10/12
121	F	1998/12/17
122	M	1995/12/28
123	M	1994/10/19
124	F	1998/01/21
125	M	1997/07/26
126	M	1998/05/12
127	M	2002/02/19
128	M	2007/08/27
129	M	1999/06/04
130	M	2004/09/30
131	F	2006/02/16
132	F	1996/02/04
133	M	2006/10/19
134	F	1994/12/12
135	M	1980/02/17
136	M	2006/01/04
137	M	1995/05/25
138	F	2006/02/10
139	F	1994/04/15
140	M	2003/04/13

Folha 1

Nº Projeto	Sexo	Data de Nascimento
141	M	1996/10/22
142	M	2004/06/01
143	M	1999/02/01
144	M	2001/09/06
145	M	2006/05/14
146	F	2000/04/01
147	M	1996/12/23
148	M	2004/03/04
149	M	1995/05/02
150	M	2003/02/13
151	F	1997/01/06
152	M	2005/01/17
153	F	1995/11/18
154	F	1999/06/18
155	F	1996/07/21
156	M	1979/09/30
157	M	2003/11/01
158	M	2004/06/28
159	M	2003/08/14
160	M	2003/05/06
161	F	2004/05/22
162	M	2005/07/31
163	F	2002/04/30
164	F	2003/11/03
165	M	2002/12/06
166	M	2006/02/15
167	F	2005/02/17
168	M	2005/02/09
169	M	2001/06/01
170	M	2004/05/01
171	M	1997/10/21
172	F	1998/06/25
173	M	1998/01/15
174	M	1995/12/24
175	F	1999/01/27
176	M	1999/11/07
177	M	1999/12/18
178	M	1999/02/03
179	F	1995/01/05
180	M	1995/10/07
181	M	1998/12/20
182	F	1998/12/01
183	M	1996/11/03
184	M	1998/10/13
185	F	1995/02/07
186	M	2000/10/26
187	F	1994/09/23
188	F	1995/12/31
189	M	2000/06/09
190	F	2000/01/15
191	F	1995/06/21
192	F	1998/07/31
193	F	1997/11/15
194	F	1995/11/16
195	M	1997/04/07
196	M	1995/10/15
197	M	1996/09/27
198	F	1997/09/03
199	F	1999/06/29
200	M	1995/01/01
201	F	1997/08/26
202	M	2005/12/23
203	M	1995/10/19
204	M	2003/07/09
205	M	2006/05/08
206	F	2007/07/09
207	F	2004/06/04
208	M	2003/10/31
209	F	2003/09/04
210	F	2001/01/31

Nº Projeto	Sexo	Data de Nascimento
211	M	2001/04/24
212	F	2005/09/19
213	M	2005/08/10
214	F	1996/10/01
215	F	2004/09/21
216	M	2004/03/01
217	F	2004/12/07
218	M	2001/02/24
219	F	1998/03/19
220	M	2004/01/31
221	M	2003/03/11
222	F	1995/03/27
223	F	1997/07/21
224	F	1994/10/19
225	M	2005/02/10
226	M	1996/04/08
227	M	2001/10/29
228	F	1994/05/16
229	M	2006/12/20
230	M	1994/04/01
231	M	2003/03/12
232	F	1999/02/20
233	M	2004/05/10
234	F	2004/12/09
235	M	2001/08/11
236	M	2004/11/18
237	F	2001/07/09
238	F	1994/08/14
239	M	2004/08/15
240	M	2004/09/15
241	F	2003/05/18
242	M	2004/04/16
243	F	1993/10/11
244	M	2003/04/15
245	M	2004/05/06
246	F	1994/04/06
247	M	2004/05/16
248	M	1997/11/22
249	F	1999/08/19
250	F	2002/07/31
251	M	2003/01/01
252	M	2002/02/06
253	M	2003/10/01
254	M	2000/12/21
255	M	2004/02/21
256	M	1994/04/15
257	M	2004/01/01
258	M	2004/01/01
259	M	1999/05/05
260	M	2003/03/21
261	M	2004/01/01
262	M	2004/05/22
263	M	2006/06/27
264	M	2004/01/01
265	M	2004/01/01
266	M	2002/01/01
267	M	2001/09/23
268	M	2002/11/15
269	M	2002/01/01
270	F	1993/09/01
271	M	2003/02/03
272	M	2001/05/22
273	M	2002/02/20
274	M	2004/03/04
275	M	2002/08/01
276	M	2002/10/02
277	M	2002/11/12
278	F	2003/07/26
279	M	2001/06/04
280	M	2002/02/01

Folha 1

Nº Projeto	Sexo	Data de Nascimento
281	F	2003/03/30
282	M	2003/02/08
283	F	2002/08/20
284	M	2002/12/05
285	F	1987/02/06
286	M	2002/01/01
287	F	2002/01/12
288	M	2001/06/18
289	F	2002/11/12
290	F	2003/10/08
291	F	2003/05/06
292	F	2003/01/02
293	M	2001/03/09
294	F	1996/12/01
295	F	2002/05/16
296	M	1992/11/30
297	M	2001/08/19
298	M	2003/03/10
299	F	1994/12/04
300	M	2002/11/03
301	F	2002/08/12
302	M	1992/09/23
303	M	2001/09/15
304	M	1992/12/14
305	M	1997/05/13
306	F	1999/02/10
307	F	2000/10/30
308	M	1999/02/20
309	M	1995/07/18
310	F	1994/08/30
311	F	2000/02/28
312	F	1996/03/24
313	F	1999/05/10
314	M	1994/11/12
315	M	1998/06/04
316	M	1996/05/15
317	F	1995/03/15
318	F	1996/08/23
319	M	1998/07/30
320	F	1994/03/15
321	M	1996/11/08
322	M	1999/01/29
323	F	1996/10/10
324	F	1999/03/27
325	M	1996/09/09
326	M	1999/12/29
327	F	1997/09/05
328	M	1995/03/30
329	F	1994/11/26
330	M	1997/05/22
331	F	1994/10/07
332	M	1995/12/26
333	M	1998/12/09
334	M	1998/02/15
335	M	1994/08/31
336	F	2001/07/09
337	M	2007/04/05
338	F	2005/09/10
339	M	2007/10/02
340	M	2006/10/07
341	F	2002/02/04
342	M	2002/11/12
343	M	2003/03/08
344	F	2001/06/10
345	M	2002/06/25
346	M	2001/04/24
347	M	2001/09/24
348	F	2001/06/19
349	F	2002/11/28
350	F	2002/03/22

Nº Projeto	Sexo	Data de Nascimento
351	M	2002/08/13
352	M	2001/08/04
353	M	2002/07/31
354	M	2001/10/16
355	F	2002/01/02
356	M	2001/04/28
357	M	2001/06/07
358	M	2001/03/23
359	F	2001/06/07
360	M	2001/09/11
361	F	1993/07/10
362	F	1993/04/07
363	M	1993/09/09
364	M	1993/05/02
365	F	1993/02/19
366	F	1992/09/02
367	F	1992/08/04
368	M	1992/03/22
369	M	1992/02/12
370	F	1992/03/01
371	F	1992/02/27
372	M	1991/08/01
373	M	2002/02/20
374	F	1998/05/10
375	M	2000/09/22
376	F	2000/11/15
377	M	2002/02/01
378	M	2002/03/10
379	M	1995/04/07
380	F	1996/07/18
381	F	1995/01/29
382	M	1996/10/07
383	M	2002/01/01
384	M	1991/09/18
385	F	1990/10/14
386	M	1991/05/10
387	F	1990/12/05
388	M	1990/07/22
389	M	1991/04/30
390	F	1989/11/09
391	F	1989/10/20
392	F	1989/10/24
393	F	1989/08/02
394	F	1989/12/22
395	F	1988/12/06
396	M	1988/05/05
397	M	1988/04/22
398	M	1988/10/08
399	M	1988/07/10
400	M	1987/08/06
401	F	1988/02/29
402	M	1987/06/10
403	F	1998/03/29
404	F	2002/01/12
405	F	2000/04/23
406	M	1995/12/23
407	F	1999/12/16
408	M	1998/09/25
409	F	1996/10/30
410	M	1995/09/15
411	F	1997/12/10
412	M	1995/08/28
413	M	1998/02/12
414	F	1999/10/08
415	M	1999/01/03
416	M	1994/10/12
417	F	1997/03/13
418	M	1997/08/10
419	F	2000/01/24
420	F	1997/11/10

Folha 1

Nº Projeto	Sexo	Data de Nascimento
421	F	1996/02/15
422	F	2000/12/29
423	M	1995/03/28
424	F	1996/03/02
425	F	1998/12/10
426	M	1997/11/10
427	M	2001/03/04
428	M	1995/12/17
429	F	1995/04/26
430	M	1997/02/23
431	F	1999/11/01
432	F	1998/08/12
433	M	1995/04/08
434	M	1999/08/22
435	F	1996/04/03
436	M	1996/10/21
437	F	1994/11/20
438	F	1996/12/07
439	M	1998/02/17
440	F	1999/08/06
441	M	1994/12/23
442	F	1997/07/07
443	F	2002/03/22
444	F	1994/08/19
445	F	1995/04/26
446	F	1997/04/11
447	F	1998/12/31
448	M	1994/12/25
449	M	1997/12/07
450	M	2000/05/22
451	F	2000/08/03
452	M	1996/01/16
453	M	1996/04/25
454	M	1996/12/05
455	M	1999/03/19
456	M	1999/12/01
457	F	1998/04/17
458	M	1996/05/06
459	M	1997/10/15
460	F	1996/10/01
461	M	1999/08/09
462	M	1997/08/10
463	M	1998/04/22
464	M	1999/11/07
465	M	1998/08/26
466	M	2000/01/21
467	M	1997/02/04
468	F	1997/11/12
469	F	1995/12/05
470	M	1998/01/14
471	F	1997/01/04
472	F	1997/02/01
473	M	1996/09/26
474	F	1997/02/22
475	F	2002/01/02
476	F	2000/08/05
477	M	1987/01/24
478	F	1999/11/23
479	F	1998/09/30
480	F	1998/04/08
481	F	1999/09/28
482	F	1999/01/13
483	F	1997/09/18
484	M	1996/07/28
485	M	1994/04/15
486	F	1999/12/29
487	F	2000/11/02
488	M	1997/06/27
489	F	1997/06/09
490	F	1995/01/07

Nº Projeto	Sexo	Data de Nascimento
491	F	1996/05/20
492	M	1997/03/04
493	M	1995/04/03
494	M	1986/12/30
495	F	1987/06/03
496	F	1986/08/30
497	M	1987/06/21
498	M	1986/09/16
499	F	1986/11/12
500	M	1986/08/23
501	M	1986/07/10
502	F	1986/07/30
503	M	1985/11/11
504	F	1987/02/07
505	M	1985/06/22
506	M	1985/01/06
507	M	1984/10/11
508	F	1984/10/01
509	M	1984/09/26
510	F	1985/04/03
511	M	1984/08/28
512	F	1984/11/17
513	F	1984/09/24
514	M	1984/02/03
515	M	1984/01/28
516	M	1983/09/29
517	M	1983/12/19
518	M	1983/05/15
519	F	1983/07/28
520	F	1983/03/08
521	F	1983/08/15
522	M	1983/03/10
523	F	1982/08/11
524	F	1982/06/02
525	F	1982/04/25
526	F	1981/12/30
527	F	1981/07/13
528	M	1986/11/15
529	M	1981/10/20
530	M	1981/07/26
531	M	1980/12/26
532	F	1980/10/10
533	F	1980/02/15
534	M	1979/05/14
535	M	1994/07/25
536	M	1998/08/11
537	M	1997/01/01
538	M	1999/03/20
539	F	1998/11/24
540	M	1999/01/15
541	M	1998/02/27
542	F	2001/06/07
543	M	1998/03/27
544	M	1994/06/30
545	M	1999/07/24
546	F	1997/01/22
547	F	2000/10/16
548	M	1996/04/22
549	F	1995/09/21
550	F	1998/09/09
551	M	1996/04/08
552	F	1995/09/27
553	M	1995/04/01
554	M	1996/09/22
555	M	1996/09/11
556	F	1979/04/20
557	F	1978/11/07
558	F	1979/04/19
559	F	1979/05/31
560	F	1978/12/23

Folha 1

Nº Projeto	Sexo	Data de Nascimento
561	M	1993/04/13
562	F	1993/12/17
563	F	2006/08/22
564	M	1997/09/24
565	F	1998/01/28
566	F	1998/06/25
567	F	1997/03/13
568	M	1997/09/30
569	F	2000/09/18
570	M	1995/07/01
571	F	2000/04/24
572	M	1995/09/14
573	F	1998/11/05
574	F	1997/06/29
575	F	1996/09/27
576	M	1995/09/20
577	M	1996/12/19
578	M	1995/06/11
579	M	1996/09/06
580	M	1997/07/11
581	M	1994/06/24
582	F	1994/08/02
583	M	1994/06/15
584	M	1994/06/21
585	F	1994/07/28
586	F	1994/05/10
587	F	1995/05/04
588	F	1995/08/29
589	M	1994/06/29
590	F	2000/03/26
591	M	1995/10/05
592	M	1996/09/09
593	F	1998/09/13
594	M	1994/07/08
595	M	1996/06/25
596	F	1997/11/03
597	F	2000/01/02
598	M	1996/07/22
599	F	1999/09/19
600	M	1998/02/25
601	F	2000/02/23
602	F	1997/11/27
603	F	1994/09/14
604	F	1998/02/13
605	F	1996/10/04
606	F	1998/12/24
607	F	1996/01/25
608	F	2000/06/30
609	F	1994/05/14
610	M	1997/08/16
611	M	1997/05/30
612	F	1999/11/23
613	F	1995/10/28
614	F	1995/05/06
615	F	1996/03/02
616	F	1998/01/10
617	F	1995/05/22
618	F	1992/05/20
619	F	1992/02/14
620	F	1991/07/27
621	M	1991/01/05
622	M	1990/12/01
623	M	1991/02/05
624	M	1991/02/05
625	F	1991/01/23
626	F	1989/11/25
627	F	1989/10/07
628	M	1990/03/15
629	M	1989/11/29
630	F	1990/04/04

Nº Projeto	Sexo	Data de Nascimento
631	M	1989/05/07
632	F	1988/12/23
633	M	1988/09/02
634	F	1989/03/21
635	F	1988/09/02
636	M	1988/09/19
637	M	1988/07/22
638	M	1988/02/17
639	M	1988/07/07
640	F	1987/12/11
641	F	1988/04/09
642	M	1988/01/30
643	F	1987/11/30
644	F	1987/08/22
645	M	1986/12/24
646	M	1987/04/08
647	F	1987/07/02
648	M	1986/11/30
649	M	1987/03/06
650	F	1986/06/19
651	F	1987/01/10
652	F	1986/06/16
653	F	1985/07/30
654	M	1985/06/22
655	F	1985/04/09
656	F	1985/01/31
657	M	1986/08/27
658	F	1984/06/20
659	M	1984/01/01
660	M	1983/11/04
661	F	1986/01/15
662	M	1984/02/06
663	M	1983/05/13
664	F	1983/04/09
665	M	1983/09/10
666	M	1983/03/12
667	M	1983/05/11
668	F	1983/05/08
669	F	1983/05/04
670	F	1985/09/09
671	M	1981/11/23
672	F	1981/06/05
673	F	1981/09/09
674	M	1980/05/08
675	F	1980/05/11
676	M	1980/01/09
677	F	1995/02/26
678	M	1996/05/12
679	F	1997/05/23
680	M	1998/02/08
681	M	1997/08/31
682	F	1998/12/06
683	F	1994/12/25
684	F	1995/04/04
685	F	1994/05/11
686	M	1994/10/26
687	M	1994/06/21
688	F	1997/07/10
689	F	1998/07/07
690	F	1996/07/06
691	F	1996/05/20
692	F	1999/09/09
693	F	1995/05/05
694	M	1994/05/22
695	F	1996/04/07
696	F	1998/06/27
697	F	1998/05/06
698	F	1995/07/14
699	F	1996/08/14
700	F	1995/11/24

Folha 1

Nº Projeto	Sexo	Data de Nascimento
701	F	1994/07/26
702	M	1994/07/30
703	F	1994/05/01
704	M	1994/05/02
705	F	1995/08/02
706	F	1996/08/03
707	F	1996/05/07
708	M	1991/10/05
709	F	1995/10/23
710	M	1991/06/20
711	M	1991/03/11
712	F	1991/11/07
713	F	1994/09/27
714	F	1991/05/01
715	F	1991/08/07
716	M	1990/09/16
717	M	1991/01/20
718	M	1991/03/05
719	F	1986/06/11
720	F	1990/09/29
721	M	1990/02/15
722	F	1995/01/01
723	F	1995/09/10
724	M	1989/11/24
725	F	1989/09/10
726	F	1995/03/22
727	F	1989/06/25
728	F	1995/02/27
729	F	1989/11/04
730	F	1989/01/12
731	F	1988/09/24
732	F	1998/10/17
733	F	1997/10/28
734	M	1988/03/30
735	F	1988/04/23
736	F	1994/05/02
737	F	1987/09/20
738	M	1988/01/08
739	F	1987/12/17
740	F	1987/10/15
741	M	1993/12/21
742	F	1993/11/16
743	M	1993/11/07
744	F	1994/05/27
745	F	1987/04/10
746	F	1987/01/09
747	F	1986/08/04
748	F	1991/01/10
749	F	1990/05/20
750	F	1990/04/23
751	F	1988/08/01
752	F	1999/08/09
753	F	1994/02/14
754	M	1993/07/19
755	F	1993/12/28
756	M	1993/07/31
757	M	1993/01/17
758	F	1986/10/22
759	M	1985/11/23
760	F	1986/05/23
761	F	1985/07/20
762	F	1992/01/25
763	F	1984/12/18
764	F	1985/04/18
765	M	1984/10/13
766	F	1984/10/21
767	M	1985/01/09
768	F	1984/08/11
769	M	1984/05/11
770	M	1984/10/07

Nº Projeto	Sexo	Data de Nascimento
771	M	1984/09/12
772	M	1983/06/20
773	M	1983/11/07
774	M	1992/01/16
775	M	1992/01/02
776	M	1991/11/21
777	M	1991/01/23
778	F	1991/02/07
779	F	1991/06/19
780	M	1990/10/17
781	M	1981/02/25
782	M	1980/10/16
783	M	1980/11/04
784	F	1989/11/07
785	M	1992/03/30
786	M	1988/09/29
787	M	1988/04/26
788	M	1990/01/18
789	M	1993/07/02
790	F	1989/07/12
791	M	1989/06/11
792	F	1993/04/03
793	M	1988/10/27
794	F	1988/05/23
795	M	1989/01/09
796	F	1988/07/15
797	M	1992/04/28
798	M	1991/11/12
799	M	1988/08/21
800	M	1991/10/15
801	M	1991/05/02
802	M	1988/03/29
803	M	1990/12/13
804	F	1988/03/14
805	M	1987/10/01
806	F	1988/03/05
807	M	1990/02/02
808	F	1988/03/27
809	M	1987/09/16
810	M	1989/10/07
811	M	1989/01/03
812	M	2000/10/14
813	M	1999/12/31
814	F	1987/04/15
815	M	1987/01/28
816	M	1986/11/02
817	M	1986/10/02
818	M	1985/11/03
819	F	1985/07/25
820	F	1985/02/12
821	F	1985/06/02
822	F	1985/04/04
823	F	1984/09/05
824	F	1984/10/04
825	M	1985/04/15
826	F	1993/09/17
827	F	1993/05/07
828	F	1992/08/27
829	F	1992/09/08
830	F	1992/09/27
831	F	1984/03/15
832	F	1992/08/28
833	M	1991/09/15
834	M	1992/05/24
835	F	1992/07/28
836	M	1991/08/20
837	F	1992/03/24
838	M	1984/03/29
839	M	1992/01/26
840	M	1992/05/04

Folha 1

Nº Projeto	Sexo	Data de Nascimento
841	M	1991/11/12
842	M	1992/01/01
843	F	1991/08/28
844	M	1990/11/29
845	M	1991/01/12
846	M	1984/01/26
847	M	1991/03/22
848	F	1983/07/17
849	M	1990/07/10
850	M	1991/01/27
851	M	1990/05/23
852	M	1990/08/07
853	F	1982/08/21
854	F	1989/12/28
855	M	1989/12/09
856	M	1990/05/12
857	M	1990/06/15
858	F	1989/08/22
859	F	1982/08/21
860	F	1990/03/03
861	F	1989/11/08
862	M	1989/10/13
863	M	1989/07/19
864	F	1989/10/02
865	F	1982/03/19
866	F	1989/08/12
867	F	1982/01/23
868	M	1988/06/10
869	F	1992/02/03
870	M	1988/09/03
871	F	1992/06/28
872	M	1988/06/24
873	F	1987/06/11
874	F	1986/11/12
875	F	1985/09/04
876	F	1985/02/21
877	F	1985/01/25
878	F	1985/04/09
879	F	1985/02/06
880	F	1993/09/26
881	M	1993/04/04
882	F	1993/09/18
883	F	1993/07/01
884	M	1992/07/13
885	M	1992/11/27
886	M	1991/12/20
887	F	1992/04/04
888	F	1991/12/24
889	M	1992/04/11
890	F	1992/05/25
891	M	1992/03/02
892	F	1992/01/27
893	F	1991/01/30
894	M	1994/01/20
895	F	1994/02/08
896	M	1993/12/24
897	M	1993/09/24
898	M	1994/01/20
899	M	1993/08/24
900	M	1993/06/23
901	M	1993/06/11
902	F	1992/12/23
903	F	1993/01/02
904	F	1992/07/09
905	F	1992/02/19
906	M	1992/04/12
907	F	1992/01/31
908	F	1991/08/22
909	F	1991/06/23
910	M	1991/08/30

Nº Projeto	Sexo	Data de Nascimento
911	F	1991/09/06
912	F	1991/02/16
913	M	1990/11/06
914	M	1990/10/09
915	M	1990/06/29
916	M	1990/06/22
917	M	1990/01/20
918	M	1989/09/08
919	M	1990/01/01
920	M	1989/04/01
921	F	1988/09/24
922	M	1988/06/25
923	F	1988/11/20
924	M	1988/07/07
925	M	1988/03/18
926	F	1987/06/06
927	F	1987/12/30
928	F	1986/05/14
929	M	1986/04/04
930	F	1986/06/08
931	M	1985/09/01
932	F	1985/08/12
933	F	1985/09/02
934	F	1984/08/10
935	F	1984/12/02
936	F	1991/07/16
937	F	1987/02/04
938	F	1992/01/14
939	F	1996/06/04
940	M	1987/06/06
941	F	1990/11/26
942	F	1990/02/10
943	M	1993/08/15
944	F	1993/02/10
945	F	1992/07/15
946	F	1992/10/03
947	M	1992/01/22
948	F	1992/04/10
949	F	1992/04/28
950	M	1991/10/09
951	M	1991/12/06
952	F	1991/09/06
953	M	1991/08/07
954	F	1991/07/30
955	M	1991/03/09
956	M	1990/08/26
957	M	1990/11/20
958	F	1991/04/24
959	M	1989/09/30
960	M	1989/08/15
961	M	1989/07/01
962	F	1989/06/29
963	F	1989/09/27
964	M	1989/03/18
965	M	1989/01/02
966	F	1989/05/21
967	F	1989/01/22
968	M	1989/03/10
969	F	1988/11/06
970	M	1989/02/07
971	F	1988/06/12
972	M	1988/01/08
973	M	1988/03/17
974	M	1988/01/04
975	F	1987/09/02
976	M	1987/09/24
977	F	1987/12/30
978	M	1992/11/05
979	M	1993/08/16
980	M	1993/02/11

Folha 1

Nº Projeto	Sexo	Data de Nascimento
981	F	1992/11/04
982	F	1992/02/04
983	M	1992/07/18
984	M	1992/08/30
985	M	1991/10/25
986	F	1992/01/09
987	M	1991/06/15
988	F	1991/04/03
989	M	1991/07/04
990	F	1986/09/14
991	F	1991/05/10
992	M	1986/10/13
993	F	1990/07/09
994	F	1990/09/18
995	F	1986/12/08
996	M	1990/08/20
997	M	1989/11/17
998	M	1985/10/14
999	F	1989/11/26
1000	M	1986/07/19
1001	M	1986/06/17
1002	M	1989/09/02
1003	M	1989/06/20
1004	M	1989/09/25
1005	F	1986/03/03
1006	M	1989/12/16
1007	M	1989/01/15
1008	M	1988/10/04
1009	F	1984/11/28
1010	M	1989/01/23
1011	F	1995/04/23
1012	F	1990/11/15
1013	F	1987/02/09
1014	F	1986/08/16
1015	F	1988/06/30
1016	F	1986/07/09
1017	F	1995/12/27
1018	F	1992/02/09
1019	F	1987/07/24
1020	F	1987/03/20
1021	F	1992/02/16
1022	F	1993/03/17
1023	M	1993/06/15
1024	M	1993/01/04
1025	M	1993/09/05
1026	F	1993/09/06
1027	M	1992/09/19
1028	M	1994/07/25
1029	M	1993/05/12
1030	M	1993/01/23
1031	F	1992/11/09
1032	M	1991/12/05
1033	F	1992/06/09
1034	M	1991/09/23
1035	F	1991/11/17
1036	M	1991/10/05
1037	M	1992/06/08
1038	F	1990/06/14
1039	F	1990/01/07
1040	F	1989/07/02
1041	F	1988/01/08
1042	F	1987/01/16
1043	F	1996/08/14
1044	F	1996/07/16
1045	F	1993/06/02
1046	F	1987/09/22
1047	F	1992/07/19
1048	F	1992/02/13
1049	F	1989/12/17
1050	F	1988/04/27

Folha 2

Nº Projeto	Data OPG	Idade na OPG
1	2023/11/16	20
1A	2019/08/29	16
2	2023/11/15	21
3	2014/12/17	18
4	2023/11/15	27
5	2014/12/16	17
6	2023/11/10	18
7	2014/12/09	19
7A	2014/12/11	19
8	2023/11/04	28
9	2023/10/29	22
10	2023/10/28	29
11	2023/10/18	18
12	2014/12/04	17
13	2014/11/12	16
14	2023/10/24	25
15	2023/09/30	19
16	2023/10/17	29
16A	2023/12/05	29
16B	2009/10/20	15
16C	2008/12/22	14
17	2023/09/16	19
18	2023/11/16	28
19	2023/09/14	16
19A	2020/01/03	13
19B	2013/07/30	6
20	2014/10/30	19
21	2023/09/07	29
22	2023/05/03	17
23	2024/04/20	25
24	2014/10/29	18
25	2023/08/22	18
26	2023/08/14	22
27	2023/08/11	16
28	2023/07/31	16
29	2023/07/27	18
30	2014/10/08	17
31	2014/09/29	16
32	2023/06/30	18
33	2014/09/20	18
34	2023/06/26	20
35	2023/06/16	20
36	2023/06/15	17
37	2014/09/11	17
38	2014/08/06	17
39	2023/06/01	20
40	2015/07/25	20
41	2023/05/15	17
42	2023/11/02	23
43	2014/07/10	20
43A	2011/12/14	17
44	2023/10/30	27
45	2023/10/03	28
46	2014/06/18	20
47	2014/05/29	18
48	2014/05/21	19
49	2023/08/20	27
50	2023/08/14	23
51	2023/08/13	26
52	2023/08/03	27
53	2023/07/14	23
54	2023/07/12	27
54A	2019/05/30	23
54B	2016/08/03	20
54C	2013/08/19	17
54D	2011/03/14	15
55	2023/07/11	25
56	2023/07/06	26
57	2023/06/30	28
58	2023/06/29	27

Nº Projeto	Data OPG	Idade na OPG
59	2023/06/27	28
60	2023/06/19	25
61	2023/06/15	24
62	2023/06/12	23
63	2023/06/11	23
64	2023/06/03	24
65	2023/06/03	26
65A	2021/04/18	24
65B	2019/09/24	22
66	2023/05/31	25
66A	2022/01/31	23
66B	2019/03/08	20
67	2023/04/20	16
68	2023/04/18	21
69	2023/04/17	18
70	2023/04/14	19
71	2023/04/11	21
72	2023/04/11	16
73	2023/04/10	18
74	2014/05/14	17
75	2023/04/03	20
76	2023/03/28	18
76A	2015/04/16	10
77	2023/03/17	21
78	2023/03/15	16
78A	2014/05/09	7
79	2023/03/03	16
80	2014/05/06	18
81	2023/03/02	17
82	2023/02/20	18
83	2023/02/15	21
83A	2022/08/18	20
84	2014/04/24	19
85	2023/02/13	19
86	2023/02/01	17
87	2023/01/30	16
88	2023/01/25	16
89	2023/01/18	20
90	2023/01/12	17
91	2022/10/13	16
92	2022/10/07	19
93	2014/04/08	18
94	2022/09/21	21
95	2022/09/13	21
96	2022/09/09	17
97	2022/09/08	18
97A	2022/11/15	18
98	2022/08/23	20
99	2022/07/30	20
100	2022/07/29	16
101	2022/07/28	19
102	2022/07/27	19
102A	2015/03/02	21
103	2022/07/20	18
104	2022/07/06	16
104A	2011/09/13	5
105	2022/06/17	21
106	2023/12/05	29
106A	2023/10/17	29
106B	2023/04/10	29
106C	2009/10/20	15
106D	2008/12/22	14
107	2023/05/26	28
108	2009/05/04	29
109	2023/05/02	26
110	2023/04/16	28
111	2023/04/12	24
112	2023/04/12	22
113	2023/04/09	25
114	2023/04/06	27

Folha 2

Nº Projeto	Data OPG	Idade na OPG
115	2023/04/05	25
116	2023/03/27	25
117	2023/03/22	26
118	2023/03/22	28
119	2023/03/16	29
120	2023/03/11	23
120A	2023/01/20	23
121	2023/03/08	24
122	2023/03/06	27
123	2023/02/23	28
124	2014/03/11	16
125	2023/02/19	25
126	2023/02/17	24
127	2023/12/14	21
128	2023/12/13	16
128A	2023/05/18	15
129	2023/12/11	24
130	2023/12/06	19
130A	2022/03/16	17
130B	2018/08/08	13
130C	2017/01/05	12
131	2023/11/29	17
132	2023/02/14	27
133	2023/11/22	17
134	2023/02/10	28
135	2009/04/16	29
136	2023/11/17	17
137	2023/02/02	27
137A	2016/10/30	21
138	2022/06/14	16
139	2023/01/20	28
139A	2021/01/12	26
140	2022/06/08	19
140A	2019/09/16	16
140B	2013/01/10	9
140C	2012/05/09	9
140D	2009/12/04	6
141	2023/01/17	26
142	2022/06/03	18
143	2023/01/17	23
144	2022/05/28	20
145	2022/05/25	16
146	2022/10/19	22
147	2014/03/05	17
148	2022/05/19	18
149	2022/10/14	27
150	2022/05/16	19
151	2022/10/14	25
152	2022/05/13	17
153	2022/10/11	26
154	2022/10/10	23
155	2022/10/10	26
156	2009/02/05	29
157	2022/05/03	18
157A	2024/02/21	20
157B	2021/09/08	17
157C	2019/09/16	15
158	2022/05/03	17
159	2022/04/28	18
160	2022/04/27	18
161	2022/04/22	17
162	2022/03/31	16
163	2022/03/16	19
164	2022/03/14	18
164A	2015/03/20	11
164B	2013/03/22	9
164C	2009/10/06	5
165	2022/03/09	19
166	2022/02/28	16
167	2022/02/04	16

Nº Projeto	Data OPG	Idade na OPG
167A	2020/01/16	14
168	2022/02/01	16
169	2022/01/26	20
170	2022/01/24	17
171	2022/09/30	24
172	2022/09/24	24
173	2022/09/11	24
174	2022/08/30	26
175	2022/08/25	23
176	2022/08/18	22
177	2022/08/09	22
178	2022/07/03	23
179	2022/06/16	27
180	2022/06/07	26
181	2022/06/02	23
182	2022/05/19	23
183	2022/04/26	25
184	2022/04/22	23
185	2022/04/05	27
186	2022/04/01	21
187	2022/01/28	27
188	2022/01/12	26
188A	2019/03/29	23
189	2022/01/10	21
189A	2024/03/06	23
190	2021/12/16	21
190A	2016/05/23	16
190B	2015/06/22	15
190C	22/09/2014	14
190D	2014/02/05	14
190E	2012/12/19	12
191	2021/10/08	26
191A	2021/05/24	25
192	2021/10/04	23
193	2021/09/24	23
194	2021/09/15	25
195	2021/09/15	24
196	2021/08/30	25
196A	2013/04/04	17
197	2021/08/30	24
197A	2021/08/13	24
198	2021/08/13	23
199	2021/07/29	22
200	2021/06/08	26
201	2014/02/19	16
202	2024/01/02	18
203	2014/02/07	18
204	2023/12/25	20
204A	2019/10/12	16
205	2023/12/19	17
206	2023/12/18	16
207	2023/12/15	19
208	2022/01/11	18
209	2022/01/04	18
210	2021/12/17	20
211	2021/12/17	20
212	2021/12/10	16
212A	2016/04/06	10
213	2021/11/24	16
214	2023/12/22	27
215	2021/11/24	17
215A	2021/10/07	17
215B	2021/09/21	17
215C	2021/09/07	16
215D	2021/09/02	16
216	2021/11/22	17
217	2021/11/20	16
218	2021/11/11	20
219	2024/01/10	25
220	2021/11/09	17

Folha 2

Nº Projeto	Data OPG	Idade na OPG
221	2021/11/04	18
222	2021/05/18	26
223	2021/05/18	23
224	2014/01/28	19
225	2021/10/15	16
226	2021/05/04	25
226A	2017/03/17	20
226B	2011/04/11	15
227	2021/10/11	19
228	2024/01/12	29
229	2024/01/18	17
230	2024/01/15	29
231	2021/09/13	18
232	2024/01/16	24
233	2021/01/29	16
234	2021/09/01	16
235	2021/08/30	20
236	2021/08/25	16
237	2024/03/13	22
238	2022/10/26	28
239	2021/01/29	16
240	2021/06/15	16
241	2019/05/23	16
242	2021/05/04	17
242A	2020/07/03	16
242B	2018/09/26	14
242C	2018/09/20	14
243	2022/09/12	28
244	2021/03/25	17
245	2021/01/27	16
246	2022/07/27	28
247	2021/02/01	16
248	2021/03/26	23
249	2021/03/04	21
250	2021/01/15	18
251	2020/12/28	17
252	2020/12/13	18
253	2020/12/09	17
254	2020/12/12	19
255	2020/10/28	16
256	2020/12/02	26
257	2020/09/29	16
258	2020/09/16	16
259	2020/11/05	21
260	2020/09/14	17
261	2020/08/26	16
262	2020/08/21	16
263	2024/02/01	17
264	2020/08/06	16
265	2020/08/06	16
266	2020/08/03	18
267	2020/07/08	18
267A	2020/01/16	18
268	2020/06/22	17
269	2020/06/22	18
270	2022/03/27	28
271	2020/05/25	17
272	2020/05/07	18
272A	2019/10/27	18
273	2020/03/11	18
274	2020/03/05	16
275	2020/02/27	17
276	2020/02/27	17
277	2020/02/20	17
278	2020/02/11	16
279	2020/02/04	18
280	2020/01/28	17
281	2020/01/08	16
281A	2016/02/01	12
282	2019/12/17	16

Nº Projeto	Data OPG	Idade na OPG
283	2019/12/13	17
283A	2019/02/20	16
284	2019/11/29	16
285	2013/11/20	26
286	2019/11/19	17
287	2019/11/14	17
288	2019/11/10	18
289	2019/10/27	16
290	2019/10/25	16
291	2019/10/23	16
292	2019/10/09	16
293	2019/10/06	18
294	2013/12/23	17
295	2019/09/04	17
296	2021/11/12	28
297	2019/07/18	17
297A	2018/07/19	16
297B	2018/02/07	16
297C	2017/10/16	16
297D	2016/12/15	15
297E	2016/02/18	14
297F	2015/11/23	14
298	2019/07/09	16
299	2013/12/14	19
300	2019/06/25	16
301	2019/06/14	16
302	2021/06/17	28
303	2019/05/27	17
304	2021/03/24	28
305	2024/02/24	26
306	2024/02/24	25
306A	2016/09/05	17
307	2024/02/16	23
307A	2015/02/25	14
307B	2014/03/03	13
308	2024/02/07	24
308A	2016/07/05	17
309	2024/01/30	28
310	2024/01/27	29
311	2020/10/13	20
312	2020/10/12	24
313	2020/10/09	21
314	2013/12/06	19
315	2020/09/29	22
316	2020/09/17	24
317	2020/09/17	25
318	2020/09/16	24
319	2020/09/06	22
320	2020/09/03	26
321	2020/08/15	23
322	2020/08/07	21
323	2020/07/20	23
324	2020/07/18	21
325	2020/07/18	23
326	2020/07/13	20
326A	2012/06/15	12
327	2020/07/08	22
328	2020/07/08	25
328A	2015/02/12	19
329	2020/07/01	25
330	2020/06/24	23
331	2020/06/22	25
332	2020/06/19	24
333	2020/05/31	21
334	2020/04/27	22
335	2020/04/04	25
336	2024/03/13	22
337	2024/03/03	16
338	2024/03/01	18
339	2024/02/15	16

Folha 2

Nº Projeto	Data OPG	Idade na OPG
340	2024/02/15	17
341	2019/05/02	17
342	2019/04/20	16
343	2019/03/11	16
344	2019/03/04	17
345	2019/02/23	16
346	2019/02/16	17
347	2019/02/12	17
348	2019/02/05	17
348A	2014/10/18	13
349	2019/01/11	16
350	2018/11/09	16
351	2018/11/08	16
352	2018/10/28	17
353	2018/08/27	16
353A	2018/06/08	15
354	2018/08/06	16
355	2018/06/11	16
356	2018/05/04	17
357	2018/04/05	16
358	2018/03/21	16
358A	2011/03/16	9
358B	2009/07/28	8
359	2018/01/03	16
360	2017/09/13	16
361	2023/11/04	30
362	2023/10/26	30
363	2023/09/26	30
364	2023/09/14	30
365	2023/06/27	30
366	2023/06/27	30
367	2023/03/21	30
368	2023/02/10	30
369	2022/09/07	30
369A	2021/07/03	29
370	2022/07/18	30
370A	2019/10/31	27
370B	2009/09/14	17
371	2022/04/01	30
372	2022/02/04	30
373	2020/03/11	18
374	2020/02/21	21
375	2020/02/18	19
376	2020/02/02	19
377	2020/01/28	17
378	2020/01/21	17
379	2020/01/14	24
380	2020/01/13	23
381	2019/12/20	24
382	2019/11/26	23
382A	2019/04/17	22
383	2019/11/19	17
384	2021/09/29	30
385	2021/08/24	30
386	2021/07/27	30
387	2021/07/18	30
388	2021/07/03	30
389	2021/06/16	30
389A	2021/06/02	30
389B	2019/08/26	28
390	2020/03/11	30
390A	2020/03/09	30
391	2020/03/04	30
392	2020/01/14	30
393	2020/01/13	30
394	2020/01/05	30
395	2019/05/31	30
396	2019/04/05	30
397	2019/01/04	30
398	2018/10/23	30

Nº Projeto	Data OPG	Idade na OPG
398A	2018/07/12	29
398B	2016/06/03	27
399	2018/09/11	30
399A	2015/08/28	27
399B	2013/04/26	24
399C	2013/04/19	24
399D	2010/07/02	21
400	2018/08/01	30
401	2018/06/23	30
402	2018/04/06	30
403	2024/03/19	25
404	2019/11/14	17
405	2019/10/09	19
406	2019/10/07	23
407	2019/09/02	19
408	2019/09/01	20
409	2019/07/16	22
410	2019/07/07	23
411	2019/07/05	21
412	2019/07/05	23
413	2019/07/03	21
414	2019/05/27	19
414A	2018/11/28	19
415	2019/05/21	20
416	2019/05/02	24
417	2019/05/02	22
418	2019/05/02	21
419	2019/04/27	19
420	2019/04/24	21
421	2019/04/15	23
422	2019/04/15	18
423	2019/04/04	24
424	2019/03/27	23
424A	2018/11/30	22
425	2019/03/26	20
426	2019/03/11	21
427	2019/03/07	18
428	2019/02/18	23
428A	2018/03/02	22
429	2019/02/13	23
430	2019/02/01	21
431	2019/01/17	19
432	2019/01/13	20
433	2019/01/04	23
434	2018/12/26	19
435	2018/12/14	22
436	2018/12/11	22
436A	2018/02/05	21
436B	2014/07/25	17
436C	2009/05/19	12
437	2018/12/10	24
438	2018/12/07	22
439	2018/12/03	20
440	2018/11/23	19
441	2018/11/22	23
442	2018/11/14	21
443	2018/11/09	16
444	2018/11/06	24
445	2018/10/31	23
446	2018/10/31	21
447	2018/10/29	19
448	2018/10/28	23
449	2018/10/25	20
450	2018/10/22	18
451	2018/10/16	18
452	2018/10/04	22
453	2018/10/02	22
454	2018/09/21	21
455	2018/09/10	19
456	2018/09/07	18

Folha 2

Nº Projeto	Data OPG	Idade na OPG
457	2018/09/07	20
458	2018/09/07	22
459	2018/09/03	20
459A	2014/12/23	17
460	2018/08/31	21
460A	2015/12/01	19
461	2018/08/10	19
462	2018/08/07	20
462A	2017/09/13	20
462B	2015/06/17	17
462C	2012/05/22	14
463	2018/08/01	20
464	2018/07/30	18
465	2018/07/25	19
466	2018/07/18	18
467	2018/07/14	21
468	2018/07/08	20
469	2018/06/27	22
470	2018/06/27	20
471	2018/06/19	21
472	2018/06/19	21
473	2018/06/18	21
474	2018/06/14	21
475	2018/06/11	16
476	2018/06/10	17
477	2013/09/19	26
478	2018/06/07	18
479	2018/06/04	19
480	2018/05/14	20
481	2018/05/03	18
482	2018/04/18	19
482A	2017/03/06	18
483	2018/04/16	20
484	2018/04/13	21
485	2018/03/27	23
486	2018/03/26	18
487	2018/03/21	17
488	2018/03/21	20
488A	2017/05/09	19
488B	2012/01/17	14
489	2018/03/18	20
490	2018/03/02	23
491	2018/03/02	21
492	2018/02/28	20
492A	2015/06/15	18
493	2018/02/23	22
494	2017/11/27	30
495	2017/10/16	30
496	2017/07/13	30
497	2017/06/27	30
498	2017/03/31	30
499	2017/03/03	30
500	2016/11/08	30
501	2016/10/04	30
501A	2015/09/27	29
502	2016/10/04	30
503	2016/09/14	30
504	2013/08/26	26
505	2016/01/18	30
506	2015/11/17	30
507	2015/09/18	30
508	2015/06/08	30
508A	2014/10/22	30
509	2015/05/19	30
509A	2013/06/18	28
509B	2012/06/27	27
510	2015/04/29	30
511	2015/04/10	30
512	2015/03/31	30
513	2015/01/19	30

Nº Projeto	Data OPG	Idade na OPG
514	2014/10/20	30
515	2014/08/25	30
516	2014/06/19	30
516A	2013/05/07	29
517	2014/04/23	30
518	2013/11/20	30
519	2013/09/27	30
520	2013/09/27	30
521	2013/09/14	30
522	2013/08/21	30
523	2013/06/27	30
524	2013/05/03	30
525	2012/06/29	30
526	2012/03/05	30
527	2012/02/15	30
528	2013/7/23	26
529	2011/12/02	30
530	2011/11/03	30
531	2011/10/12	30
532	2011/09/08	30
533	2010/11/01	30
534	2010/02/14	30
535	2024/03/29	29
536	2018/01/28	19
537	2018/01/24	21
538	2018/01/22	18
539	2018/01/08	19
540	2018/01/06	18
541	2018/01/04	19
542	2018/01/03	16
543	2018/01/02	19
544	2017/12/31	23
545	2017/12/29	18
546	2017/12/11	20
547	2017/11/24	17
548	2017/10/19	21
549	2017/10/16	22
550	2017/10/16	19
551	2017/10/16	21
552	2017/10/13	22
553	2017/09/07	22
554	2017/09/07	20
555	2017/08/24	20
556	2009/11/06	30
557	2009/10/16	30
558	2009/08/06	30
559	2009/07/17	30
559A	2009/07/14	30
560	2009/04/08	30
561	2024/02/07	30
562	2024/01/18	30
563	2024/03/21	17
563A	2018/01/25	11
564	2017/08/22	19
565	2017/08/17	19
566	2017/07/27	19
566A	2012/01/26	13
567	2017/07/17	20
568	2017/07/17	19
568A	2016/09/01	18
569	2017/06/30	16
570	2017/06/27	21
571	2017/06/08	17
572	2017/06/02	21
572A	2015/06/04	19
573	2017/05/30	18
573A	2017/05/25	18
574	2017/05/18	19
575	2017/05/16	20
575A	2015/09/10	18

Folha 2

Nº Projeto	Data OPG	Idade na OPG
576	2017/05/08	21
576A	2015/06/24	19
577	2017/05/02	20
578	2017/04/28	21
579	2017/04/11	20
580	2017/03/15	19
581	2017/06/29	23
582	2017/05/12	22
583	2017/05/12	22
584	2017/04/17	22
585	2017/04/13	22
585A	2014/06/12	19
586	2017/03/23	22
587	2017/02/25	21
588	2017/02/24	21
589	2017/02/24	22
590	2017/02/22	16
591	2017/02/22	21
592	2016/12/02	20
593	2017/02/20	18
594	2017/02/17	22
595	2017/02/17	20
596	2017/02/14	19
597	2017/02/13	17
598	2017/02/06	20
599	2016/11/22	17
599A	2016/03/24	16
600	2017/01/20	18
601	2016/11/16	16
602	2016/11/04	18
603	2016/10/28	22
604	2016/10/26	18
605	2016/10/19	20
606	2016/09/26	17
607	2016/09/12	20
608	2016/09/07	16
609	2016/07/07	22
610	2016/06/14	18
611	2016/06/02	19
612	2016/05/23	16
612A	2010/12/29	11
612B	2009/07/06	9
613	2016/05/18	20
614	2016/05/05	20
615	2016/04/07	20
615A	2012/07/05	16
616	2016/03/28	18
617	2016/03/17	20
618	2021/11/22	29
619	2021/09/28	29
620	2021/07/08	29
621	2020/10/27	29
622	2020/05/20	29
623	2020/05/15	29
624	2020/02/27	29
624A	2018/04/16	27
624B	2009/06/18	18
625	2020/02/11	29
626	2019/07/25	29
627	2019/07/16	29
628	2019/07/13	29
629	2019/05/28	29
630	2019/05/20	29
631	2019/04/16	29
632	2018/07/02	29
633	2018/06/19	29
633A	2014/01/31	25
634	2018/04/03	29
635	2018/02/20	29
636	2018/01/24	29

Nº Projeto	Data OPG	Idade na OPG
637	2018/01/05	29
638	2017/09/25	29
639	2017/08/18	29
640	2017/05/08	29
641	2017/05/03	29
642	2017/03/09	29
643	2017/01/30	29
644	2016/11/30	29
645	2016/09/28	29
646	2016/09/02	29
647	2016/07/27	29
648	2016/05/25	29
649	2016/03/07	29
650	2015/09/23	29
651	2013/01/25	29
652	2015/07/15	29
653	2015/05/28	29
654	2015/03/11	29
655	2014/12/15	29
655A	2014/04/07	28
655B	2011/07/20	26
656	2014/03/14	29
657	2012/12/14	26
658	2013/11/07	29
659	2013/10/28	29
660	2013/10/18	29
661	2012/09/19	26
662	2013/10/01	29
663	2013/04/11	29
664	2012/11/09	29
665	2012/10/29	29
666	2012/08/10	29
667	2012/08/09	29
668	2012/07/30	29
669	2012/07/23	29
670	2012/08/07	26
671	2010/12/03	29
672	2010/10/20	29
673	2010/09/15	29
674	2010/03/05	29
675	2010/01/11	29
676	2009/10/28	29
676A	2009/02/18	29
677	2016/03/12	21
678	2016/03/10	19
679	2016/03/02	18
680	2016/02/29	18
681	2016/02/29	18
682	2016/02/19	17
683	2016/02/18	21
684	2016/02/12	20
685	2016/02/10	21
686	2016/02/04	21
687	2016/01/19	21
687A	2015/11/26	21
687B	2015/11/23	21
688	2016/01/06	18
689	2016/01/06	17
689A	2015/01/13	16
689B	2014/03/05	15
689C	2009/03/03	10
690	2015/12/28	19
691	2015/12/17	19
692	2015/12/15	16
693	2015/12/09	20
694	2015/10/29	21
695	2015/10/14	19
696	2015/09/09	17
697	2015/07/27	17
697A	2012/03/02	13

Folha 2

Nº Projeto	Data OPG	Idade na OPG
698	2015/06/30	19
699	2015/04/24	18
700	2015/04/23	19
701	2015/03/27	20
702	2015/02/16	20
703	2015/02/11	20
704	2015/01/23	20
705	2013/11/20	18
706	2013/11/06	17
707	2013/10/15	17
708	2020/01/14	28
709	2013/09/02	17
710	2019/12/26	28
711	2019/12/28	28
712	2019/12/06	28
713	2013/07/12	18
714	2019/10/24	28
715	2019/09/17	28
716	2019/09/10	28
717	2019/09/06	28
718	2019/05/09	28
719	2012/06/15	26
720	2019/02/05	28
720A	2012/04/24	21
720B	2010/04/16	19
721	2018/08/06	28
722	2013/02/27	18
723	2013/02/22	17
724	2018/06/12	28
725	2018/06/01	28
726	2013/01/31	17
726A	2013/01/10	17
726B	2013/01/01	17
727	2018/01/27	28
728	2012/09/21	17
729	2017/12/12	28
730	2017/12/25	28
731	2017/05/22	28
732	2017/08/31	18
733	2016/04/21	18
734	2016/12/22	28
735	2016/12/17	28
736	2012/12/20	18
737	2016/08/04	28
738	2016/08/03	28
739	2016/03/28	28
739A	2010/07/29	22
740	2016/02/19	28
741	2014/12/18	20
742	2014/10/16	20
743	2014/09/12	20
744	2014/07/10	20
744A	2011/12/14	17
745	2015/08/25	28
746	2015/06/09	28
747	2015/04/09	28
748	2011/12/07	20
749	2011/01/13	20
750	2010/09/21	20
751	2009/06/02	20
752	2019/11/18	20
753	2021/12/29	27
754	2021/07/12	27
755	2021/06/19	27
756	2021/03/12	27
757	2020/02/09	27
758	2015/01/28	28
759	2014/11/13	28
760	2014/09/10	28
761	2014/04/23	28

Nº Projeto	Data OPG	Idade na OPG
762	2019/10/21	27
763	2013/09/06	28
764	2013/10/11	28
765	2013/07/26	28
766	2013/06/14	28
767	2013/06/08	28
768	2013/05/27	28
769	2012/12/11	28
770	2012/11/20	28
770A	2012/11/05	28
771	2012/10/29	28
772	2012/03/21	28
773	2012/02/25	28
774	2019/07/03	27
775	2019/03/27	27
776	2018/11/22	27
777	2018/10/31	27
777A	2013/11/18	22
778	2018/09/18	27
779	2018/09/01	27
780	2018/05/30	27
781	2009/10/21	28
782	2009/07/17	28
783	2009/06/16	28
784	2017/07/26	27
785	2020/08/02	28
785A	2028/02/14	35
786	2017/05/10	28
787	2016/07/06	28
788	2017/04/05	27
788A	2012/06/25	22
789	2012/09/17	19
790	2016/10/12	27
791	2016/09/20	27
792	2012/06/08	19
793	2016/04/08	27
794	2016/02/17	27
795	2016/02/02	27
796	21/01/2016	27
797	2011/08/01	19
798	2011/05/24	19
799	2015/11/20	27
800	2011/02/21	19
801	2010/10/08	19
802	2015/10/05	27
803	2010/01/30	19
804	2015/08/25	27
805	2015/06/05	27
806	2015/04/30	27
807	2009/06/20	19
808	2015/04/13	27
809	2015/03/05	27
810	2009/01/27	19
811	2008/11/26	19
812	2020/10/05	19
813	2019/07/29	19
814	2014/12/04	27
815	2014/09/19	27
816	2014/07/31	27
817	2014/06/18	27
817A	2009/03/08	22
818	2013/05/10	27
819	2013/03/20	27
820	2012/11/26	27
821	2012/10/03	27
822	2012/09/28	27
823	2012/08/01	27
824	2012/07/12	27
825	2012/06/15	27
826	2019/12/18	26

Folha 2

Nº Projeto	Data OPG	Idade na OPG
827	2019/09/22	26
828	2019/07/22	26
828A	2017/06/14	24
829	2018/12/04	26
830	2018/10/11	26
830A	2017/12/12	25
831	2011/11/29	27
832	2018/09/22	26
833	2018/09/09	26
834	2018/08/29	26
835	2018/08/29	26
835A	2017/06/06	24
835B	2016/08/09	24
836	2018/07/16	26
837	2018/06/18	26
838	2011/11/10	27
839	2018/05/30	26
840	2018/05/11	26
840A	2017/03/17	24
841	2018/04/02	26
841A	2014/10/22	22
841B	2014/10/07	22
842	2018/02/22	26
843	2017/11/27	26
844	2017/11/10	26
845	2017/10/16	26
846	2011/08/21	27
847	2017/07/18	26
848	2010/10/04	27
849	2017/04/06	26
850	2017/02/15	26
851	2016/12/19	26
852	2016/11/13	26
853	2010/01/04	27
854	2016/10/19	26
854A	01/07/2014	24
854B	14/01/2009	19
855	2016/09/28	26
856	2016/09/21	26
856A	2024/05/13	34
857	2016/09/09	26
858	2016/07/08	26
859	2010/01/03	27
860	2016/06/06	26
861	2016/06/03	26
862	2016/04/07	26
862A	2012/07/05	22
863	2016/02/03	26
864	2015/12/09	26
865	2009/11/11	27
866	2015/08/13	26
867	2009/09/21	27
868	2014/12/09	26
869	2019/12/26	27
869A	2017/02/22	25
870	2014/09/19	26
871	2019/08/23	27
872	2014/08/06	26
873	2014/08/01	27
874	2014/03/31	27
874A	2012/10/03	25
874B	2009/11/20	23
875	2012/05/09	26
876	2011/12/12	26
877	2011/12/08	26
878	2011/11/25	26
879	2011/10/26	26
880	2014/12/30	21
881	2014/12/29	21
882	2014/12/02	21

Nº Projeto	Data OPG	Idade na OPG
883	2014/10/28	21
884	2014/02/18	21
885	2014/01/13	21
886	2013/12/12	21
887	2013/11/26	21
888	2013/10/03	21
889	2013/10/01	21
890	2013/09/06	21
891	2013/08/13	21
892	2013/05/22	21
893	2012/09/20	21
894	2019/09/25	25
895	2019/09/06	25
896	2019/07/26	25
897	2019/06/29	25
898	2019/03/08	25
899	2019/02/12	25
899A	2016/04/29	22
900	2019/01/02	25
901	2018/06/22	25
902	2018/06/20	25
903	2018/05/23	25
903A	2012/09/14	19
904	2018/05/18	25
905	2017/10/29	25
906	2017/08/21	25
907	2017/07/17	25
908	2017/06/08	25
909	2017/04/28	25
910	2017/04/20	25
911	2016/11/28	25
912	2016/07/29	25
913	2016/05/17	25
914	2016/04/12	25
915	2015/10/19	25
916	2015/08/20	25
917	2015/05/28	25
918	2015/03/20	25
919	2015/01/19	25
920	2014/05/02	25
921	2014/04/01	25
922	2014/03/09	25
922A	2014/03/11	25
922B	2014/03/20	25
923	2014/02/06	25
924	2013/09/02	25
925	2013/04/16	25
926	2013/03/04	25
927	2013/02/01	25
928	2011/12/23	25
928A	2009/04/21	22
929	2011/10/17	25
930	2011/10/11	25
931	2011/01/24	25
932	2010/09/24	25
933	2010/09/10	25
934	2010/06/11	25
935	2010/01/03	25
936	2016/11/23	25
936A	2015/03/25	23
937	2012/05/22	25
938	2017/11/12	25
939	2021/09/21	25
940	2015/04/02	27
941	2012/05/30	21
942	2011/08/19	21
943	2017/08/31	24
944	2017/05/22	24
945	2017/04/05	24
946	2017/01/16	24

Folha 2

Nº Projeto	Data OPG	Idade na OPG
947	2016/12/30	24
948	2016/12/22	24
949	2016/12/16	24
950	2016/03/19	24
951	2016/01/18	24
952	2016/01/11	24
953	2015/12/15	24
954	2015/10/28	24
955	2015/09/29	24
956	2015/07/16	24
957	2015/07/16	24
958	2015/04/27	24
959	2014/09/09	24
960	2014/05/31	24
961	2014/05/10	24
962	2014/01/30	24
963	2013/10/27	24
964	2013/11/25	24
965	2013/10/31	24
966	2013/08/28	24
967	2013/08/02	24
968	2013/05/15	24
969	2013/04/10	24
970	2013/03/13	24
971	2013/01/08	24
972	2012/04/27	24
973	2012/04/12	24
974	2012/03/20	24
975	2012/03/19	24
976	2012/02/08	24
977	2012/01/30	24
978	2015/09/23	22
978A	2011/09/21	18
979	2015/08/18	22
980	2015/08/12	22
981	2015/02/17	22
982	2014/12/28	22
983	2014/12/11	22
984	2014/10/29	22
985	2014/10/02	22
986	2014/07/23	22
987	2014/05/13	22
988	2013/10/25	22
989	2013/07/16	22
990	2011/07/26	24
991	2013/06/24	22
992	2011/06/24	24
992A	2009/04/02	22
993	2013/05/17	22
994	2013/02/27	22
995	2011/03/07	24
996	2013/01/21	22
997	2012/10/22	22
998	2010/10/08	24
998A	2010/10/01	24
999	2012/09/16	22
1000	2010/08/04	24
1001	2010/06/28	24
1002	2012/05/11	22
1003	2012/05/02	22
1004	2012/03/21	22
1005	2010/03/17	24
1006	2012/01/18	22
1007	2011/11/01	22
1008	2011/10/03	22
1009	2009/05/18	24
1010	2011/03/15	22
1011	2020/01/01	24
1012	2015/03/31	24
1013	2009/05/04	22

Nº Projeto	Data OPG	Idade na OPG
1014	2009/05/03	22
1015	2013/04/19	24
1016	2009/03/29	22
1017	2018/11/24	22
1017A	2016/12/20	20
1018	2014/08/08	22
1019	2012/05/17	24
1020	2009/07/24	22
1021	2014/06/18	22
1022	2016/12/12	23
1023	2016/11/04	23
1024	2016/11/04	23
1025	2016/10/12	23
1026	2016/09/07	23
1027	2016/08/04	23
1028	2024/03/29	29
1029	2016/07/27	23
1030	2016/07/26	23
1031	2016/05/16	23
1032	2015/10/16	23
1033	2015/09/04	23
1034	2015/08/21	23
1035	2015/08/11	23
1035A	2012/07/17	20
1036	2014/11/26	23
1037	2015/07/24	23
1038	2013/09/12	23
1039	2013/05/13	23
1040	2012/08/15	23
1041	2011/12/20	23
1042	2010/01/20	23
1042A	2010/01/19	23
1043	2019/12/20	23
1044	2019/11/27	23
1044A	2014/02/14	17
1045	2016/11/30	23
1045A	2016/04/13	22
1046	2011/05/17	23
1047	2015/11/02	23
1048	2015/05/29	23
1048A	2011/11/13	19
1048B	2009/01/28	16
1049	2013/06/14	23
1049A	2010/09/20	20
1050	2011/11/07	23

Anexo 2, III – Editor de *IBM SPSS® Statistics* 29

Nº Projeto	Sexo	Idade	Intervalo Idades
1	1	20	1
2	1	21	1
3	1	18	1
4	2	27	2
5	1	17	1
6	2	18	1
7	1	19	1
8	2	28	2
9	2	22	1
10	2	29	2
11	1	18	1
12	1	17	1
13	2	16	1
14	2	25	2
15	1	19	1
16	1	29	2
17	1	19	1
18	1	28	2
19	1	16	1
20	1	19	1
21	1	29	2
22	1	17	1
23	2	25	2
24	1	18	1
25	1	18	1
26	1	22	1
27	1	16	1
28	1	16	1
29	2	18	1
30	2	17	1
31	1	16	1
32	1	18	1
33	2	18	1
34	2	20	1
35	2	20	1
36	1	17	1
37	2	17	1
38	2	17	1
39	1	20	1
40	1	20	1
41	2	17	1
42	2	23	1
43	1	20	1
44	2	27	2
45	1	28	2
46	2	20	1
47	2	18	1
48	1	19	1
49	2	27	2
50	2	23	1
51	2	26	2
52	2	27	2
53	2	23	1
54	2	27	2
55	2	25	2
56	2	26	2
57	1	28	2
58	2	27	2
59	2	28	2
60	2	25	2
61	2	24	2
62	2	23	1
63	1	23	1
64	1	24	2
65	1	26	2
66	1	25	2
67	2	16	1
68	2	21	1
69	1	18	1
70	2	19	1

Nº Projeto	Sexo	Idade	Intervalo Idades
71	1	21	1
72	2	16	1
73	1	18	1
74	1	17	1
75	2	20	1
76	1	18	1
77	2	21	1
78	2	16	1
79	2	16	1
80	1	18	1
81	2	17	1
82	1	18	1
83	1	21	1
84	1	19	1
85	2	19	1
86	2	17	1
87	1	16	1
88	2	16	1
89	2	20	1
90	2	17	1
91	2	16	1
92	1	19	1
93	1	18	1
94	1	21	1
95	2	21	1
96	2	17	1
97	2	18	1
98	2	20	1
99	1	20	1
100	2	16	1
101	1	19	1
102	2	19	1
103	2	18	1
104	1	16	1
105	1	21	1
106	1	29	2
107	2	28	2
108	1	29	2
109	1	26	2
110	1	28	2
111	1	24	2
112	2	22	1
113	2	25	2
114	2	27	2
115	1	25	2
116	2	25	2
117	2	26	2
118	1	28	2
119	1	29	2
120	2	23	1
121	1	24	2
122	2	27	2
123	2	28	2
124	1	16	1
125	2	25	2
126	2	24	2
127	2	21	1
128	2	16	1
129	2	24	2
130	2	19	1
131	1	17	1
132	1	27	2
133	2	17	1
134	1	28	2
135	2	29	2
136	2	17	1
137	2	27	2
138	1	16	1
139	1	28	2
140	2	19	1

Nº Projeto	Sexo	Idade	Intervalo Idades
141	2	26	2
142	2	18	1
143	2	23	1
144	2	20	1
145	2	16	1
146	1	22	1
147	2	17	1
148	2	18	1
149	2	27	2
150	2	19	1
151	1	25	2
152	2	17	1
153	1	26	2
154	1	23	1
155	1	26	2
156	2	29	2
157	2	18	1
158	2	17	1
159	2	18	1
160	2	18	1
161	1	17	1
162	2	16	1
163	1	19	1
164	1	18	1
165	2	19	1
166	2	16	1
167	1	16	1
168	2	16	1
169	2	20	1
170	2	17	1
171	2	24	2
172	1	24	2
173	2	24	2
174	2	26	2
175	1	23	1
176	2	22	1
177	2	22	1
178	2	23	1
179	1	27	2
180	2	26	2
181	2	23	1
182	1	23	1
183	2	25	2
184	2	23	1
185	1	27	2
186	2	21	1
187	1	27	2
188	1	26	2
189	2	21	1
190	1	21	1
191	1	26	2
192	1	23	1
193	1	23	1
194	1	25	2
195	2	24	2
196	2	25	2
197	2	24	2
198	1	23	1
199	1	22	1
200	2	26	2
201	1	16	1
202	2	18	1
203	2	18	1
204	2	20	1
205	2	17	1
206	1	16	1
207	1	19	1
208	2	18	1
209	1	18	1
210	1	20	1

Nº Projeto	Sexo	Idade	Intervalo Idades
211	2	20	1
212	1	16	1
213	2	16	1
214	1	27	2
215	1	17	1
216	2	17	1
217	1	16	1
218	2	20	1
219	1	25	2
220	2	17	1
221	2	18	1
222	1	26	2
223	1	23	1
224	1	19	1
225	2	16	1
226	2	25	2
227	2	19	1
228	1	29	2
229	2	17	1
230	2	29	2
231	2	18	1
232	1	24	2
233	2	16	1
234	1	16	1
235	2	20	1
236	2	16	1
237	1	22	1
238	1	28	2
239	2	16	1
240	2	16	1
241	1	16	1
242	2	17	1
243	1	28	2
244	2	17	1
245	2	16	1
246	1	28	2
247	2	16	1
248	2	23	1
249	1	21	1
250	1	18	1
251	2	17	1
252	2	18	1
253	2	17	1
254	2	19	1
255	2	16	1
256	2	26	2
257	2	16	1
258	2	16	1
259	2	21	1
260	2	17	1
261	2	16	1
262	2	16	1
263	2	17	1
264	2	16	1
265	2	16	1
266	2	18	1
267	2	18	1
268	2	17	1
269	2	18	1
270	1	28	2
271	2	17	1
272	2	18	1
273	2	18	1
274	2	16	1
275	2	17	1
276	2	17	1
277	2	17	1
278	1	16	1
279	2	18	1
280	2	17	1

Nº Projeto	Sexo	Idade	Intervalo Idades
281	1	16	1
282	2	16	1
283	1	17	1
284	2	16	1
285	1	26	2
286	2	17	1
287	1	17	1
288	2	18	1
289	1	16	1
290	1	16	1
291	1	16	1
292	1	16	1
293	2	18	1
294	1	17	1
295	1	17	1
296	2	28	2
297	2	17	1
298	2	16	1
299	1	19	1
300	2	16	1
301	1	16	1
302	2	28	2
303	2	17	1
304	2	28	2
305	2	26	2
306	1	25	2
307	1	23	1
308	2	24	2
309	2	28	2
310	1	29	2
311	1	20	1
312	1	24	2
313	1	21	1
314	2	19	1
315	2	22	1
316	2	24	2
317	1	25	2
318	1	24	2
319	2	22	1
320	1	26	2
321	2	23	1
322	2	21	1
323	1	23	1
324	1	21	1
325	2	23	1
326	2	20	1
327	1	22	1
328	2	25	2
329	1	25	2
330	2	23	1
331	1	25	2
332	2	24	2
333	2	21	1
334	2	22	1
335	2	25	2
336	1	22	1
337	2	16	1
338	1	18	1
339	2	16	1
340	2	17	1
341	1	17	1
342	2	16	1
343	2	16	1
344	1	17	1
345	2	16	1
346	2	17	1
347	2	17	1
348	1	17	1
349	1	16	1
350	1	16	1

Nº Projeto	Sexo	Idade	Intervalo Idades
351	2	16	1
352	2	17	1
353	2	16	1
354	2	16	1
355	1	16	1
356	2	17	1
357	2	16	1
358	2	16	1
359	1	16	1
360	2	16	1
361	1	30	2
362	1	30	2
363	2	30	2
364	2	30	2
365	1	30	2
366	1	30	2
367	1	30	2
368	2	30	2
369	2	30	2
370	1	30	2
371	1	30	2
372	2	30	2
373	2	18	1
374	1	21	1
375	2	19	1
376	1	19	1
377	2	17	1
378	2	17	1
379	2	24	2
380	1	23	1
381	1	24	2
382	2	23	1
383	2	17	1
384	2	30	2
385	1	30	2
386	2	30	2
387	1	30	2
388	2	30	2
389	2	30	2
390	1	30	2
391	1	30	2
392	1	30	2
393	1	30	2
394	1	30	2
395	1	30	2
396	2	30	2
397	2	30	2
398	2	30	2
399	2	30	2
400	2	30	2
401	1	30	2
402	2	30	2
403	1	25	2
404	1	17	1
405	1	19	1
406	2	23	1
407	1	19	1
408	2	20	1
409	1	22	1
410	2	23	1
411	1	21	1
412	2	23	1
413	2	21	1
414	1	19	1
415	2	20	1
416	2	24	2
417	1	22	1
418	2	21	1
419	1	19	1
420	1	21	1

Nº Projeto	Sexo	Idade	Intervalo Idades
421	1	23	1
422	1	18	1
423	2	24	2
424	1	23	1
425	1	20	1
426	2	21	1
427	2	18	1
428	2	23	1
429	1	23	1
430	2	21	1
431	1	19	1
432	1	20	1
433	2	23	1
434	2	19	1
435	1	22	1
436	2	22	1
437	1	24	2
438	1	22	1
439	2	20	1
440	1	19	1
441	2	23	1
442	1	21	1
443	1	16	1
444	1	24	2
445	1	23	1
446	1	21	1
447	1	19	1
448	2	23	1
449	2	20	1
450	2	18	1
451	1	18	1
452	2	22	1
453	2	22	1
454	2	21	1
455	2	19	1
456	2	18	1
457	1	20	1
458	2	22	1
459	2	20	1
460	1	21	1
461	2	19	1
462	2	20	1
463	2	20	1
464	2	18	1
465	2	19	1
466	2	18	1
467	2	21	1
468	1	20	1
469	1	22	1
470	2	20	1
471	1	21	1
472	1	21	1
473	2	21	1
474	1	21	1
475	1	16	1
476	1	17	1
477	2	26	2
478	1	18	1
479	1	19	1
480	1	20	1
481	1	18	1
482	1	19	1
483	1	20	1
484	2	21	1
485	2	23	1
486	1	18	1
487	1	17	1
488	2	20	1
489	1	20	1
490	1	23	1

Nº Projeto	Sexo	Idade	Intervalo Idades
491	1	21	1
492	2	20	1
493	2	22	1
494	2	30	2
495	1	30	2
496	1	30	2
497	2	30	2
498	2	30	2
499	1	30	2
500	2	30	2
501	2	30	2
502	1	30	2
503	2	30	2
504	1	26	2
505	2	30	2
506	2	30	2
507	2	30	2
508	1	30	2
509	2	30	2
510	1	30	2
511	2	30	2
512	1	30	2
513	1	30	2
514	2	30	2
515	2	30	2
516	2	30	2
517	2	30	2
518	2	30	2
519	1	30	2
520	1	30	2
521	1	30	2
522	2	30	2
523	1	30	2
524	1	30	2
525	1	30	2
526	1	30	2
527	1	30	2
528	2	26	2
529	2	30	2
530	2	30	2
531	2	30	2
532	1	30	2
533	1	30	2
534	2	30	2
535	2	29	2
536	2	19	1
537	2	21	1
538	2	18	1
539	1	19	1
540	2	18	1
541	2	19	1
542	1	16	1
543	2	19	1
544	2	23	1
545	2	18	1
546	1	20	1
547	1	17	1
548	2	21	1
549	1	22	1
550	1	19	1
551	2	21	1
552	1	22	1
553	2	22	1
554	2	20	1
555	2	20	1
556	1	30	2
557	1	30	2
558	1	30	2
559	1	30	2
560	1	30	2

Nº Projeto	Sexo	Idade	Intervalo Idades
561	2	30	2
562	1	30	2
563	1	17	1
564	2	19	1
565	1	19	1
566	1	19	1
567	1	20	1
568	2	19	1
569	1	16	1
570	2	21	1
571	1	17	1
572	2	21	1
573	1	18	1
574	1	19	1
575	1	20	1
576	2	21	1
577	2	20	1
578	2	21	1
579	2	20	1
580	2	19	1
581	2	23	1
582	1	22	1
583	2	22	1
584	2	22	1
585	1	22	1
586	1	22	1
587	1	21	1
588	1	21	1
589	2	22	1
590	1	16	1
591	2	21	1
592	2	20	1
593	1	18	1
594	2	22	1
595	2	20	1
596	1	19	1
597	1	17	1
598	2	20	1
599	1	17	1
600	2	18	1
601	1	16	1
602	1	18	1
603	1	22	1
604	1	18	1
605	1	20	1
606	1	17	1
607	1	20	1
608	1	16	1
609	1	22	1
610	2	18	1
611	2	19	1
612	1	16	1
613	1	20	1
614	1	20	1
615	1	20	1
616	1	18	1
617	1	20	1
618	1	29	2
619	1	29	2
620	1	29	2
621	2	29	2
622	2	29	2
623	2	29	2
624	2	29	2
625	1	29	2
626	1	29	2
627	1	29	2
628	2	29	2
629	2	29	2
630	1	29	2

Nº Projeto	Sexo	Idade	Intervalo Idades
631	2	29	2
632	1	29	2
633	2	29	2
634	1	29	2
635	1	29	2
636	2	29	2
637	2	29	2
638	2	29	2
639	2	29	2
640	1	29	2
641	1	29	2
642	2	29	2
643	1	29	2
644	1	29	2
645	2	29	2
646	2	29	2
647	1	29	2
648	2	29	2
649	2	29	2
650	1	29	2
651	1	26	2
652	1	29	2
653	1	29	2
654	2	29	2
655	1	29	2
656	1	29	2
657	2	26	2
658	1	29	2
659	2	29	2
660	2	29	2
661	1	26	2
662	2	29	2
663	2	29	2
664	1	29	2
665	2	29	2
666	2	29	2
667	2	29	2
668	1	29	2
669	1	29	2
670	1	26	2
671	2	29	2
672	1	29	2
673	1	29	2
674	2	29	2
675	1	29	2
676	2	29	2
677	1	21	1
678	2	19	1
679	1	18	1
680	2	18	1
681	2	18	1
682	1	17	1
683	1	21	1
684	1	20	1
685	1	21	1
686	2	21	1
687	2	21	1
688	1	18	1
689	1	17	1
690	1	19	1
691	1	19	1
692	1	16	1
693	1	20	1
694	2	21	1
695	1	19	1
696	1	17	1
697	1	17	1
698	1	19	1
699	1	18	1
700	1	19	1

Nº Projeto	Sexo	Idade	Intervalo Idades
701	1	20	1
702	2	20	1
703	1	20	1
704	2	20	1
705	1	18	1
706	1	17	1
707	1	17	1
708	2	28	2
709	1	17	1
710	2	28	2
711	2	28	2
712	1	28	2
713	1	18	1
714	1	28	2
715	1	28	2
716	2	28	2
717	2	28	2
718	2	28	2
719	1	26	2
720	1	28	2
721	2	28	2
722	1	18	1
723	1	17	1
724	2	28	2
725	1	28	2
726	1	17	1
727	1	28	2
728	1	17	1
729	1	28	2
730	1	28	2
731	1	28	2
732	1	18	1
733	1	18	1
734	2	28	2
735	1	28	2
736	1	18	1
737	1	28	2
738	2	28	2
739	1	28	2
740	1	28	2
741	2	20	1
742	1	20	1
743	2	20	1
744	1	20	1
745	1	28	2
746	1	28	2
747	1	28	2
748	1	20	1
749	1	20	1
750	1	20	1
751	1	20	1
752	1	20	1
753	1	27	2
754	2	27	2
755	1	27	2
756	2	27	2
757	2	27	2
758	1	28	2
759	2	28	2
760	1	28	2
761	1	28	2
762	1	27	2
763	1	28	2
764	1	28	2
765	2	28	2
766	1	28	2
767	2	28	2
768	1	28	2
769	2	28	2
770	2	28	2

Nº Projeto	Sexo	Idade	Intervalo Idades
771	2	28	2
772	2	28	2
773	2	28	2
774	2	27	2
775	2	27	2
776	2	27	2
777	2	27	2
778	1	27	2
779	1	27	2
780	2	27	2
781	2	28	2
782	2	28	2
783	2	28	2
784	1	27	2
785	2	28	2
786	2	28	2
787	2	28	2
788	2	27	2
789	2	19	1
790	1	27	2
791	2	27	2
792	1	19	1
793	2	27	2
794	1	27	2
795	2	27	2
796	1	27	2
797	2	19	1
798	2	19	1
799	2	27	2
800	2	19	1
801	2	19	1
802	2	27	2
803	2	19	1
804	1	27	2
805	2	27	2
806	1	27	2
807	2	19	1
808	1	27	2
809	2	27	2
810	2	19	1
811	2	19	1
812	2	19	1
813	2	19	1
814	1	27	2
815	2	27	2
816	2	27	2
817	2	27	2
818	2	27	2
819	1	27	2
820	1	27	2
821	1	27	2
822	1	27	2
823	1	27	2
824	1	27	2
825	2	27	2
826	1	26	2
827	1	26	2
828	1	26	2
829	1	26	2
830	1	26	2
831	1	27	2
832	1	26	2
833	2	26	2
834	2	26	2
835	1	26	2
836	2	26	2
837	1	26	2
838	2	27	2
839	2	26	2
840	2	26	2

Nº Projeto	Sexo	Idade	Intervalo Idades
841	2	26	2
842	2	26	2
843	1	26	2
844	2	26	2
845	2	26	2
846	2	27	2
847	2	26	2
848	1	27	2
849	2	26	2
850	2	26	2
851	2	26	2
852	2	26	2
853	1	27	2
854	1	26	2
855	2	26	2
856	2	26	2
857	2	26	2
858	1	26	2
859	1	27	2
860	1	26	2
861	1	26	2
862	2	26	2
863	2	26	2
864	1	26	2
865	1	27	2
866	1	26	2
867	1	27	2
868	2	26	2
869	1	27	2
870	2	26	2
871	1	27	2
872	2	26	2
873	1	27	2
874	1	27	2
875	1	26	2
876	1	26	2
877	1	26	2
878	1	26	2
879	1	26	2
880	1	21	1
881	2	21	1
882	1	21	1
883	1	21	1
884	2	21	1
885	2	21	1
886	2	21	1
887	1	21	1
888	1	21	1
889	2	21	1
890	1	21	1
891	2	21	1
892	1	21	1
893	1	21	1
894	2	25	2
895	1	25	2
896	2	25	2
897	2	25	2
898	2	25	2
899	2	25	2
900	2	25	2
901	2	25	2
902	1	25	2
903	1	25	2
904	1	25	2
905	1	25	2
906	2	25	2
907	1	25	2
908	1	25	2
909	1	25	2
910	2	25	2

Nº Projeto	Sexo	Idade	Intervalo Idades
911	1	25	2
912	1	25	2
913	2	25	2
914	2	25	2
915	2	25	2
916	2	25	2
917	2	25	2
918	2	25	2
919	2	25	2
920	2	25	2
921	1	25	2
922	2	25	2
923	1	25	2
924	2	25	2
925	2	25	2
926	1	25	2
927	1	25	2
928	1	25	2
929	2	25	2
930	1	25	2
931	2	25	2
932	1	25	2
933	1	25	2
934	1	25	2
935	1	25	2
936	1	25	2
937	1	25	2
938	1	25	2
939	1	25	2
940	2	27	2
941	1	21	1
942	1	21	1
943	2	24	2
944	1	24	2
945	1	24	2
946	1	24	2
947	2	24	2
948	1	24	2
949	1	24	2
950	2	24	2
951	2	24	2
952	1	24	2
953	2	24	2
954	1	24	2
955	2	24	2
956	2	24	2
957	2	24	2
958	1	24	2
959	2	24	2
960	2	24	2
961	2	24	2
962	1	24	2
963	1	24	2
964	2	24	2
965	2	24	2
966	1	24	2
967	1	24	2
968	2	24	2
969	1	24	2
970	2	24	2
971	1	24	2
972	2	24	2
973	2	24	2
974	2	24	2
975	1	24	2
976	2	24	2
977	1	24	2
978	2	22	1
979	2	22	1
980	2	22	1

Nº Projeto	Sexo	Idade	Intervalo Idades
981	1	22	1
982	1	22	1
983	2	22	1
984	2	22	1
985	2	22	1
986	1	22	1
987	2	22	1
988	1	22	1
989	2	22	1
990	1	24	2
991	1	22	1
992	2	24	2
993	1	22	1
994	1	22	1
995	1	24	2
996	2	22	1
997	2	22	1
998	2	24	2
999	1	22	1
1000	2	24	2
1001	2	24	2
1002	2	22	1
1003	2	22	1
1004	2	22	1
1005	1	24	2
1006	2	22	1
1007	2	22	1
1008	2	22	1
1009	1	24	2
1010	2	22	1
1011	1	24	2
1012	1	24	2
1013	1	22	1
1014	1	22	1
1015	1	24	2
1016	1	22	1
1017	1	22	1
1018	1	22	1
1019	1	24	2
1020	1	22	1
1021	1	22	1
1022	1	23	1
1023	2	23	1
1024	2	23	1
1025	2	23	1
1026	1	23	1
1027	2	23	1
1028	2	29	2
1029	2	23	1
1030	2	23	1
1031	1	23	1
1032	2	23	1
1033	1	23	1
1034	2	23	1
1035	1	23	1
1036	2	23	1
1037	2	23	1
1038	1	23	1
1039	1	23	1
1040	1	23	1
1041	1	23	1
1042	1	23	1
1043	1	23	1
1044	1	23	1
1045	1	23	1
1046	1	23	1
1047	1	23	1
1048	1	23	1
1049	1	23	1
1050	1	23	1

Anexo 3 – Análise Estatística Descritiva

I – Distribuição da Amostra por Sexo

II – Distribuição da Amostra por Sexo e Intervalo de Idades

Anexo 3, I – Distribuição da Amostra por Sexo

Sexo

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	F	516	49,1	49,1	49,1
	M	534	50,9	50,9	100,0
	Total	1050	100,0	100,0	

Anexo 3, II – Distribuição da Amostra por Sexo e Intervalo de Idades

Tabulação cruzada Intervalos de Idade 16-23 vs 24-30 * Sexo

		Sexo		
		F	M	Total
Faixas etárias 16-23 versus 24-30	16 a 23	272	293	565
	24 a 30	244	241	485
Total		516	534	1050

Anexo 4 – *Heatmaps* de Classificação de Idade

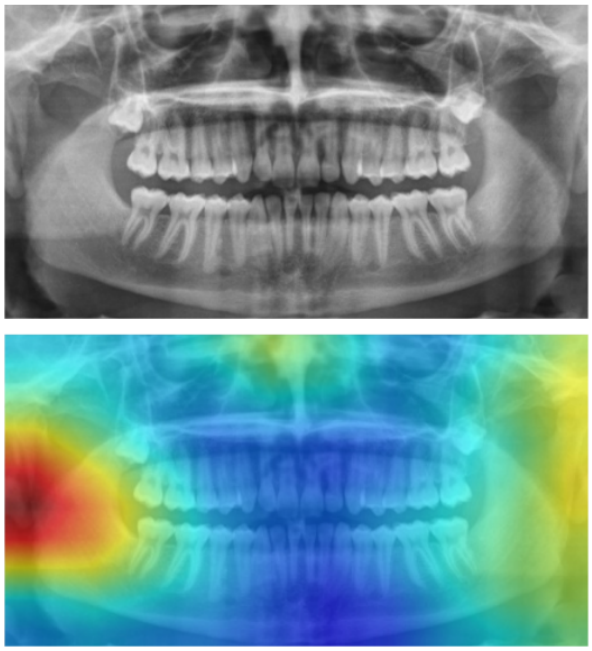
I – *Heatmaps* de OPG da classe “16_23” classificadas como “16_23”

II – *Heatmaps* de OPG da classe “16_23” classificadas como “24_30”

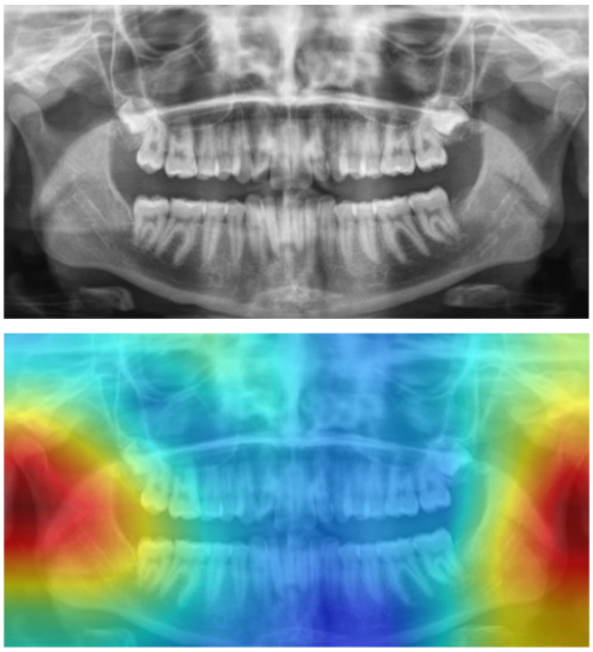
III – *Heatmaps* de OPG da classe “24_30” classificadas como “24_30”

IV – *Heatmaps* de OPG da classe “24_30” classificadas como “16_23”

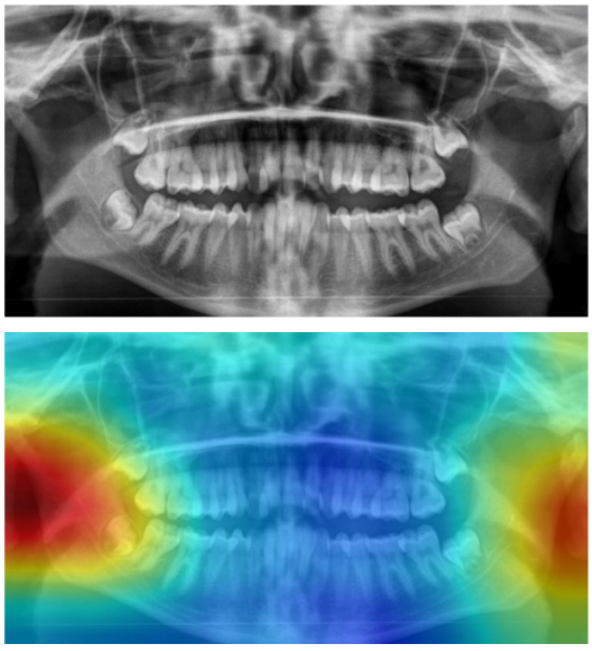
Anexo 4, I – *Heatmaps* de OPG da classe “16_23” classificadas como “16_23”



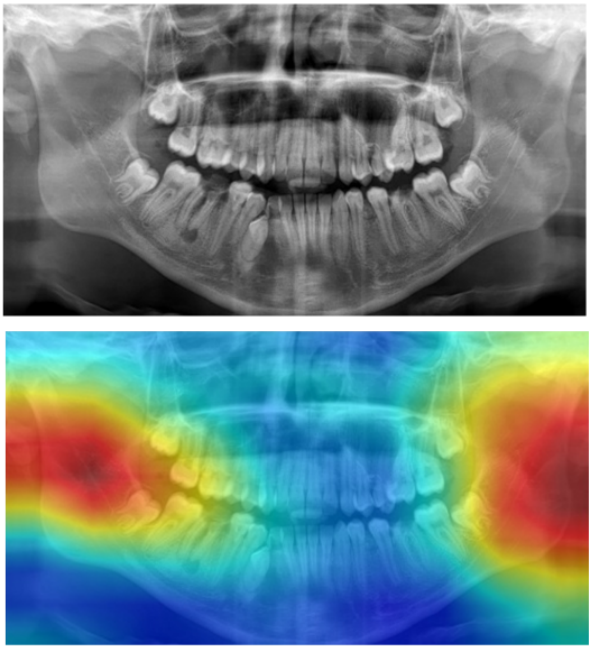
Model prediction: 0.6605
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



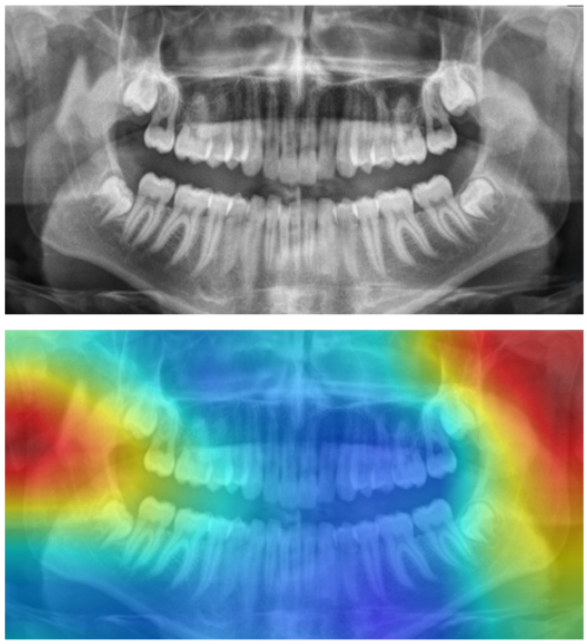
Model prediction: 0.7128
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



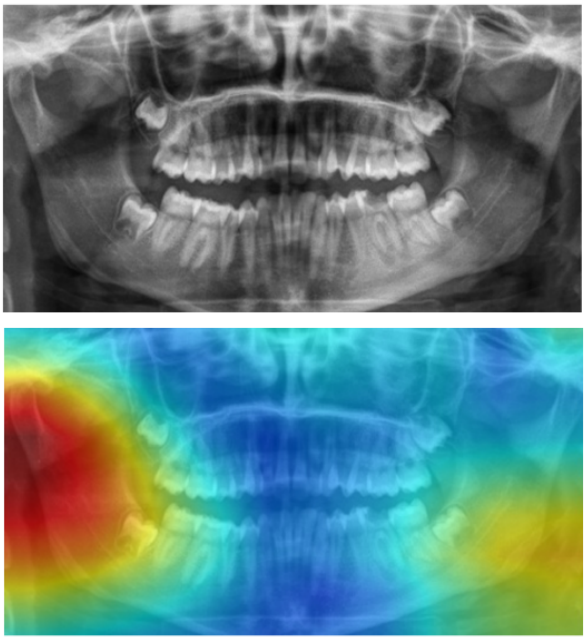
Model prediction: 0.7972
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



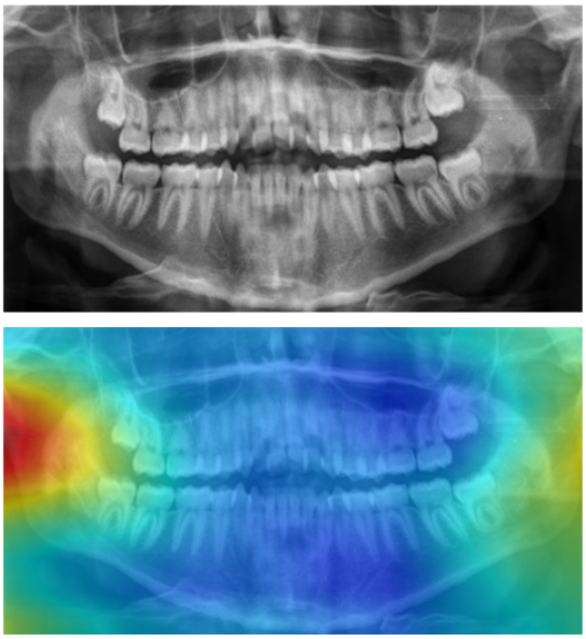
Model prediction: 0.6916
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



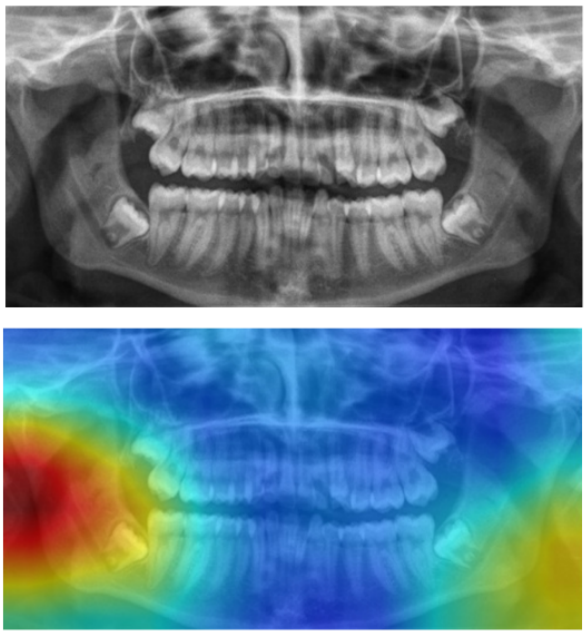
Model prediction: 0.6723
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



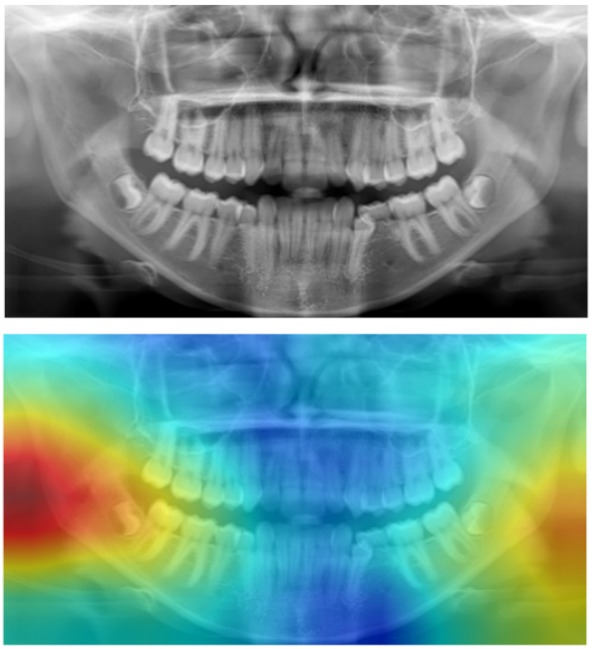
Model prediction: 0.7021
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



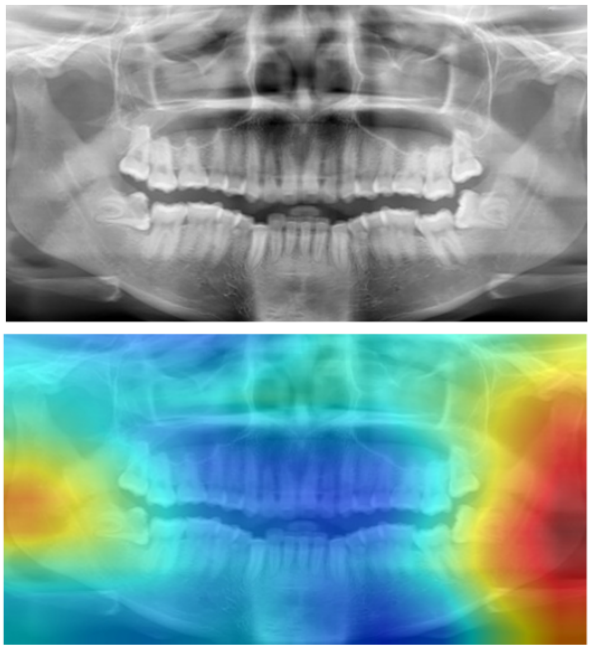
Model prediction: 0.7577
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



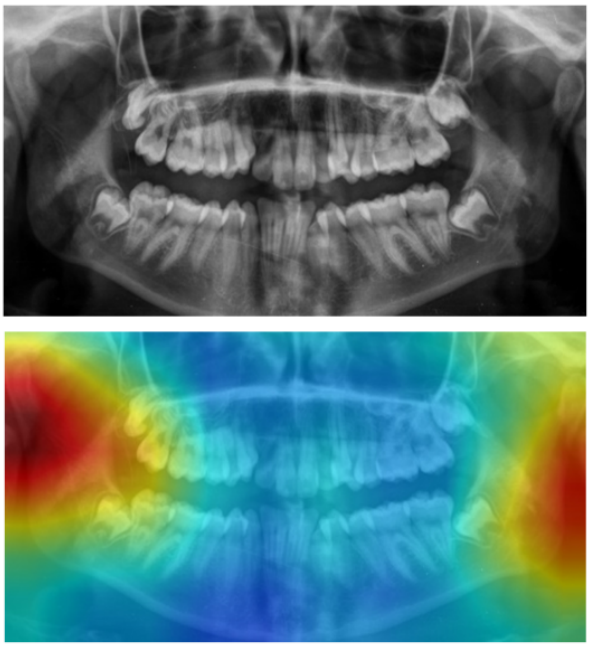
Model prediction: 0.7858
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



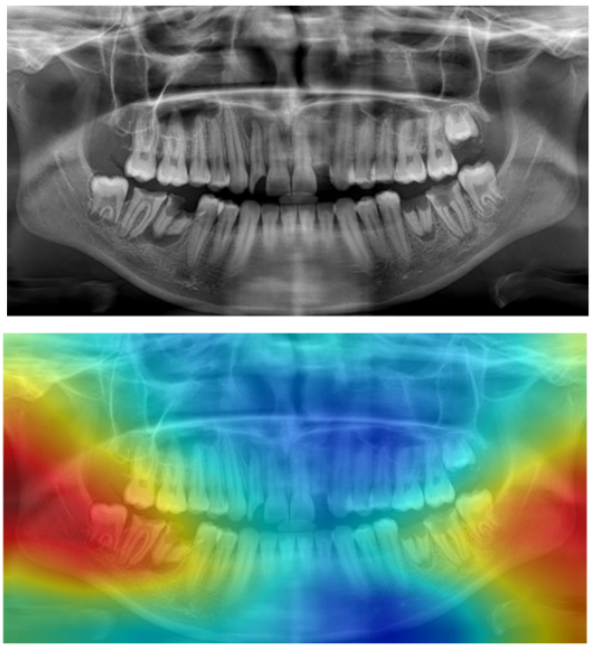
Model prediction: 0.6697
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



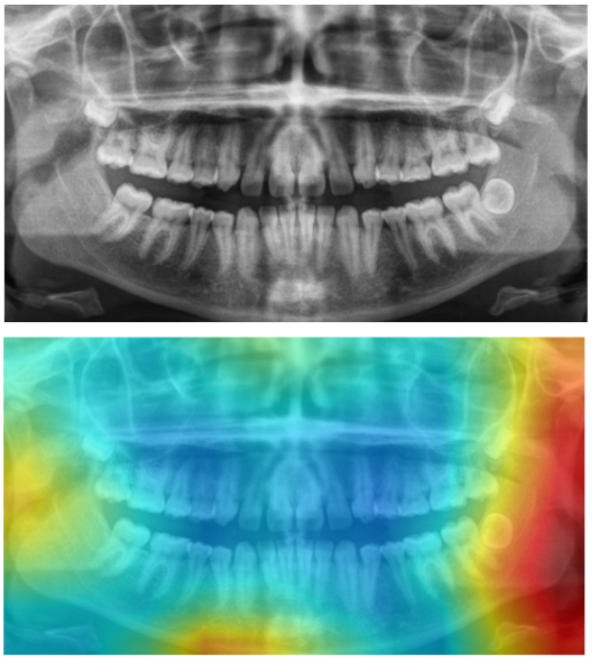
Model prediction: 0.6095
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



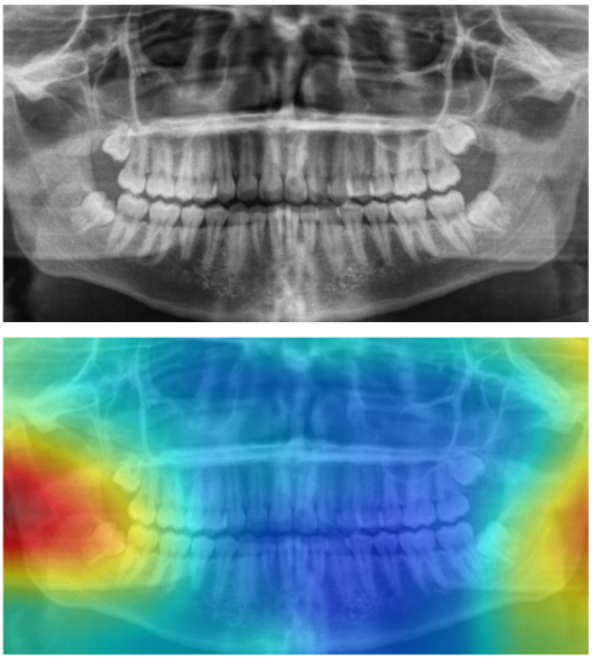
Model prediction: 0.8589
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



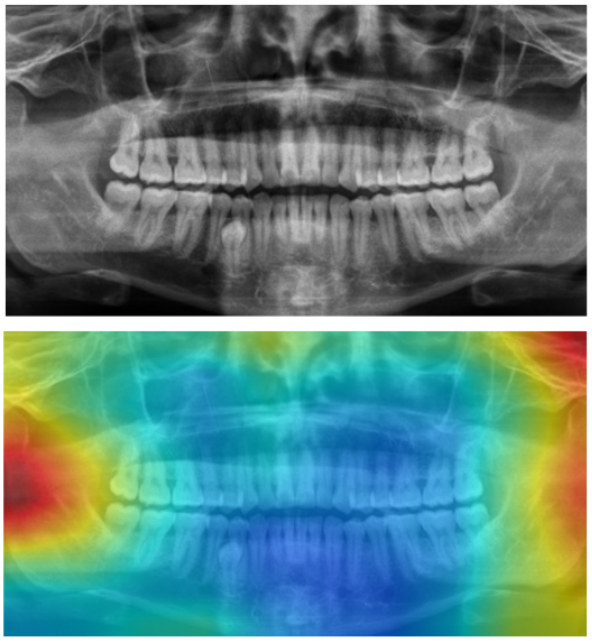
Model prediction: 0.6208
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



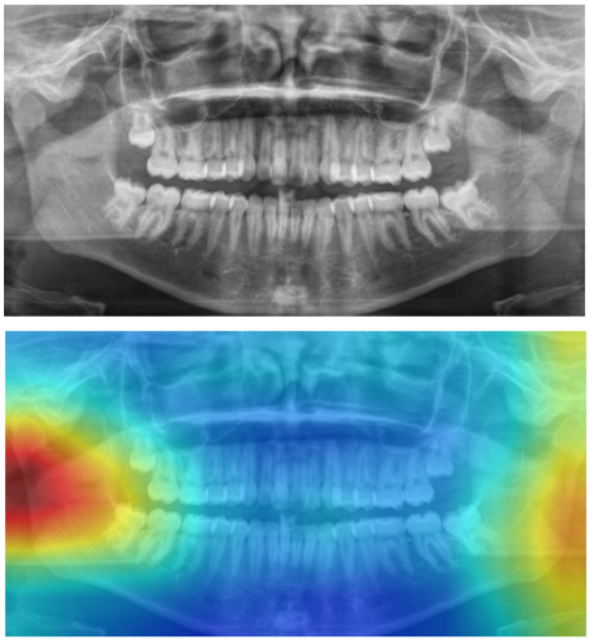
Model prediction: 0.5778
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



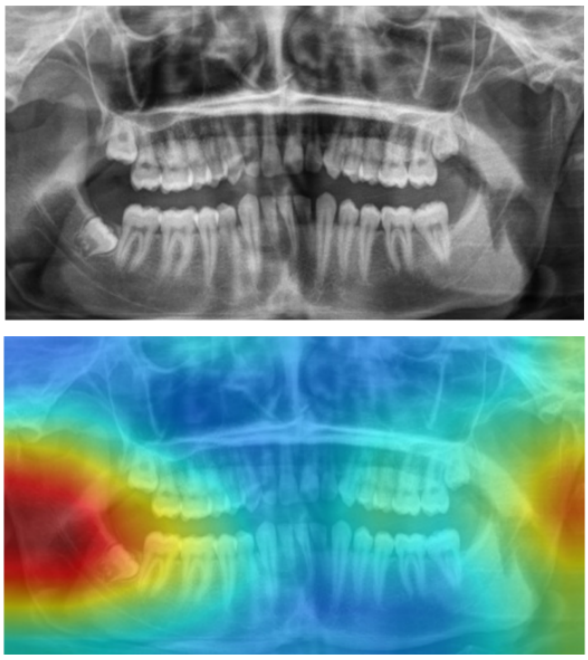
Model prediction: 0.8201
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



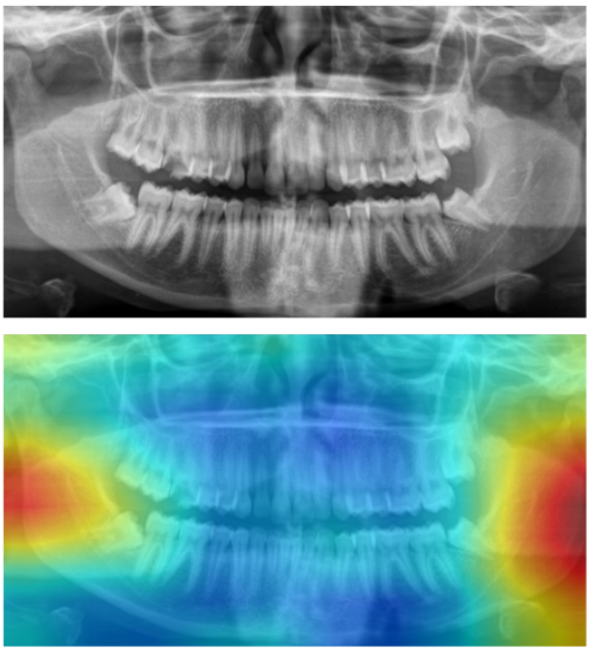
Model prediction: 0.6789
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



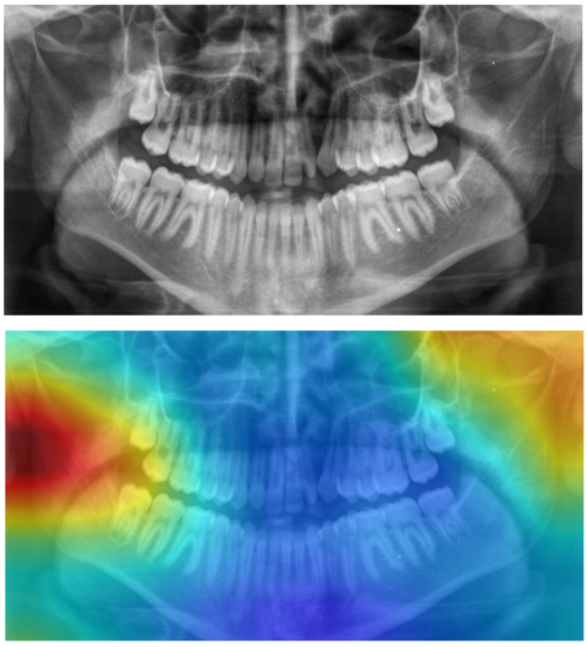
Model prediction: 0.7211
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



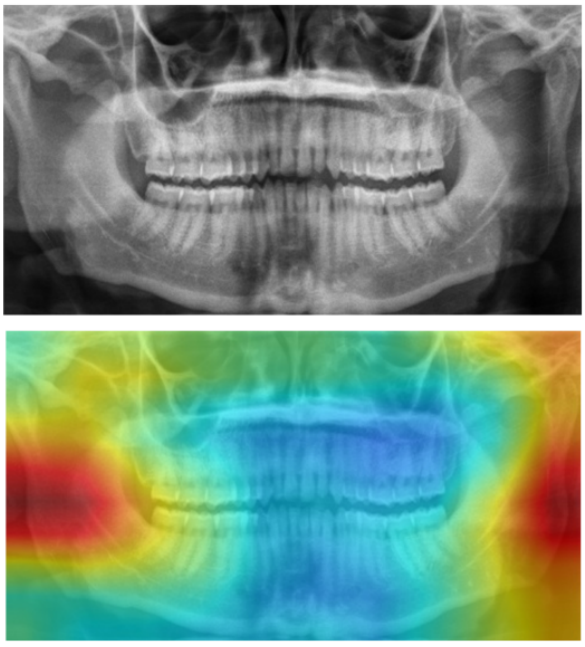
Model prediction: 0.6899
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



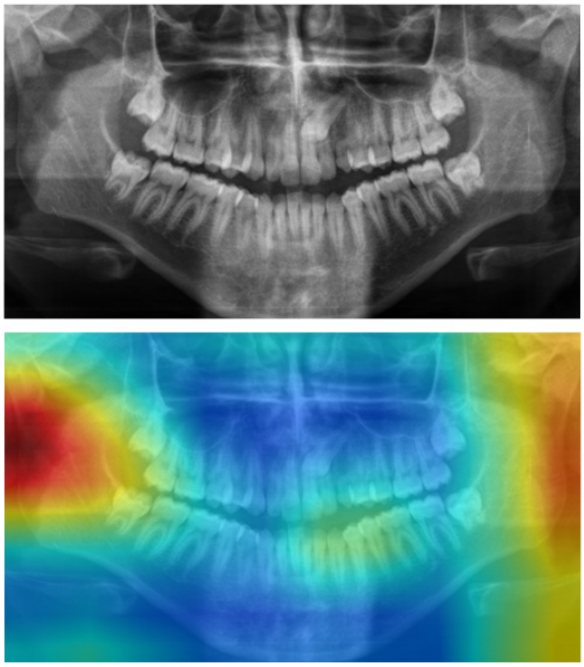
Model prediction: 0.6212
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



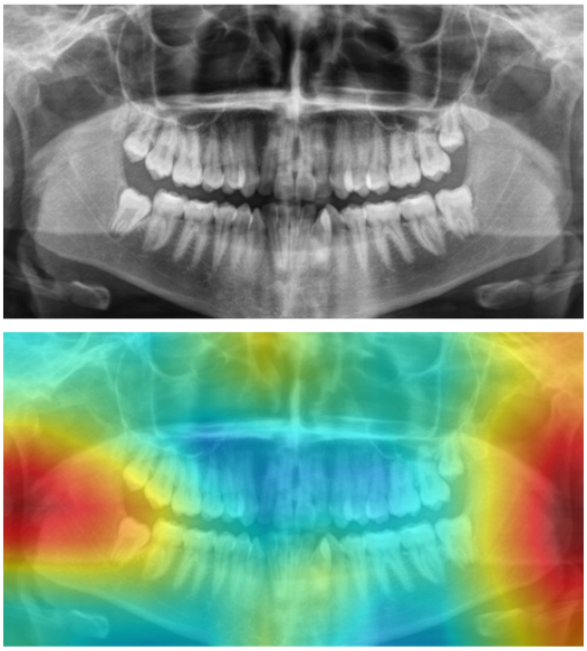
Model prediction: 0.8394
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



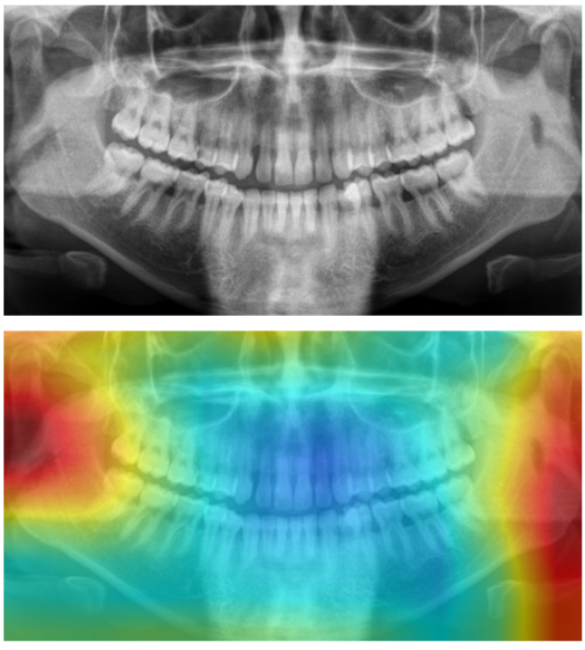
Model prediction: 0.5998
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



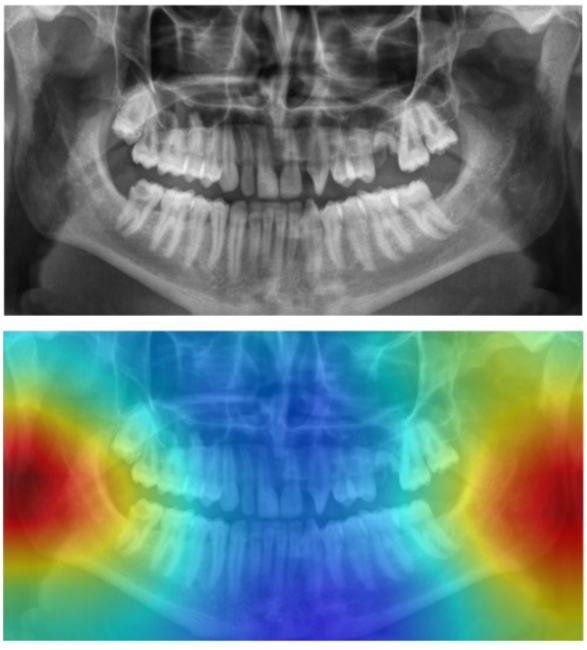
Model prediction: 0.7187
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



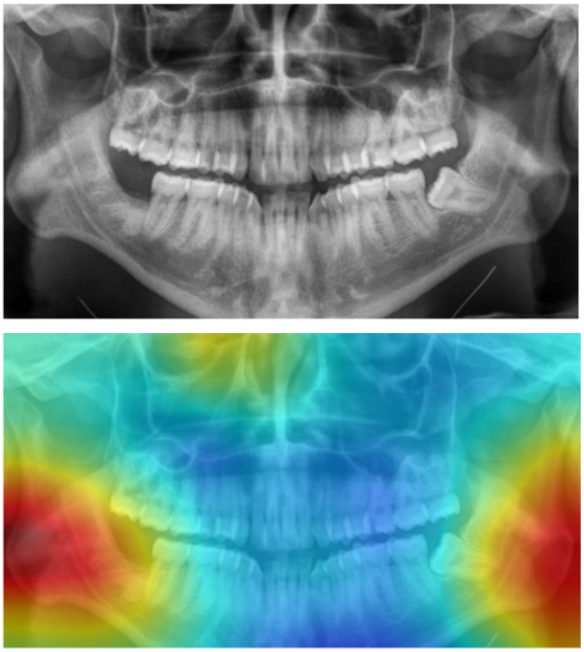
Model prediction: 0.6663
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



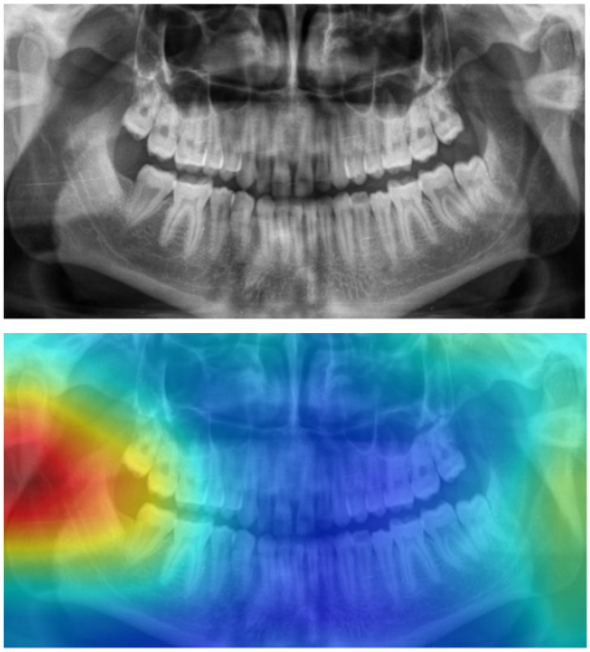
Model prediction: 0.6231
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



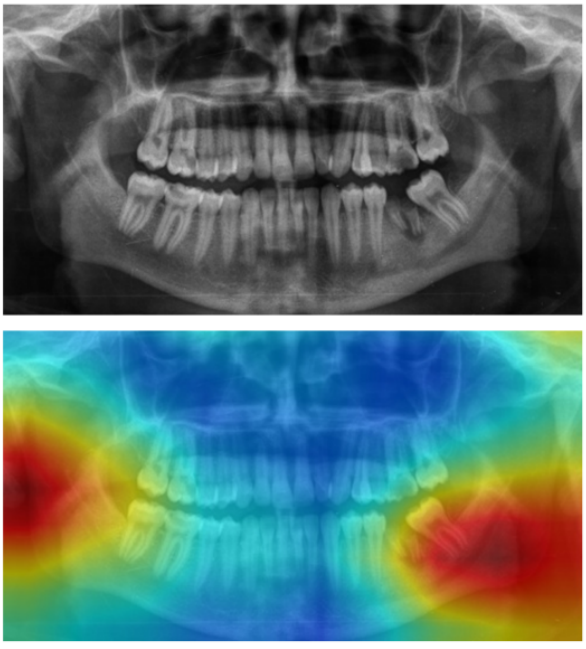
Model prediction: 0.7531
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



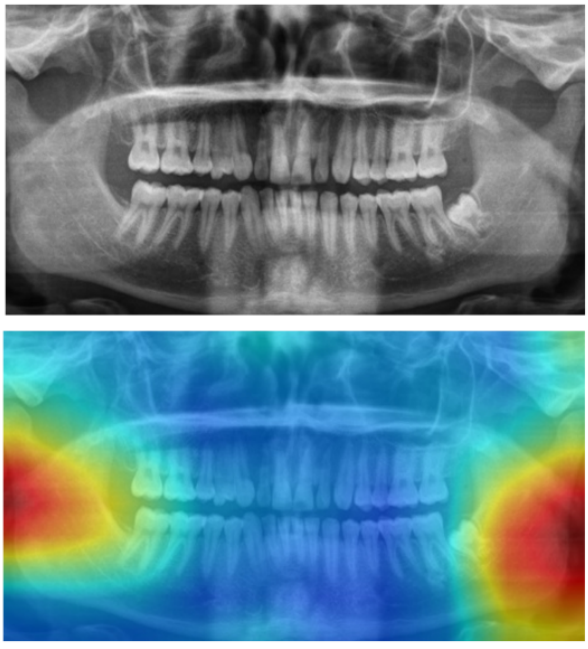
Model prediction: 0.7051
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



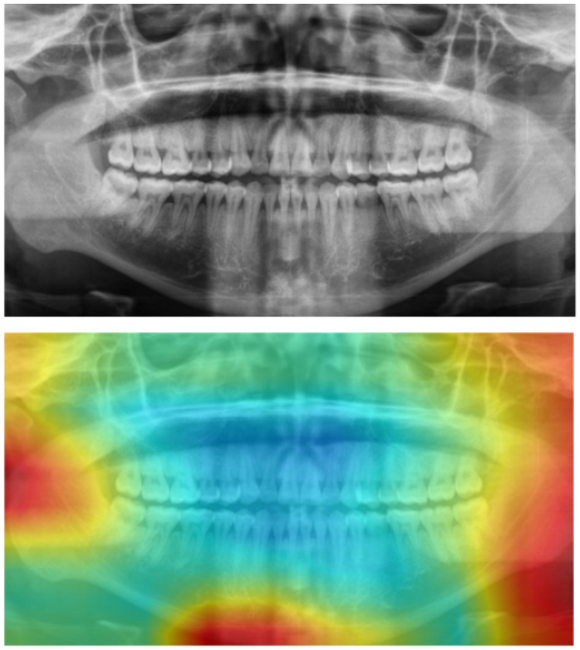
Model prediction: 0.8251
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



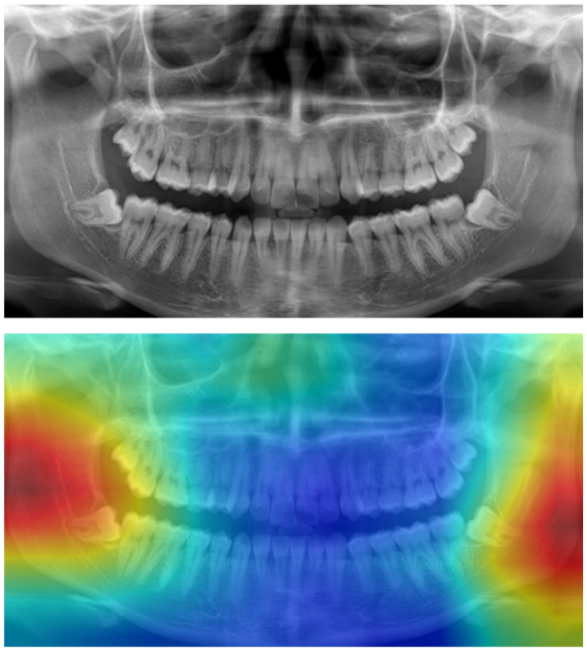
Model prediction: 0.5668
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



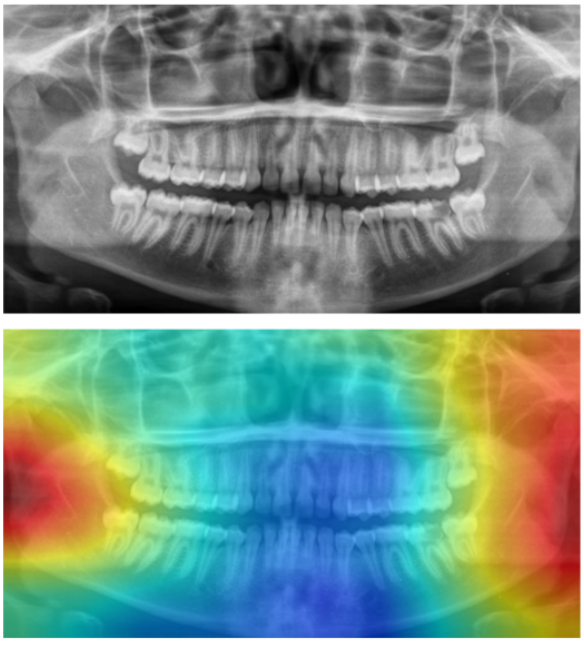
Model prediction: 0.6861
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



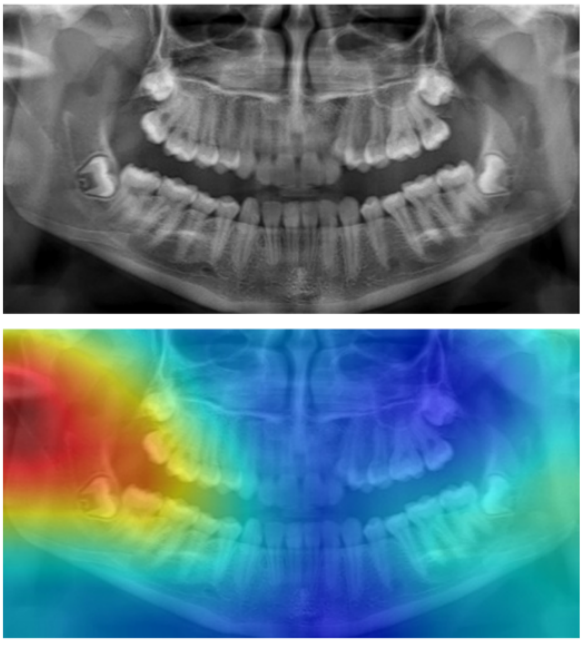
Model prediction: 0.5708
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



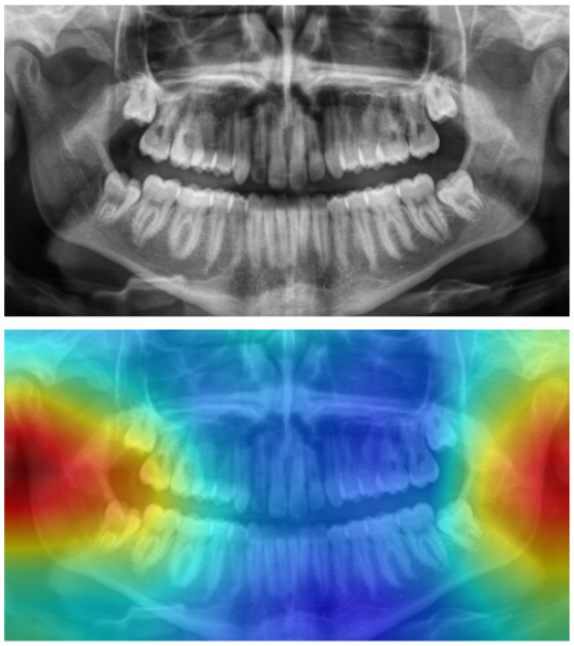
Model prediction: 0.8586
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



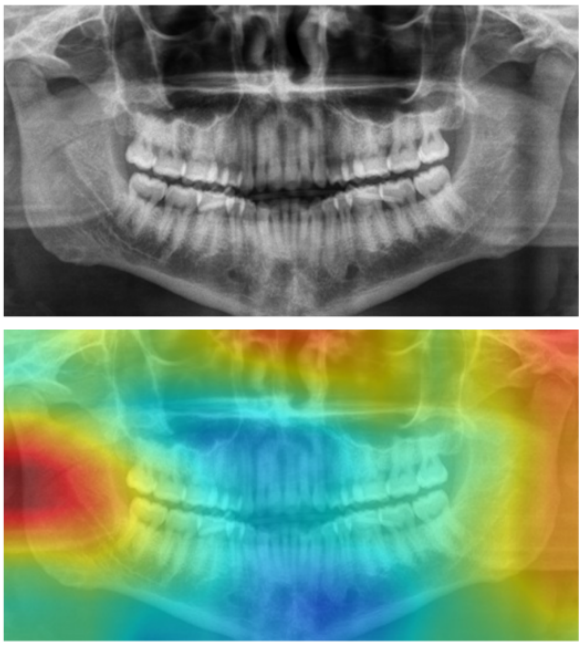
Model prediction: 0.6663
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



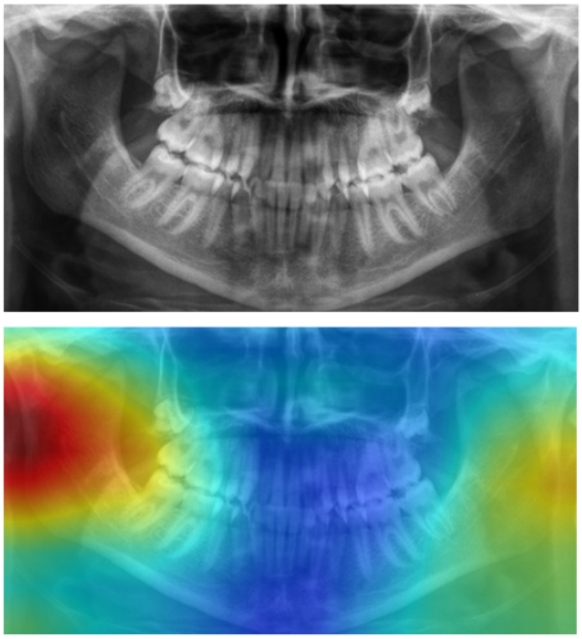
Model prediction: 0.8597
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



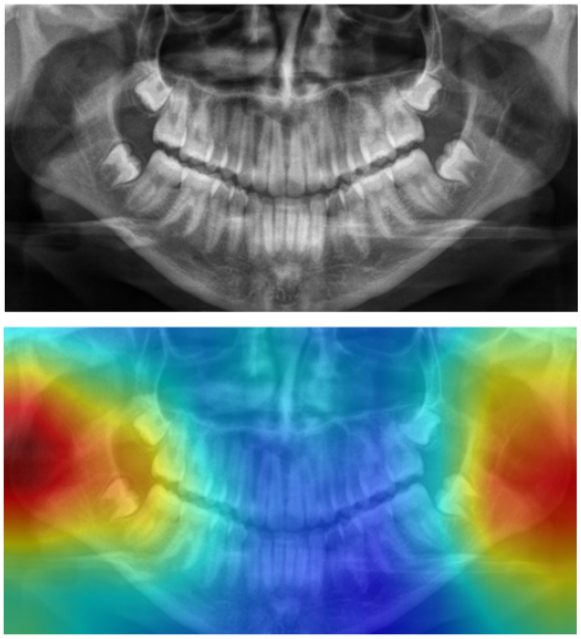
Model prediction: 0.8508
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



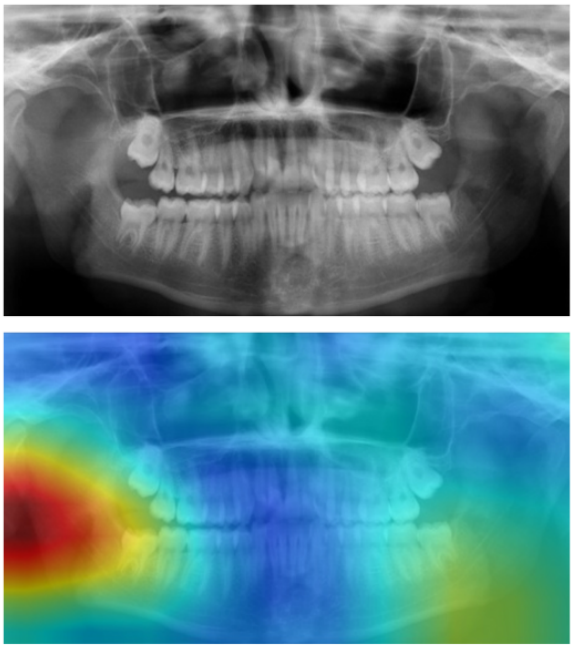
Model prediction: 0.501
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



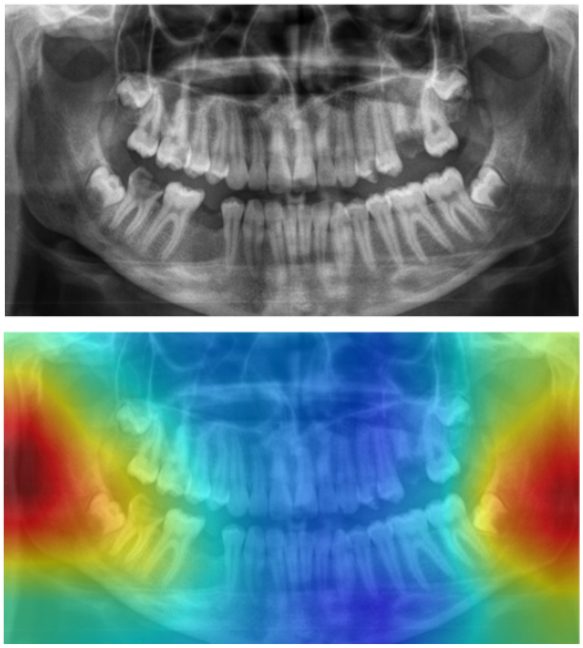
Model prediction: 0.8554
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



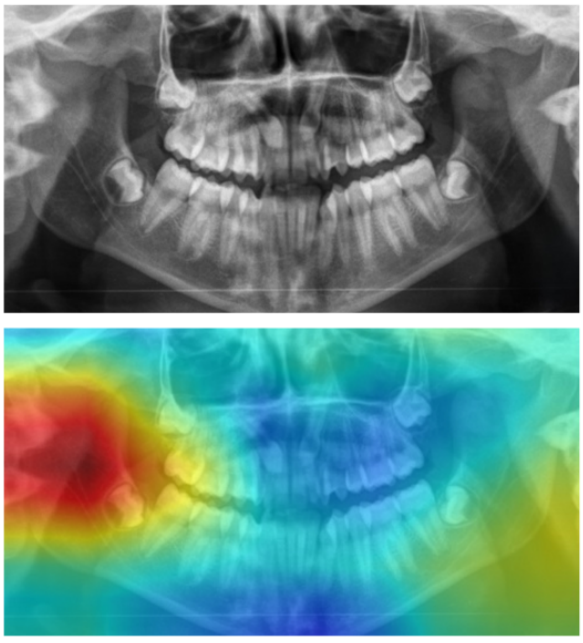
Model prediction: 0.8711
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



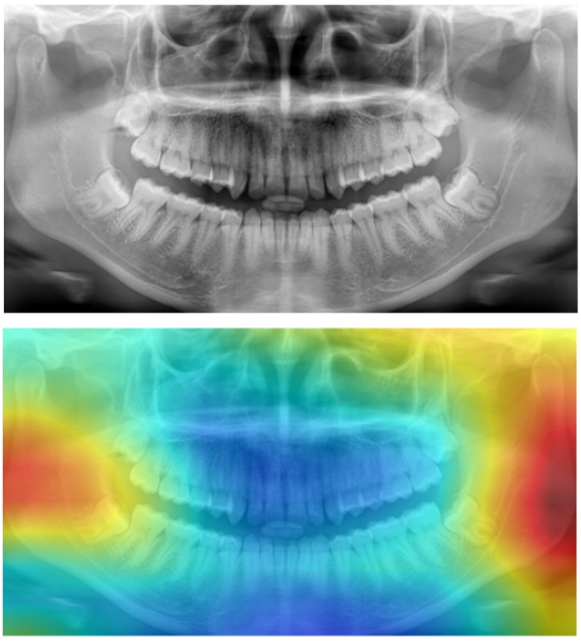
Model prediction: 0.6981
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



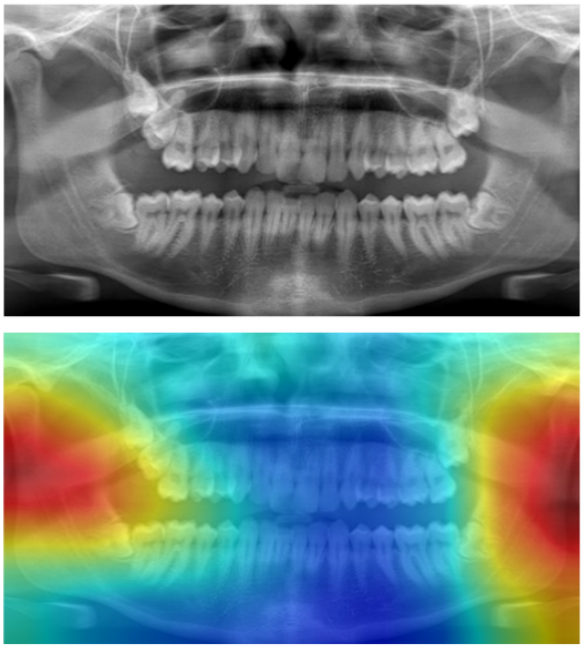
Model prediction: 0.7669
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



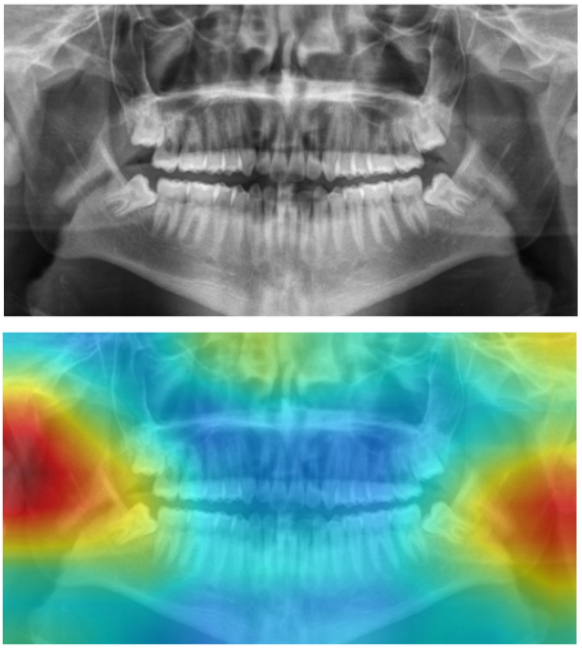
Model prediction: 0.7925
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



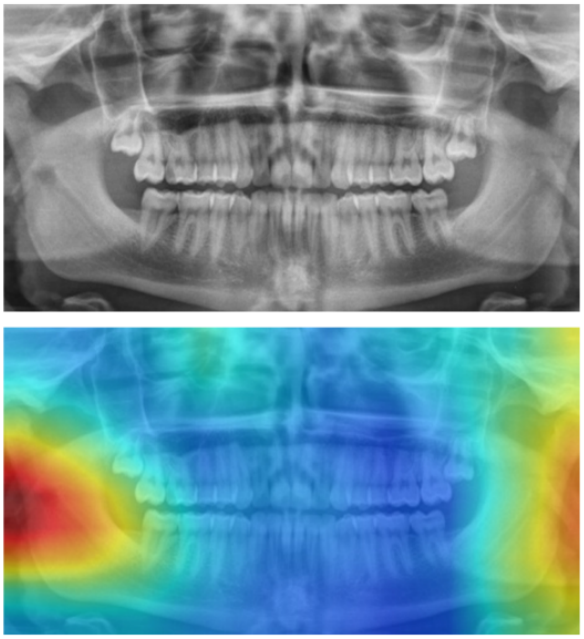
Model prediction: 0.6226
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



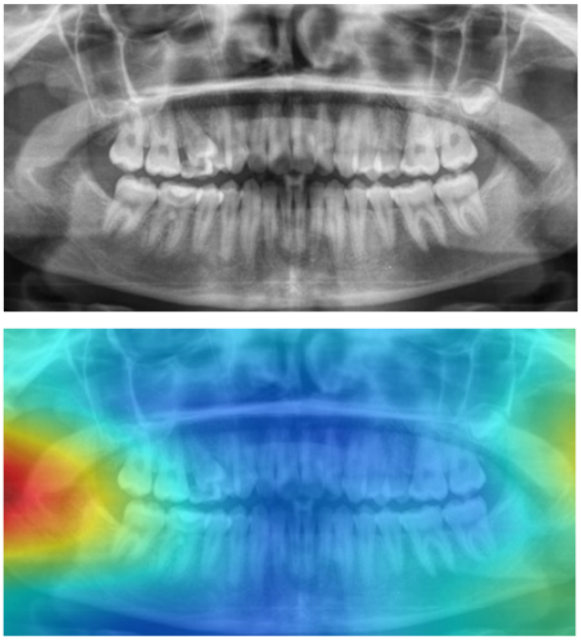
Model prediction: 0.7553
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



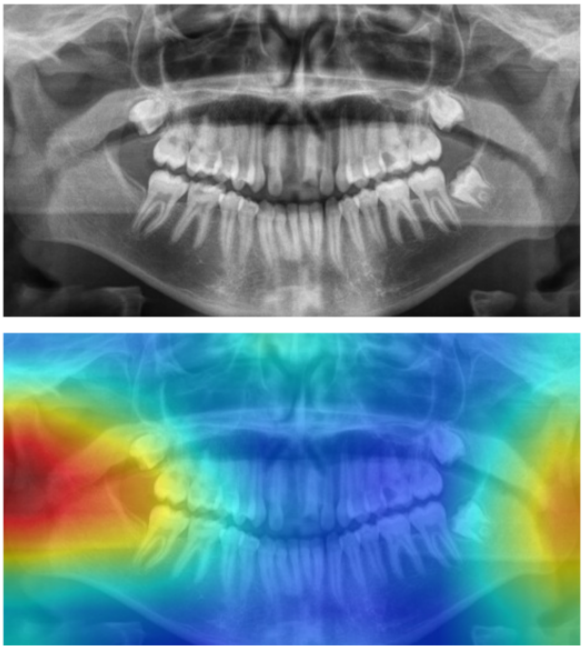
Model prediction: 0.724
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



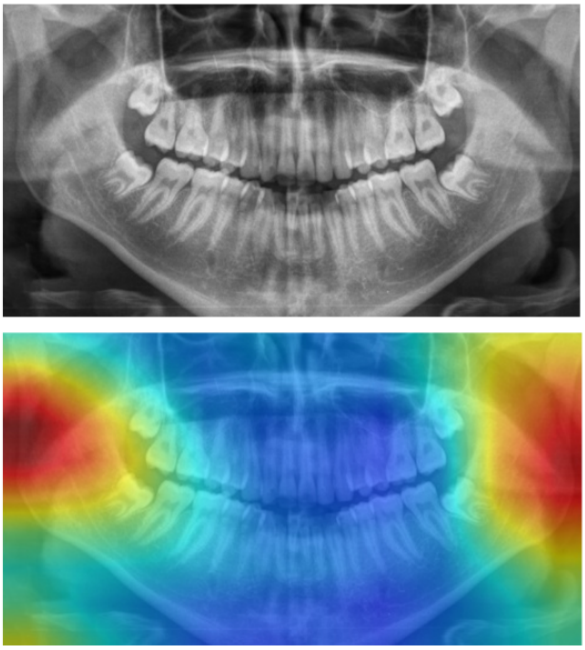
Model prediction: 0.7243
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



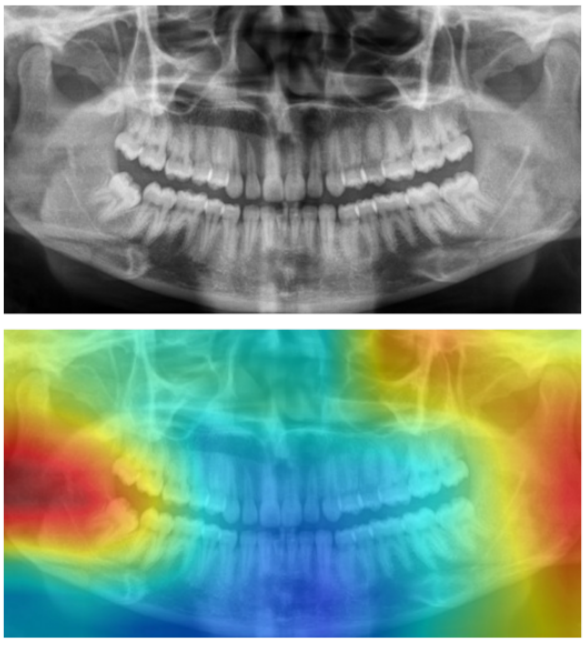
Model prediction: 0.6655
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



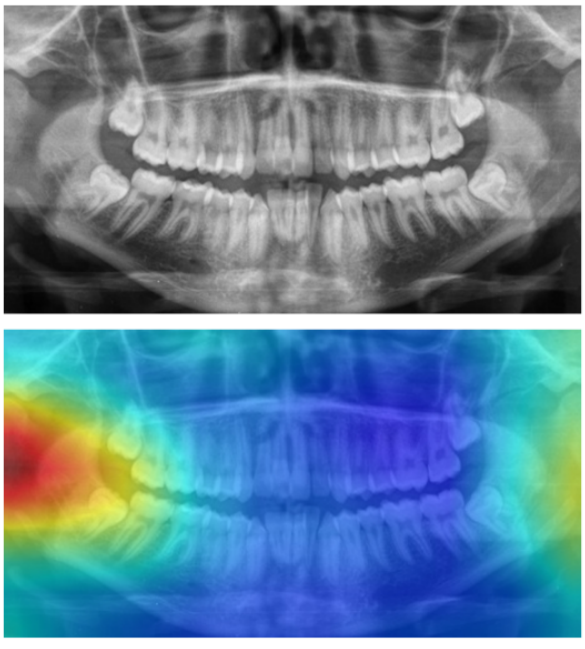
Model prediction: 0.8426
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



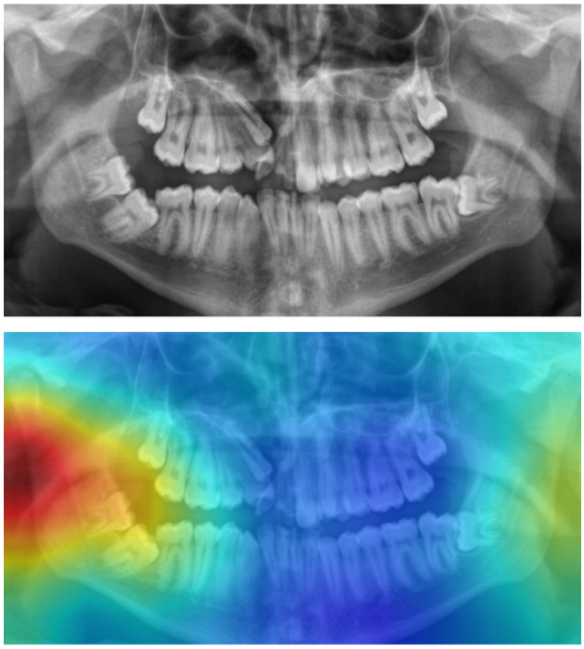
Model prediction: 0.805
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



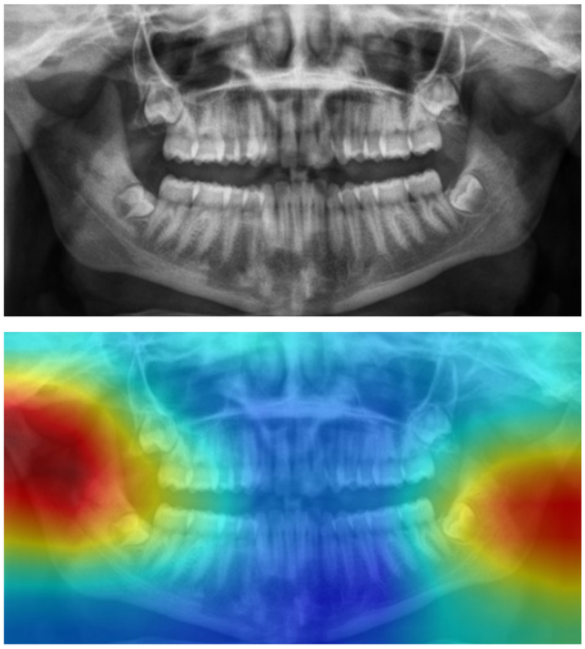
Model prediction: 0.6505
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



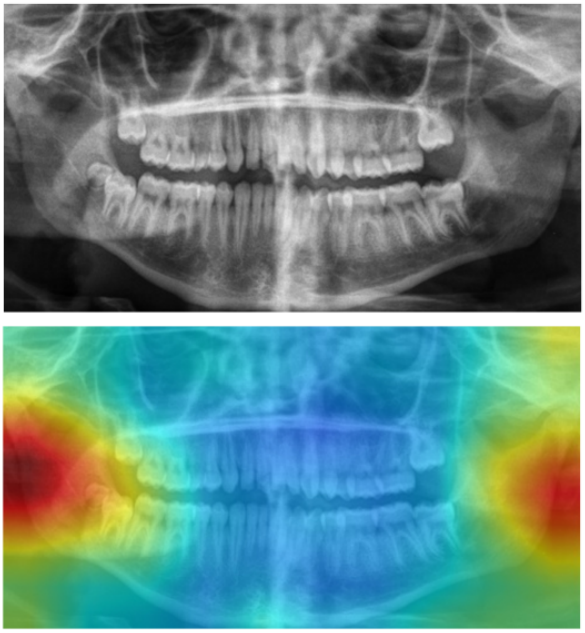
Model prediction: 0.8472
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



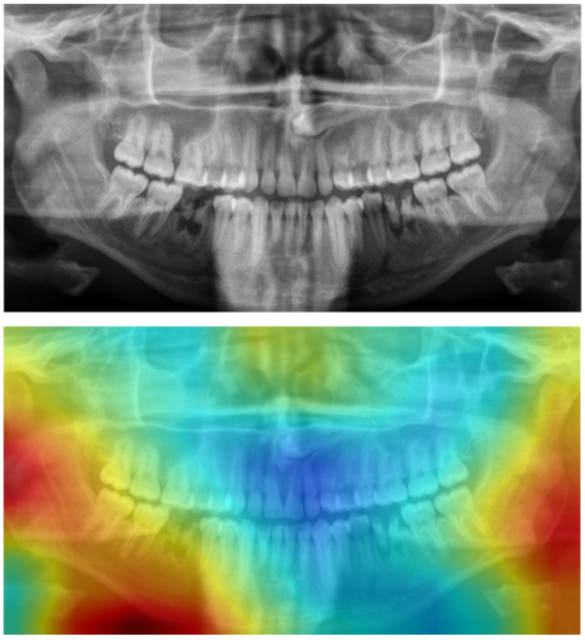
Model prediction: 0.871
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



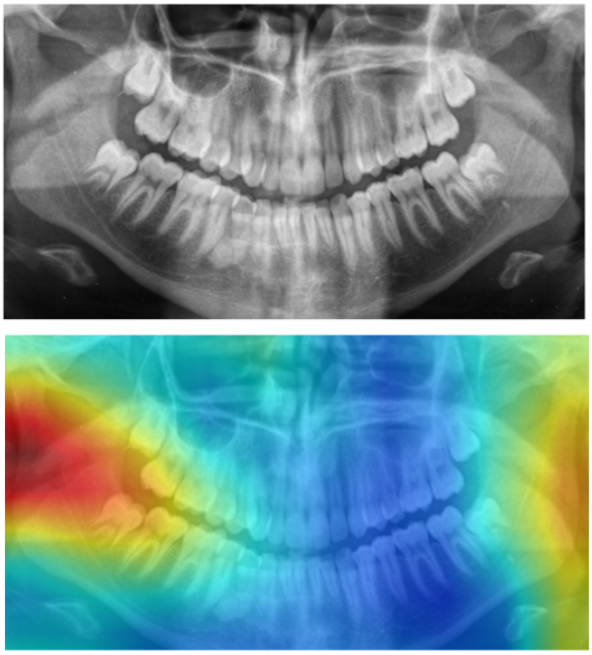
Model prediction: 0.7824
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



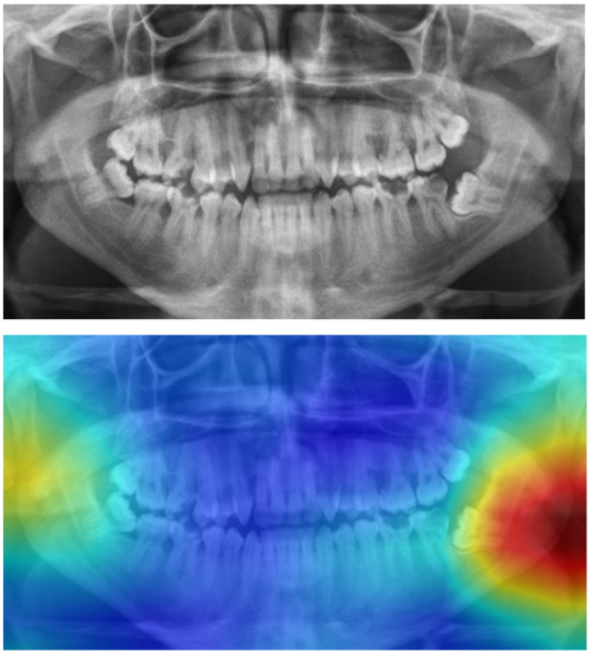
Model prediction: 0.8107
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



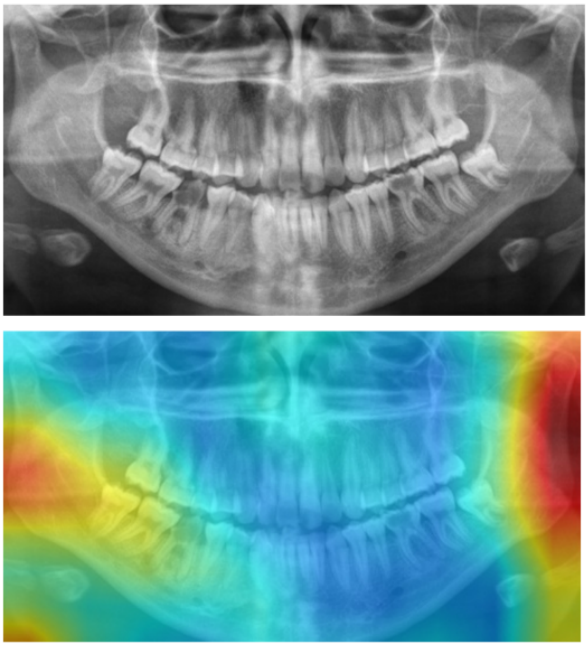
Model prediction: 0.5714
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



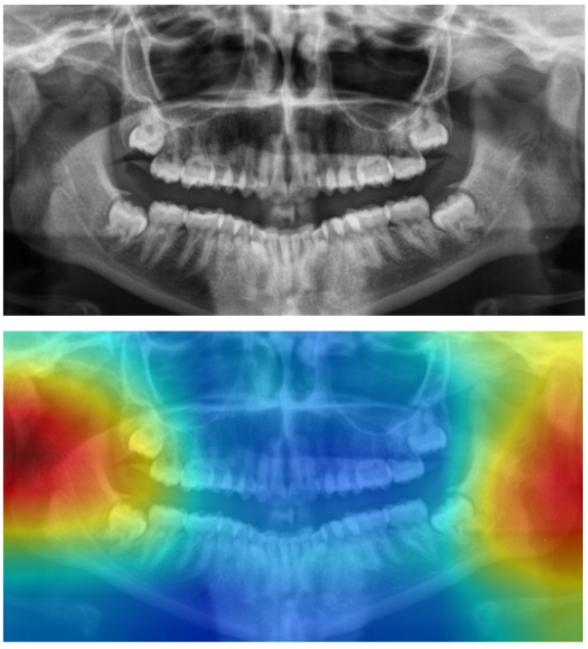
Model prediction: 0.7307
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



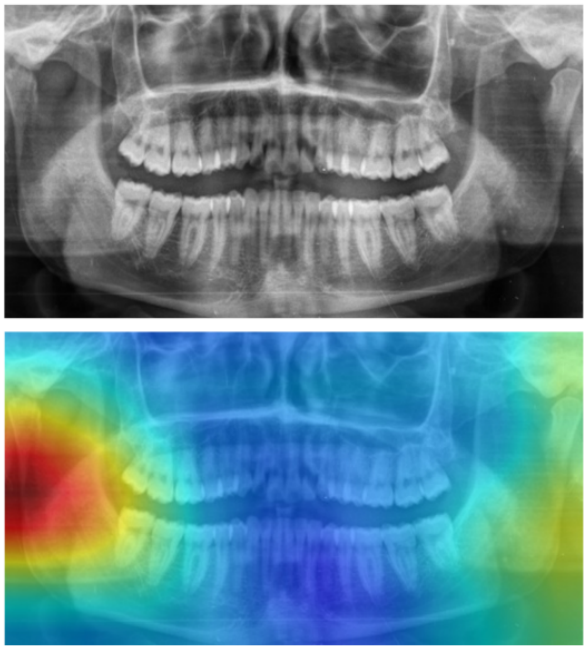
Model prediction: 0.6547
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



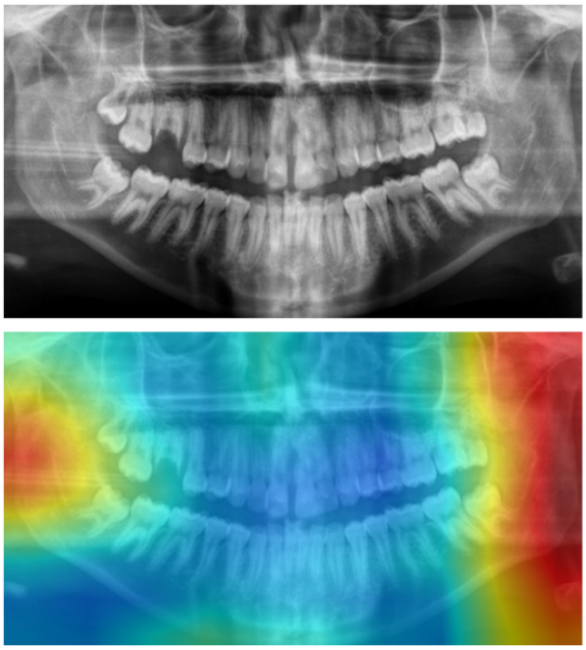
Model prediction: 0.5844
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



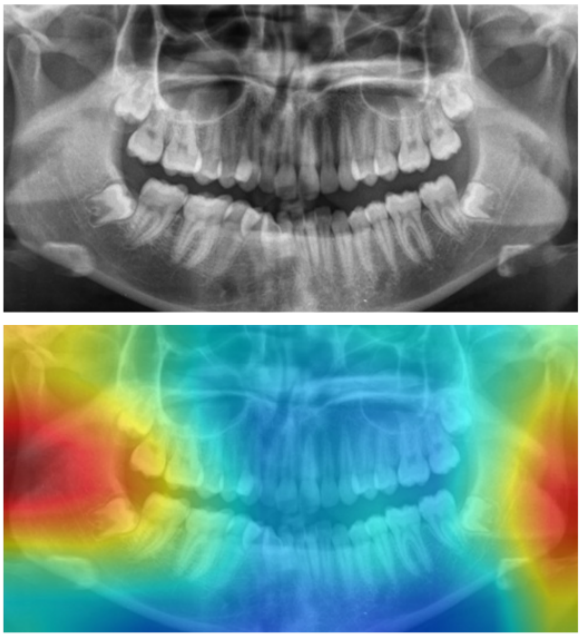
Model prediction: 0.8566
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



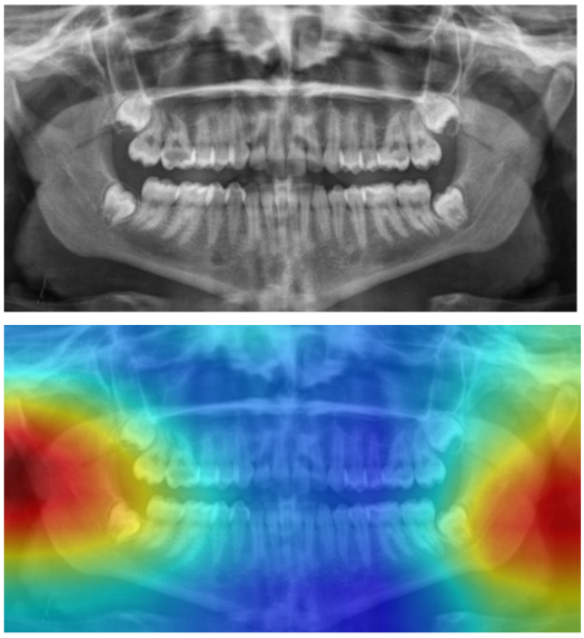
Model prediction: 0.7597
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



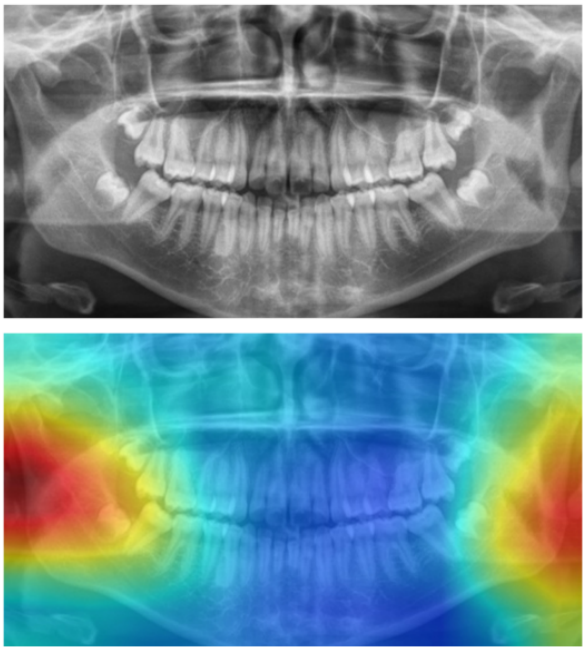
Model prediction: 0.6291
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



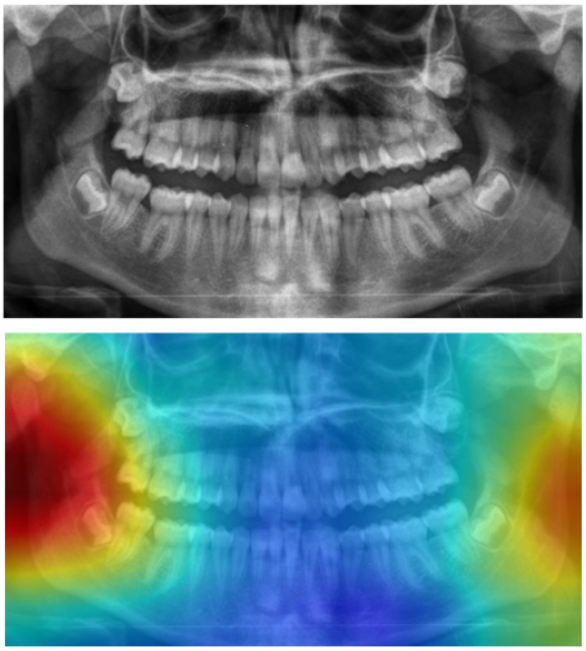
Model prediction: 0.69
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



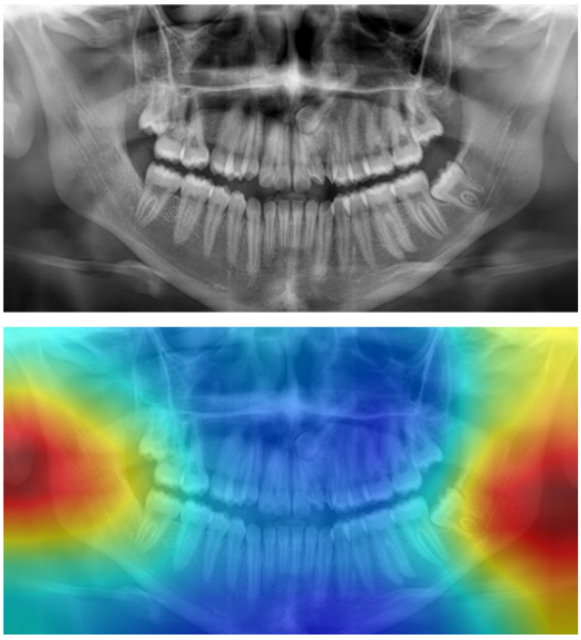
Model prediction: 0.7808
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



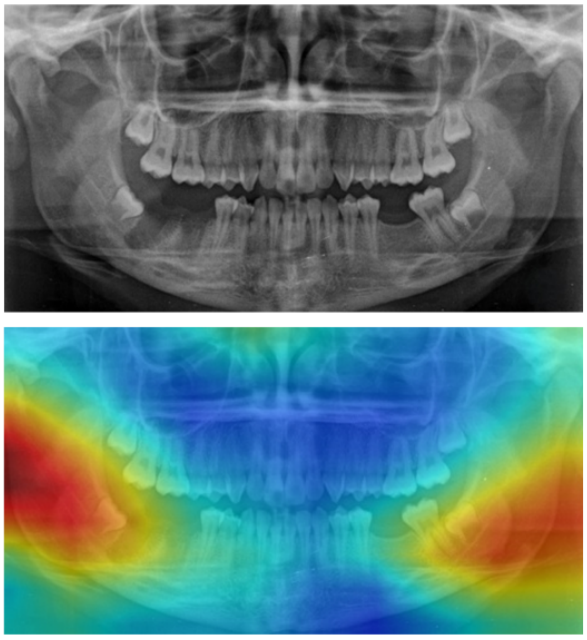
Model prediction: 0.7891
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



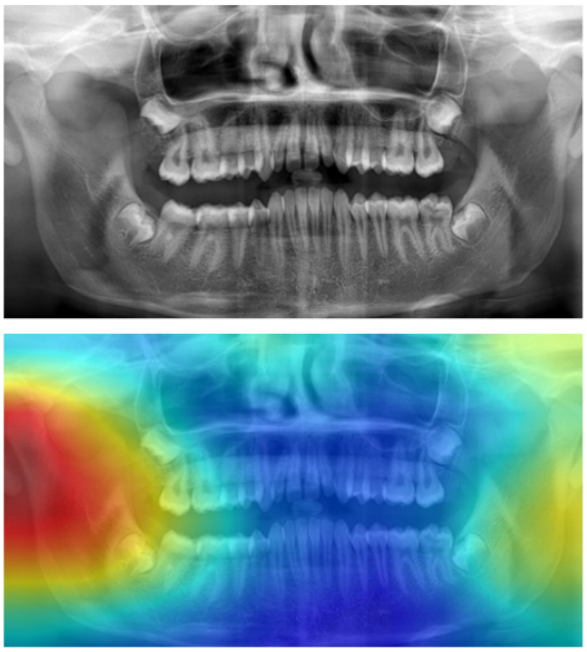
Model prediction: 0.8432
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



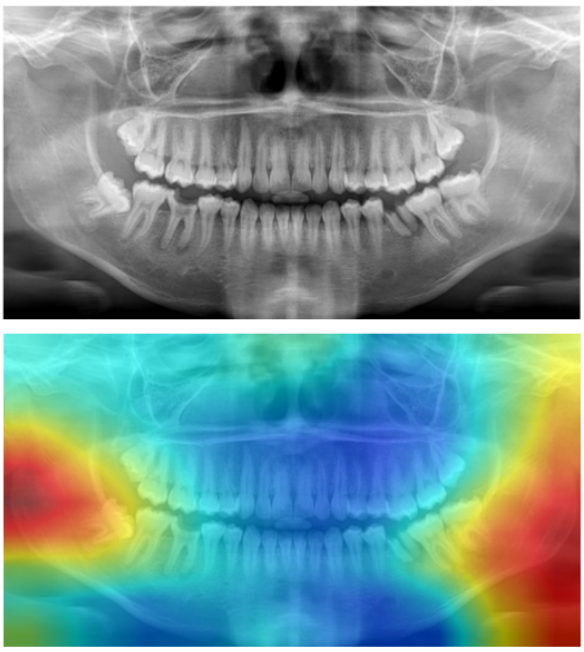
Model prediction: 0.7619
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



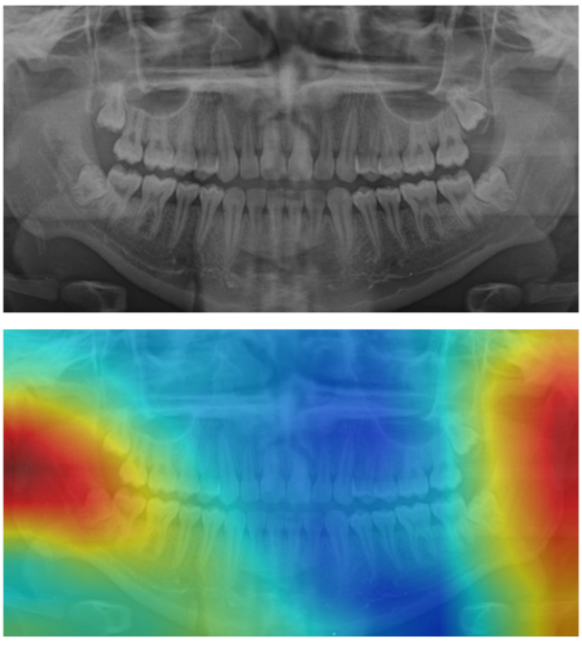
Model prediction: 0.5789
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



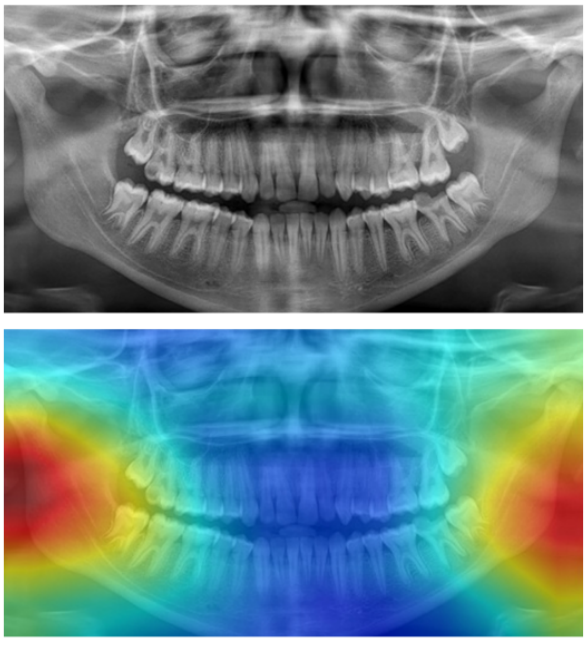
Model prediction: 0.8756
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



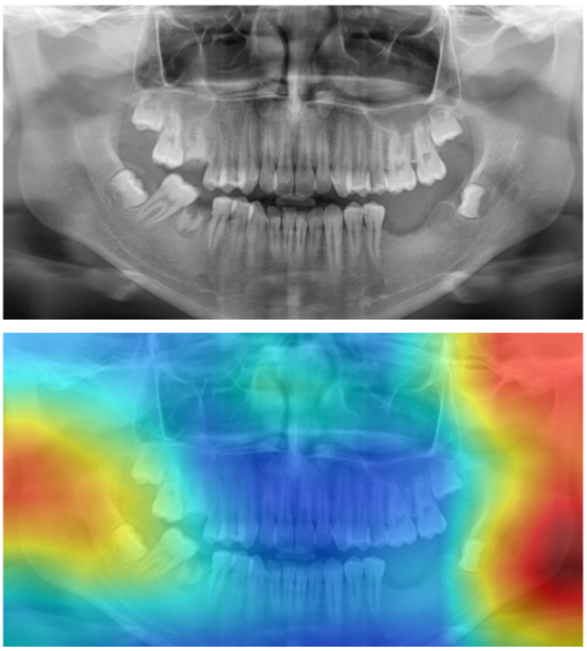
Model prediction: 0.5834
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



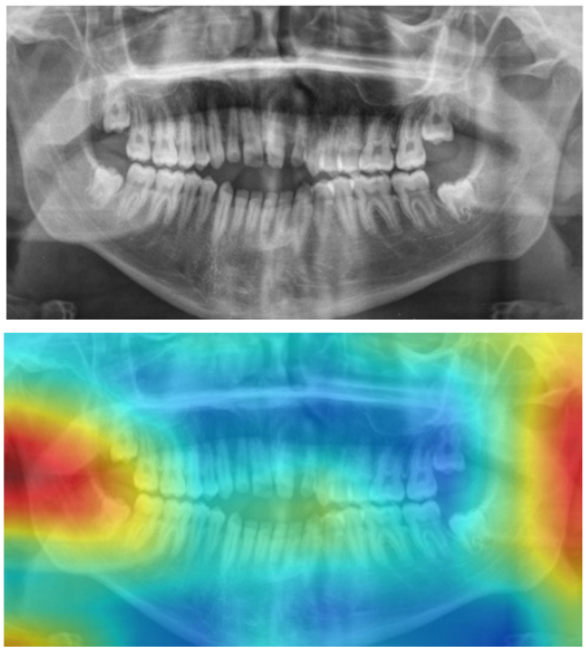
Model prediction: 0.6718
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



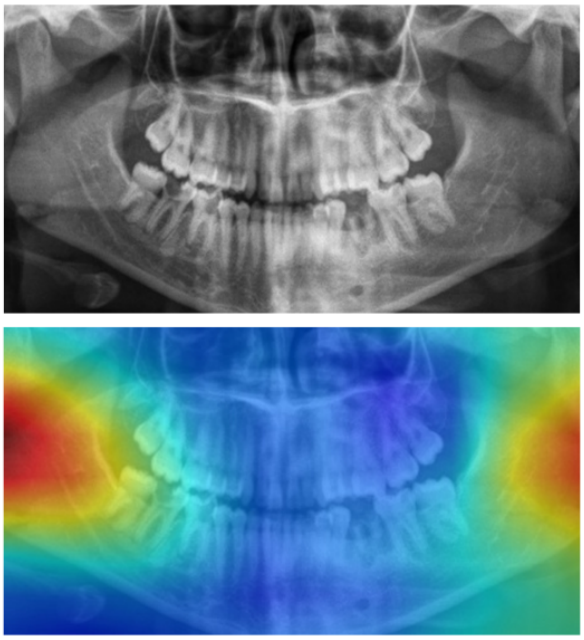
Model prediction: 0.7652
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



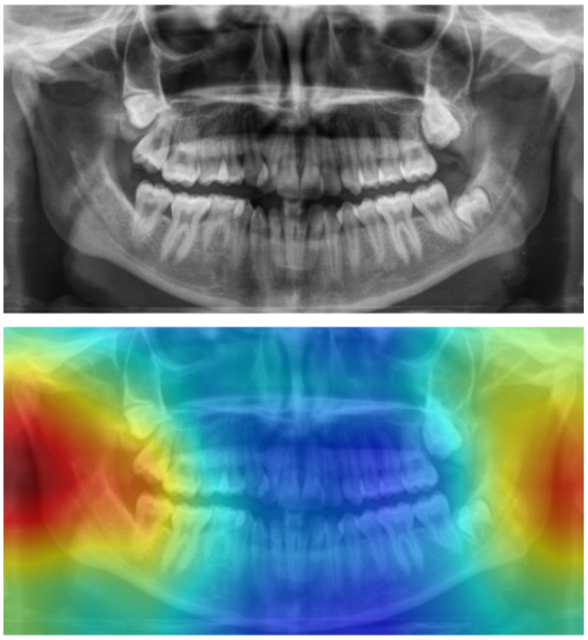
Model prediction: 0.7433
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes



Model prediction: 0.7431
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes

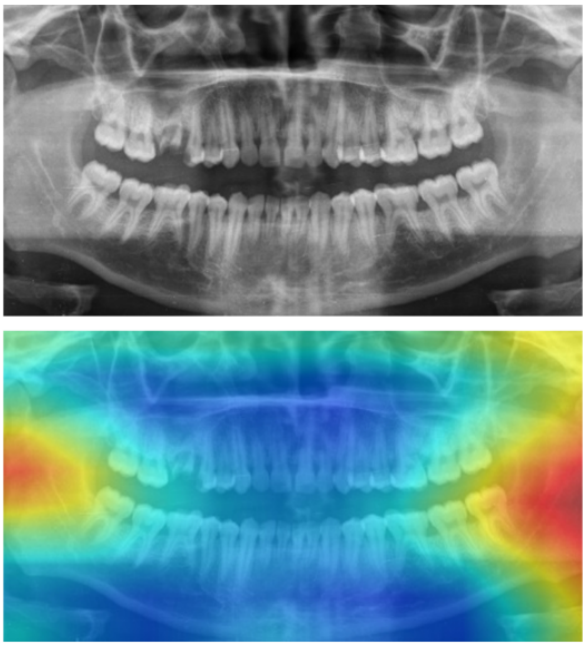


Model prediction: 0.753
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes

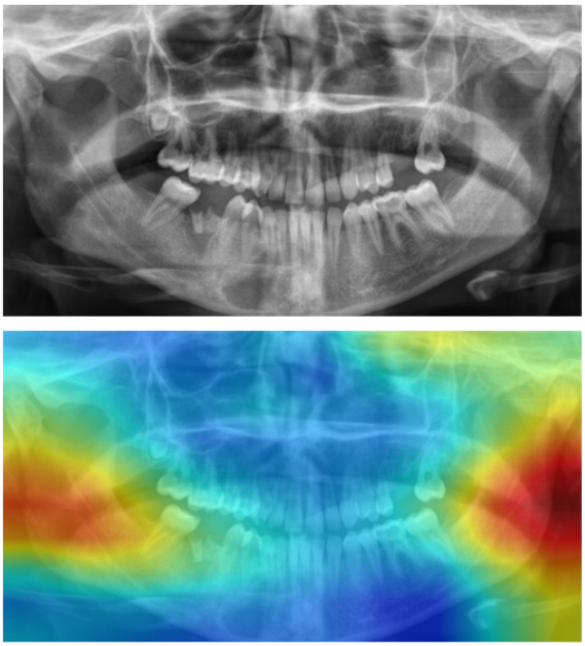


Model prediction: 0.9012
Actual Label: 16_23
Model classification: 16_23
Correct classification: Yes

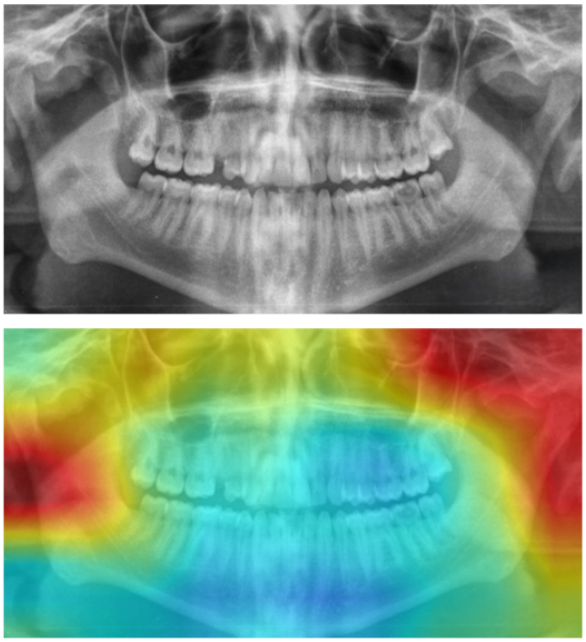
Anexo 4, II – *Heatmaps* de OPG da classe “16_23” classificadas como “24_30”



Model prediction: 0.4964
Actual Label: 16_23
Model classification: 24_30
Correct classification: No

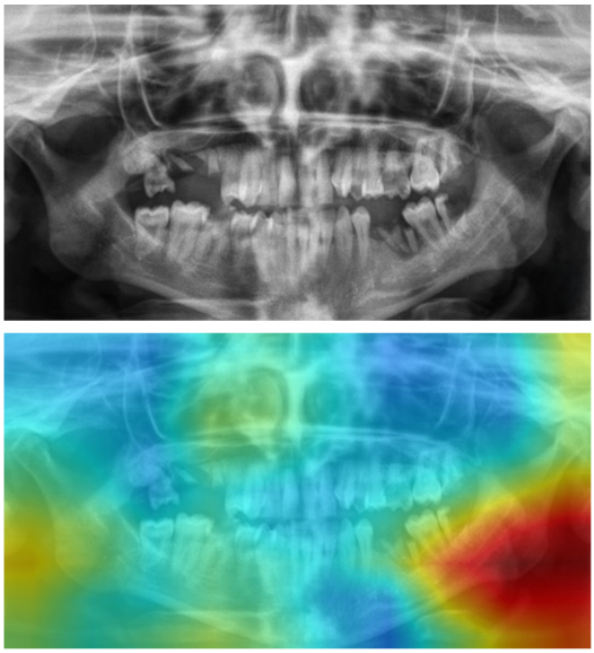


Model prediction: 0.4785
Actual Label: 16_23
Model classification: 24_30
Correct classification: No

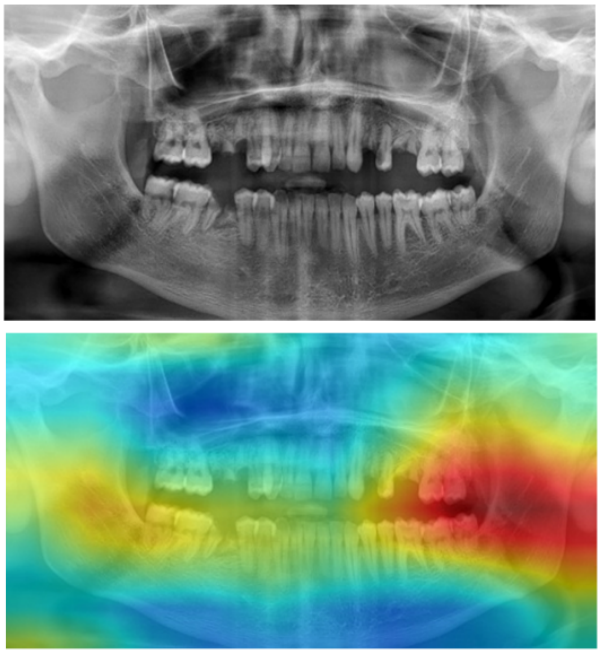


Model prediction: 0.4134
Actual Label: 16_23
Model classification: 24_30
Correct classification: No

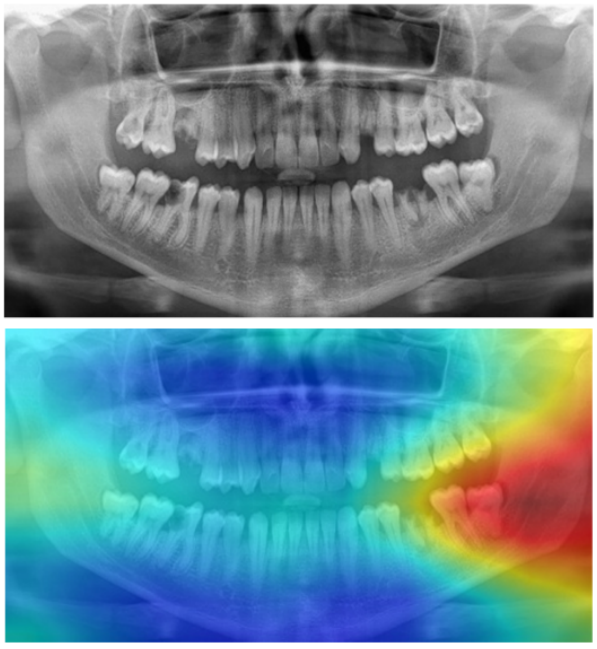
Anexo 4, III – *Heatmaps* de OPG da classe "24_30" classificadas como "24_30"



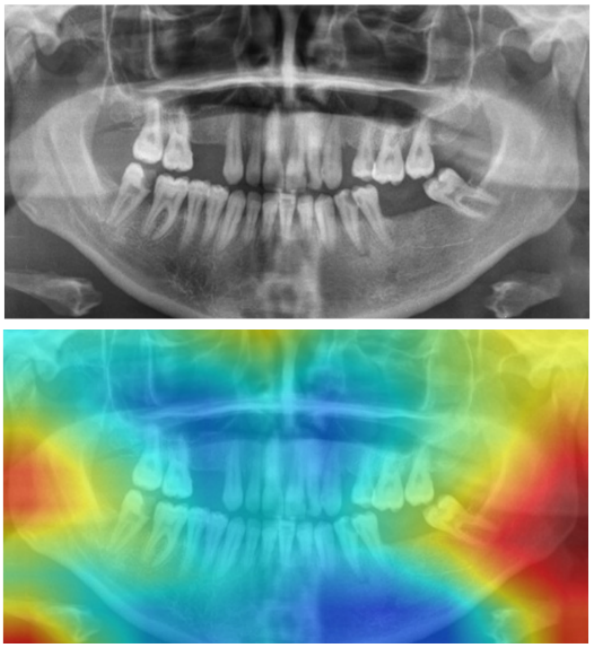
Model prediction: 0.3463
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



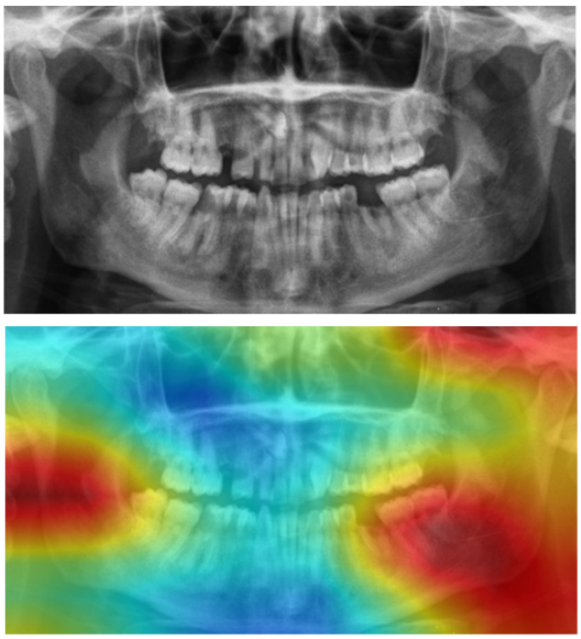
Model prediction: 0.2309
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



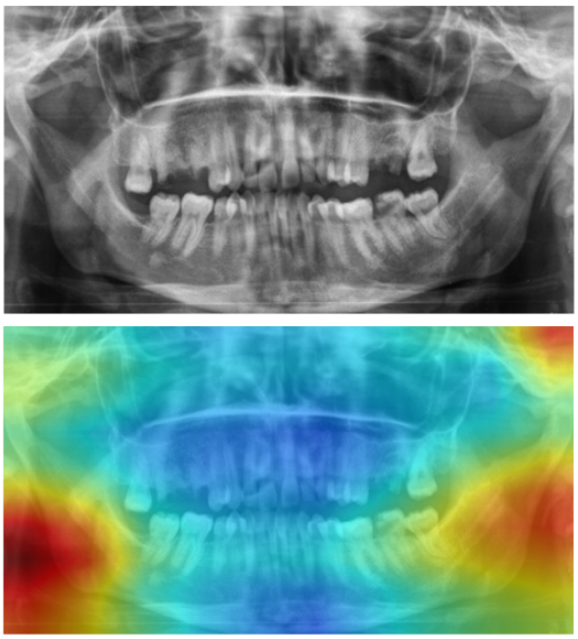
Model prediction: 0.2596
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



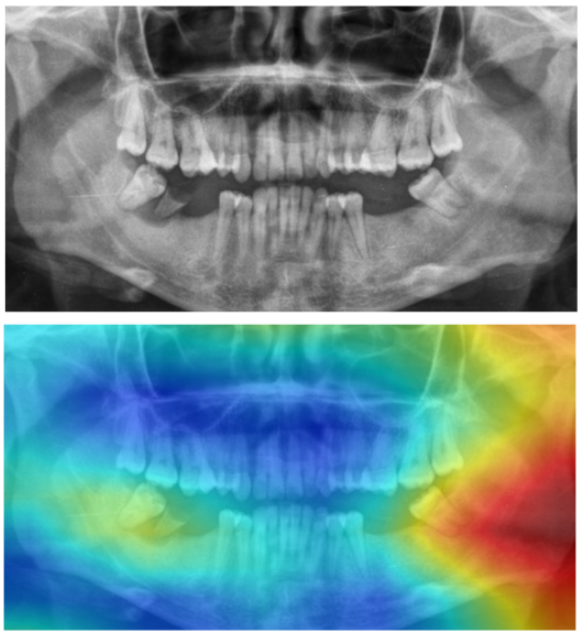
Model prediction: 0.4498
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



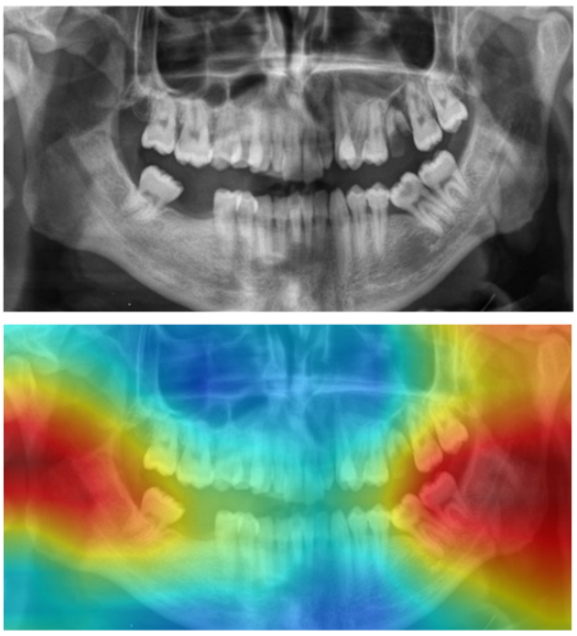
Model prediction: 0.2624
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



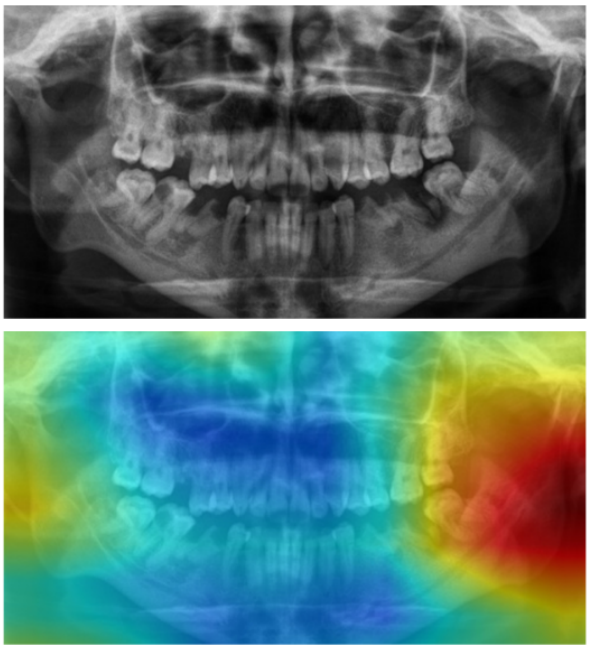
Model prediction: 0.4578
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



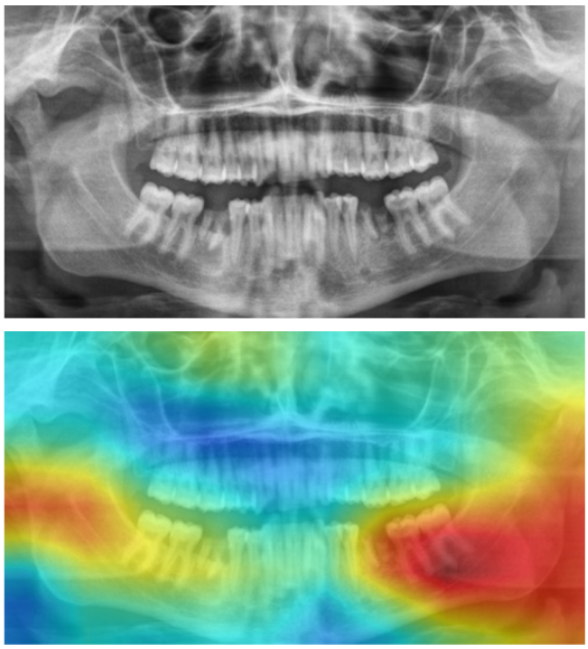
Model prediction: 0.2539
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



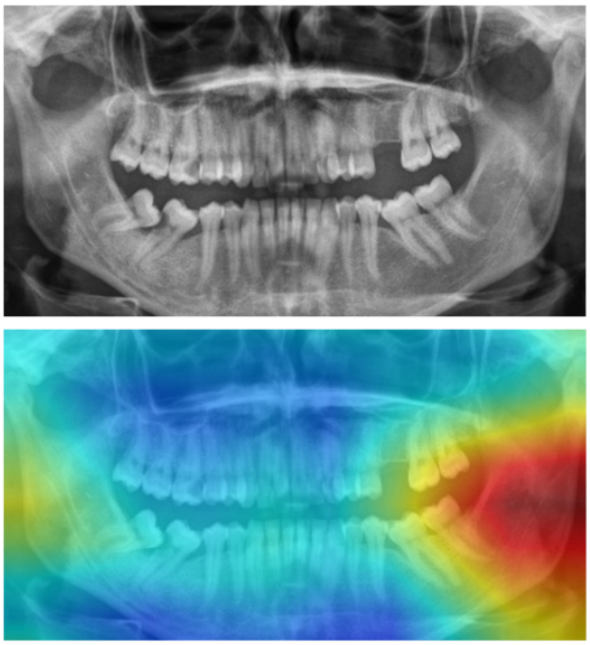
Model prediction: 0.3847
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



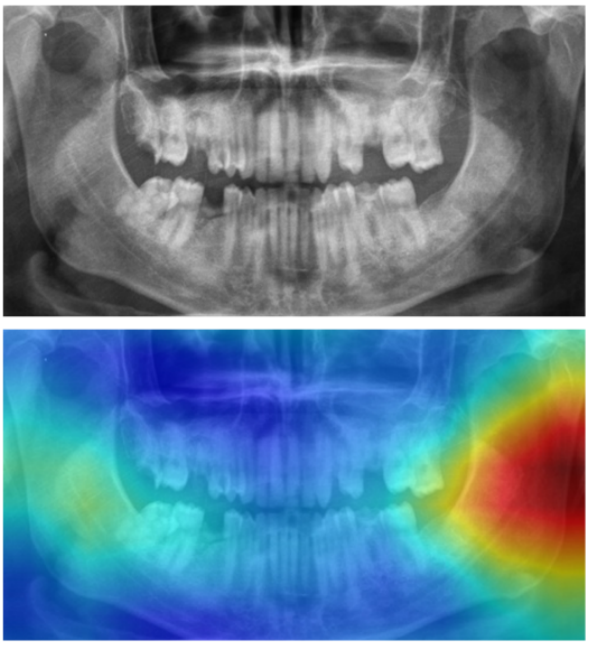
Model prediction: 0.4263
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



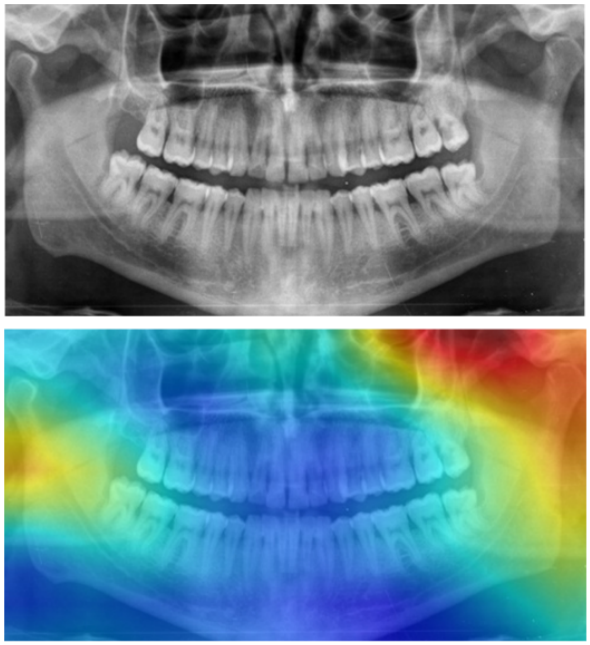
Model prediction: 0.275
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



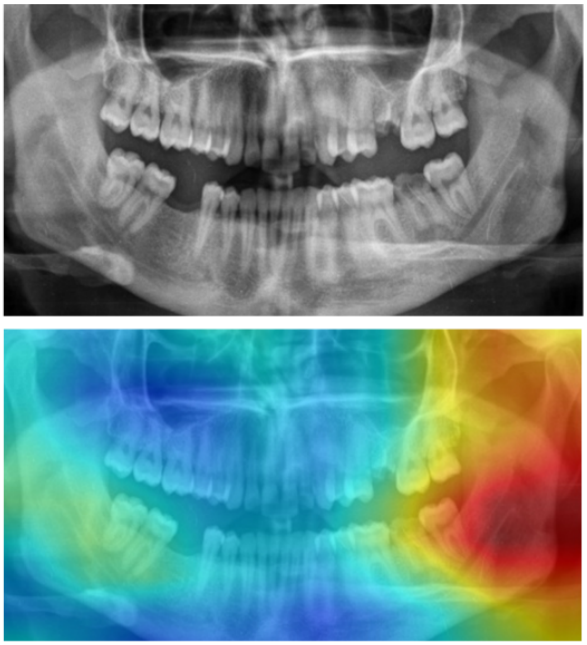
Model prediction: 0.3044
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



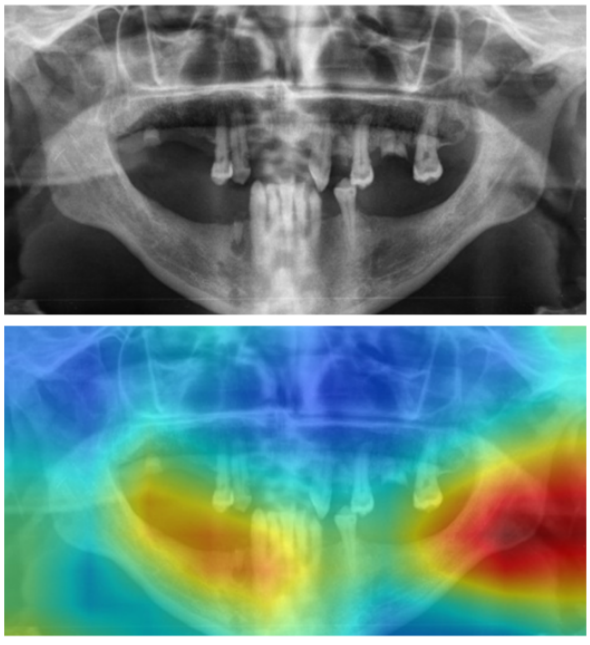
Model prediction: 0.3254
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



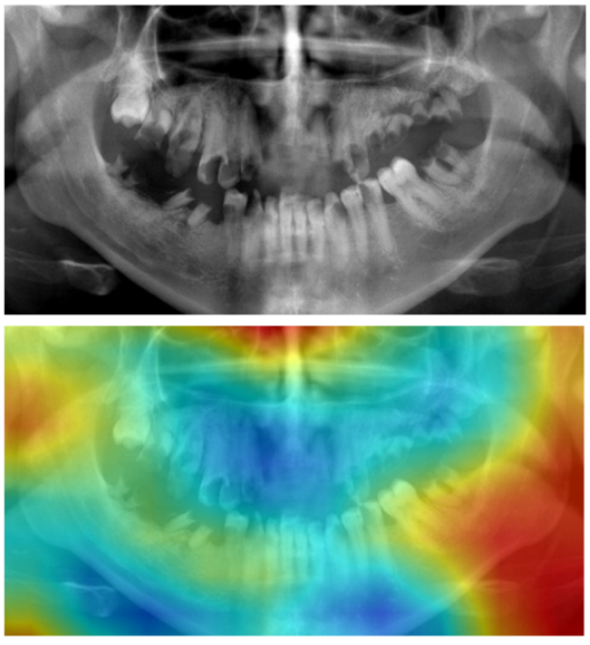
Model prediction: 0.377
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



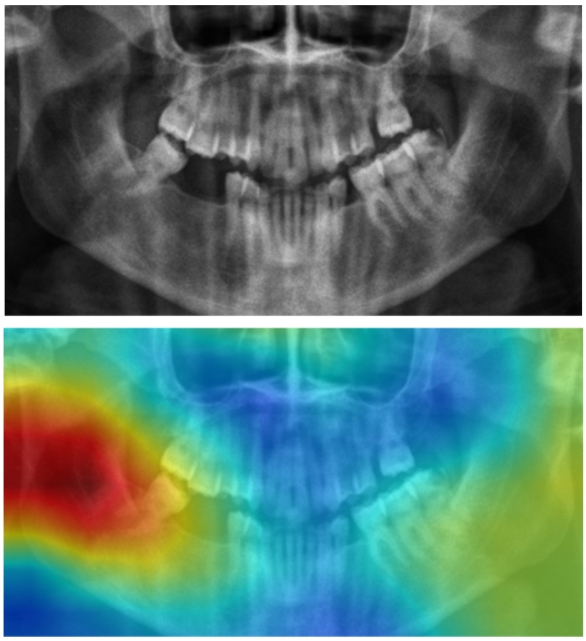
Model prediction: 0.2483
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



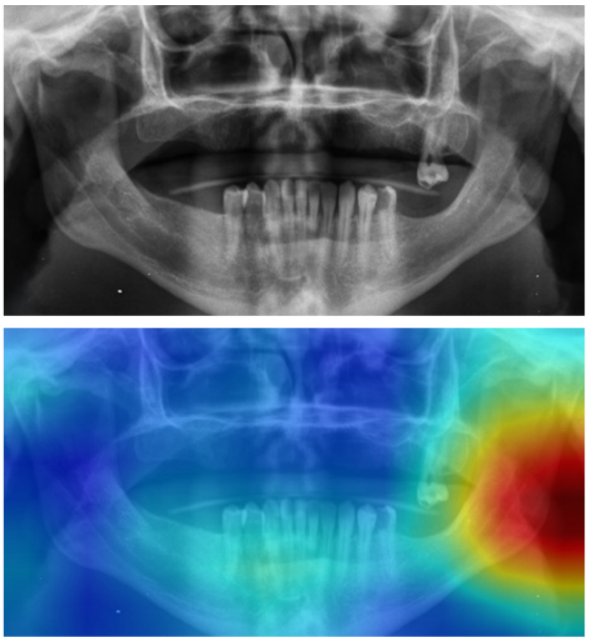
Model prediction: 0.2307
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



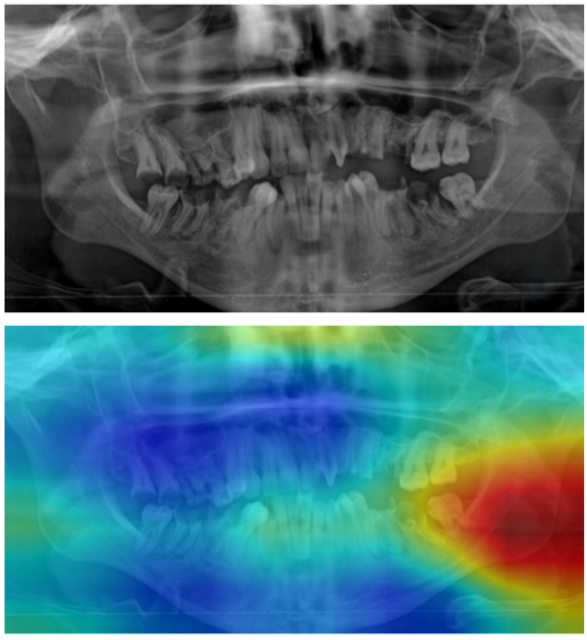
Model prediction: 0.2856
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



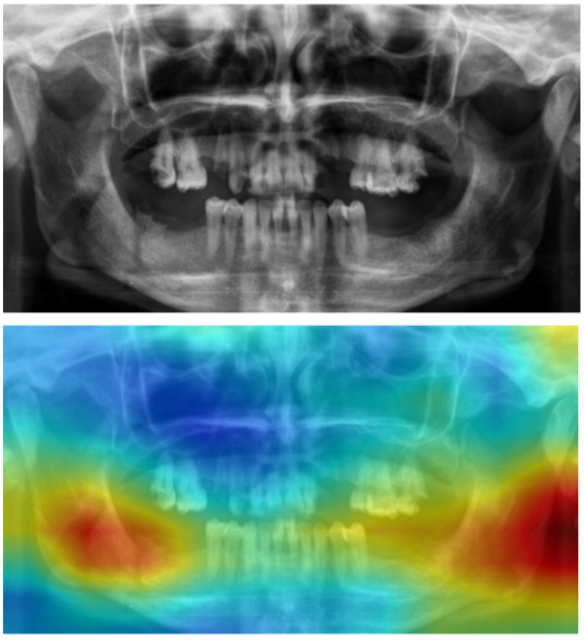
Model prediction: 0.4841
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



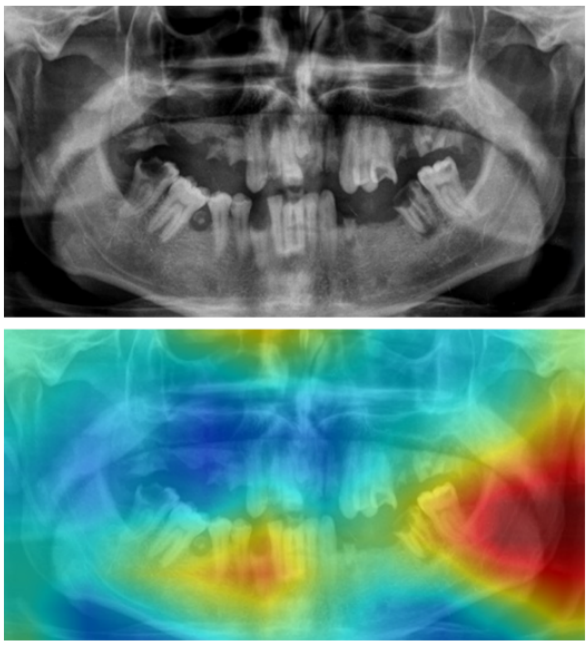
Model prediction: 0.2196
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



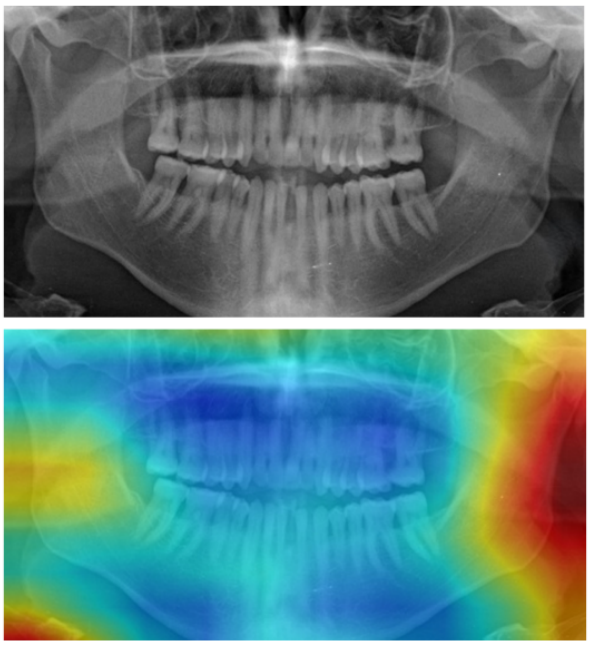
Model prediction: 0.2713
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



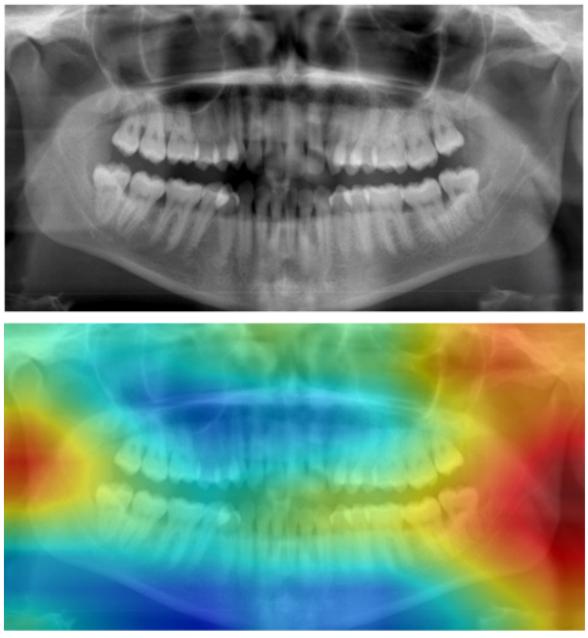
Model prediction: 0.2937
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



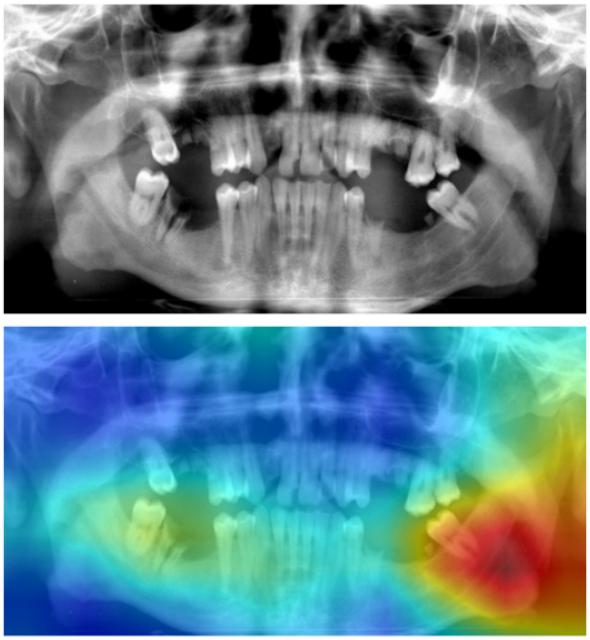
Model prediction: 0.2089
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



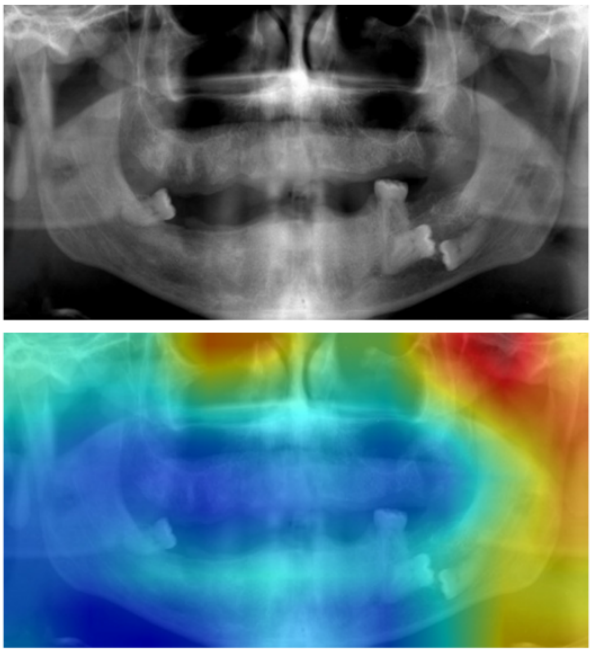
Model prediction: 0.4497
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



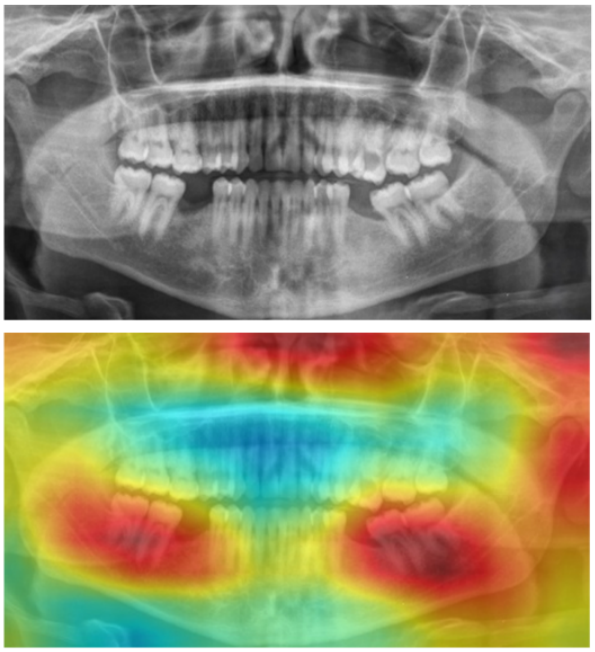
Model prediction: 0.499
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



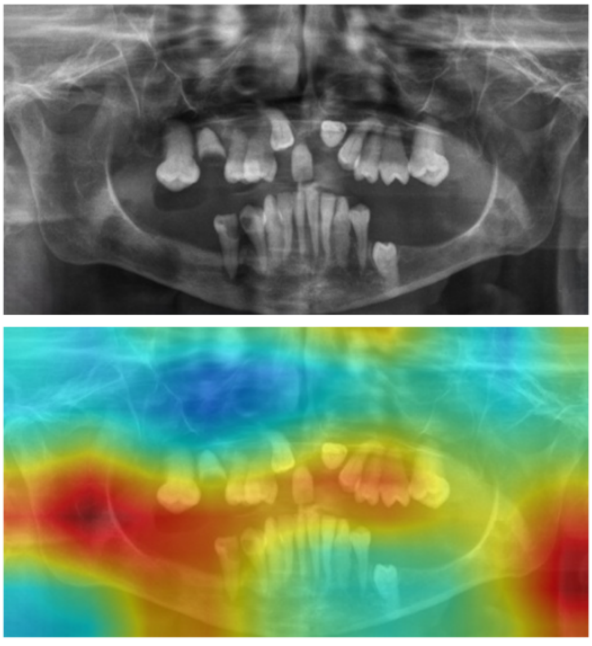
Model prediction: 0.1269
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



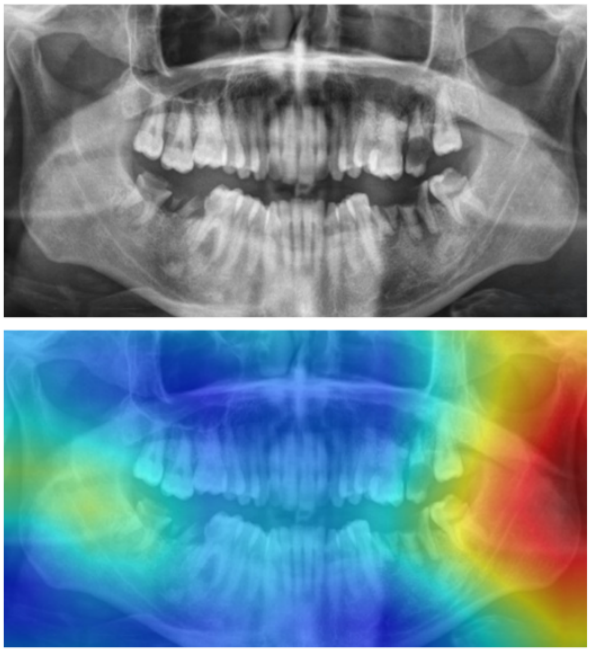
Model prediction: 0.2285
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



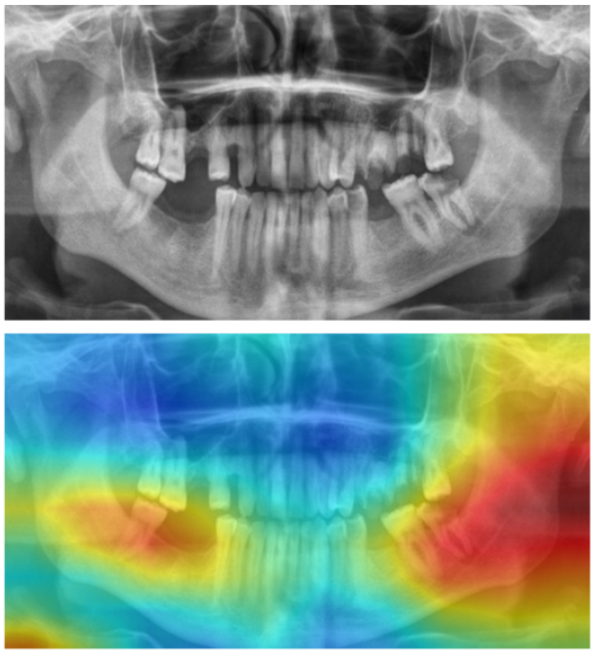
Model prediction: 0.2702
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



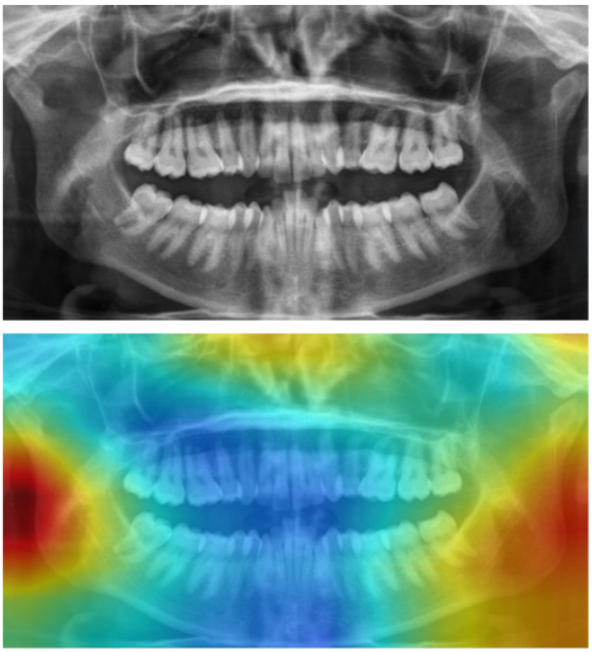
Model prediction: 0.2337
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



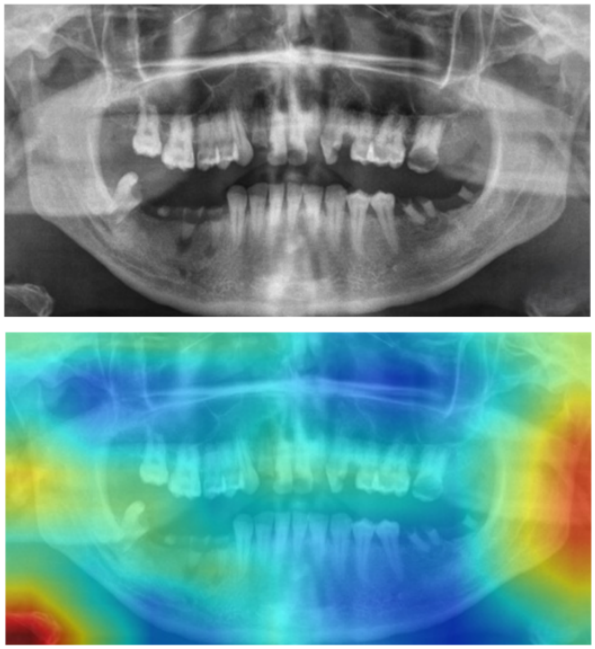
Model prediction: 0.2879
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



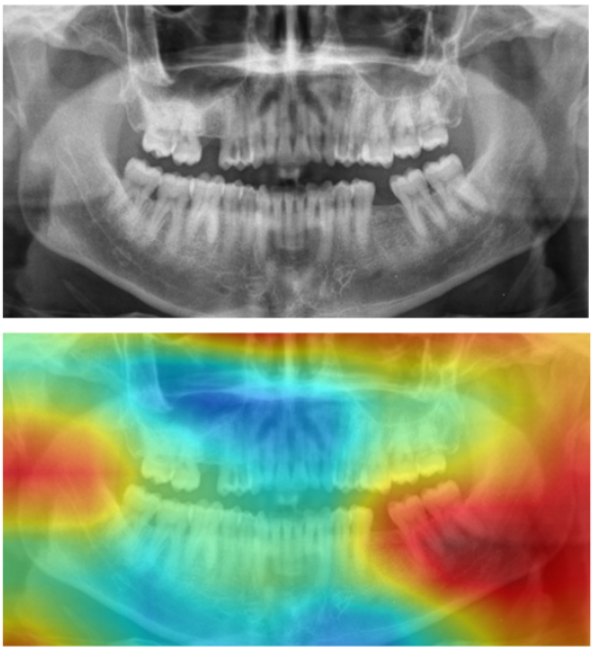
Model prediction: 0.1947
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



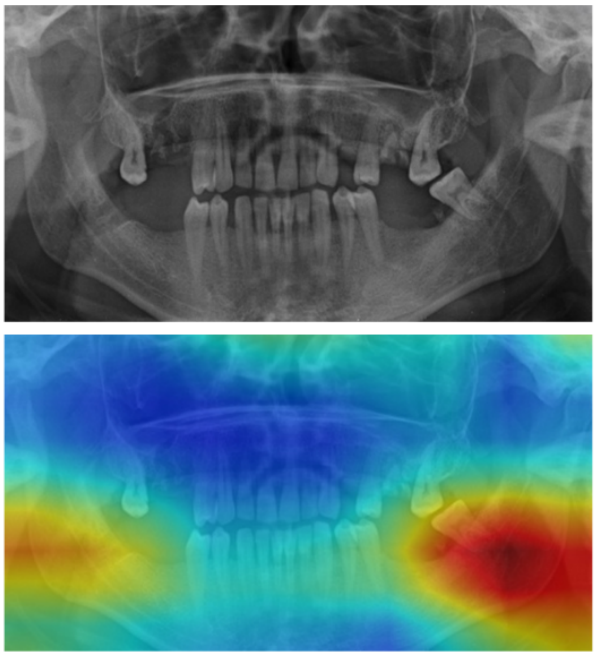
Model prediction: 0.4707
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



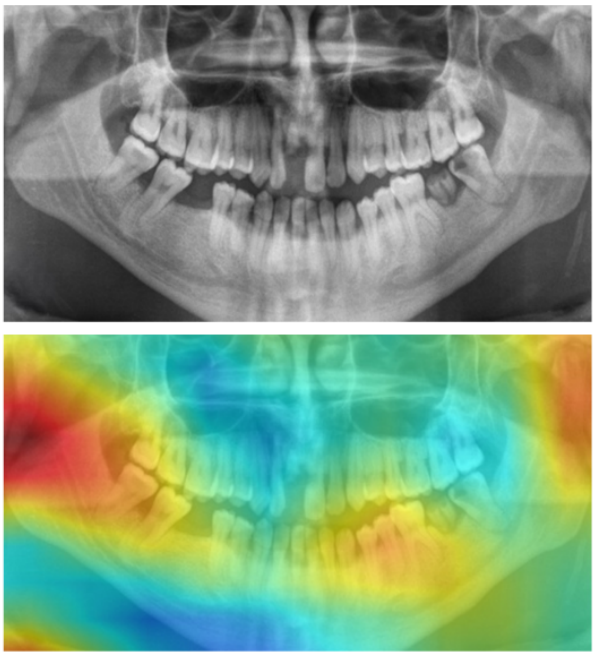
Model prediction: 0.3834
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



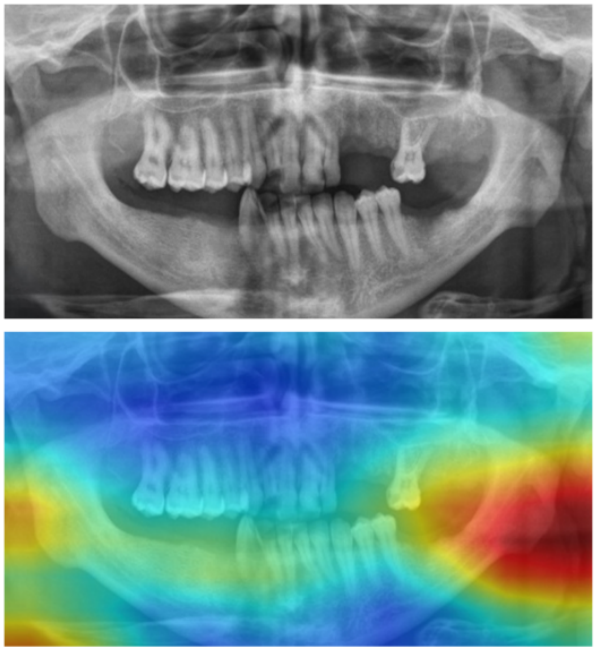
Model prediction: 0.3121
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



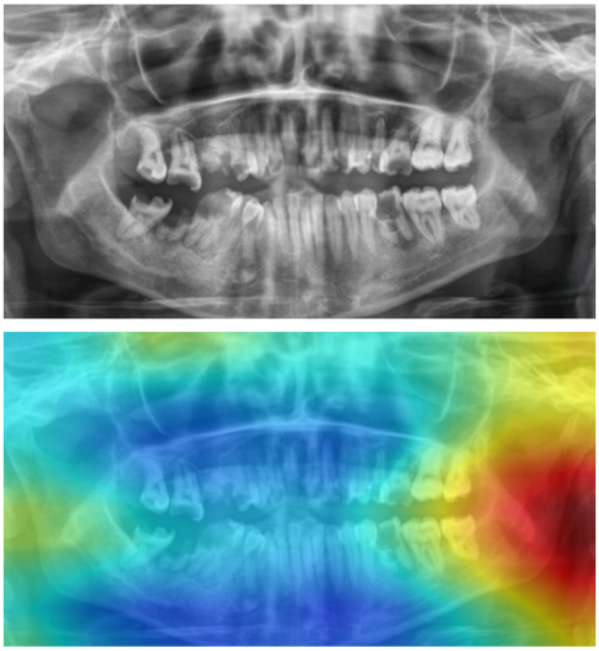
Model prediction: 0.2557
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



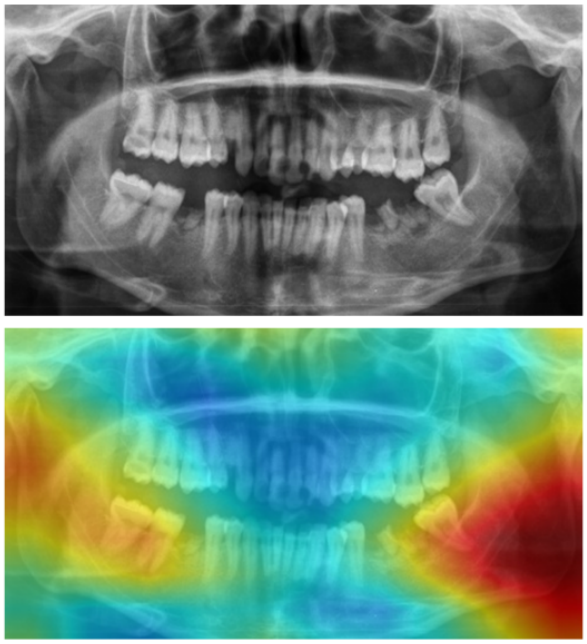
Model prediction: 0.4263
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



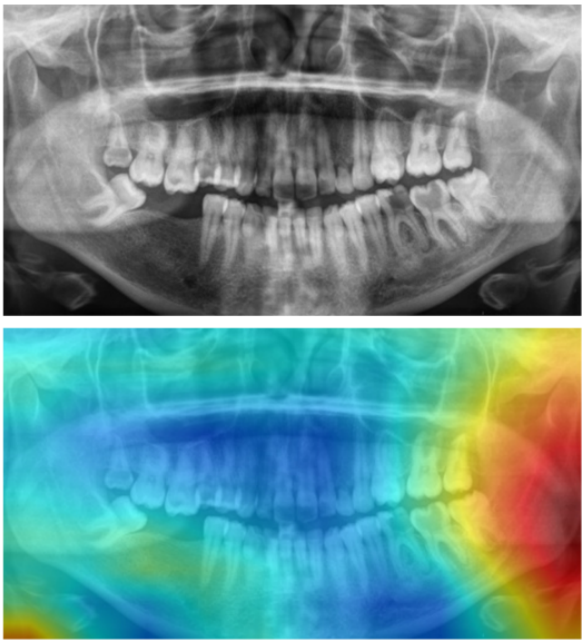
Model prediction: 0.287
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



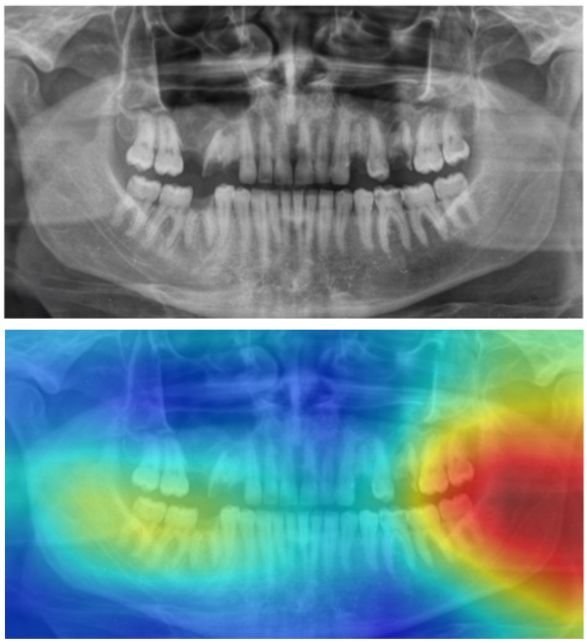
Model prediction: 0.3108
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



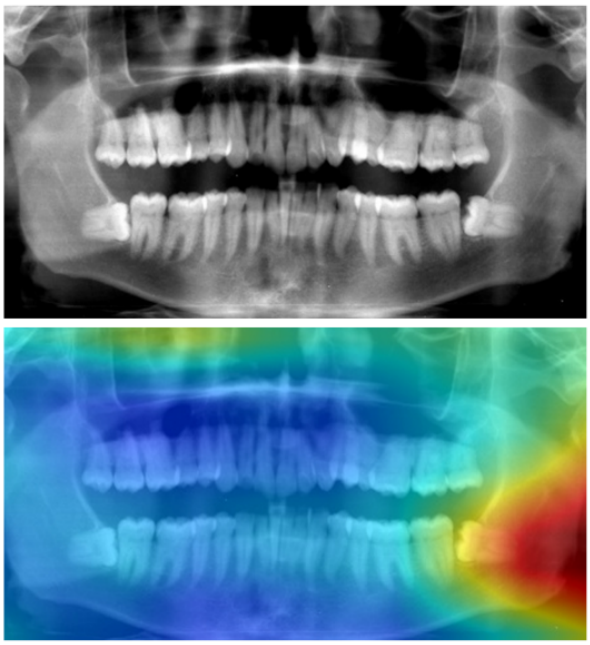
Model prediction: 0.451
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



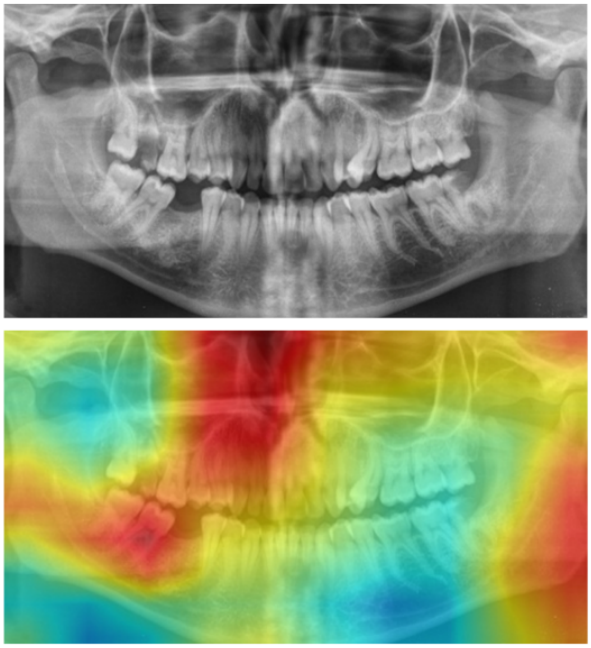
Model prediction: 0.3556
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



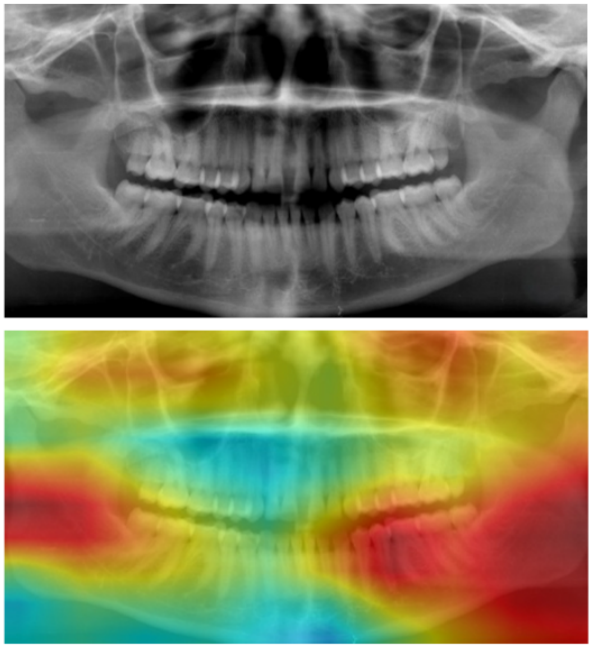
Model prediction: 0.1743
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



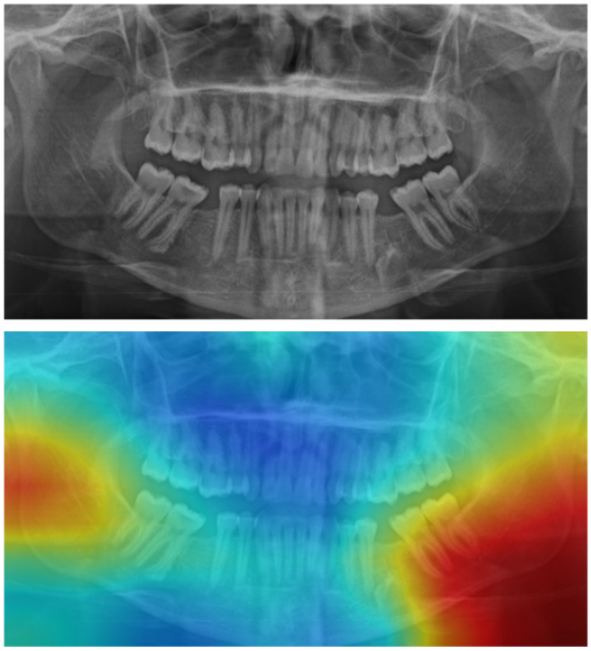
Model prediction: 0.2798
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



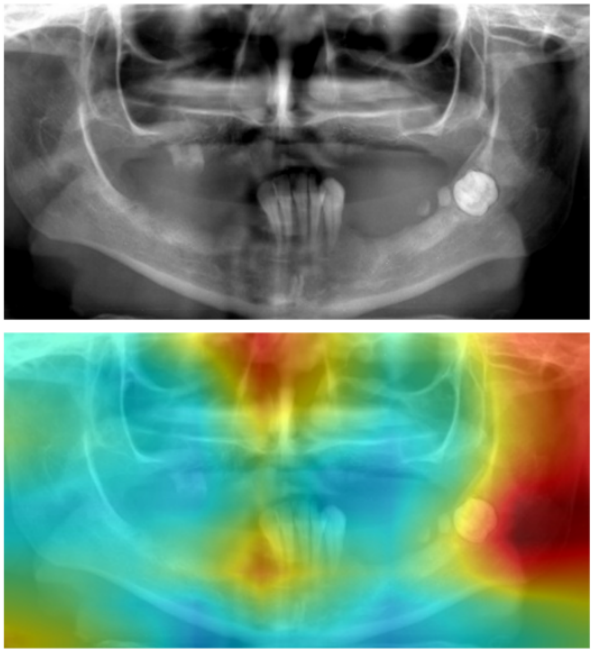
Model prediction: 0.2709
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



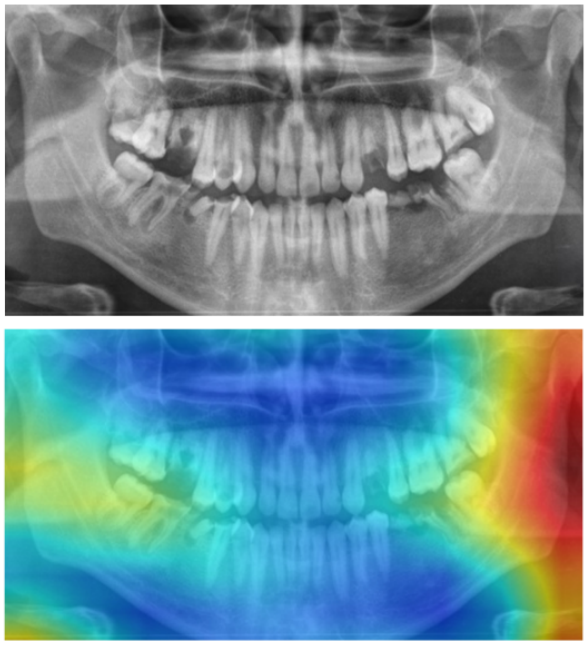
Model prediction: 0.3284
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



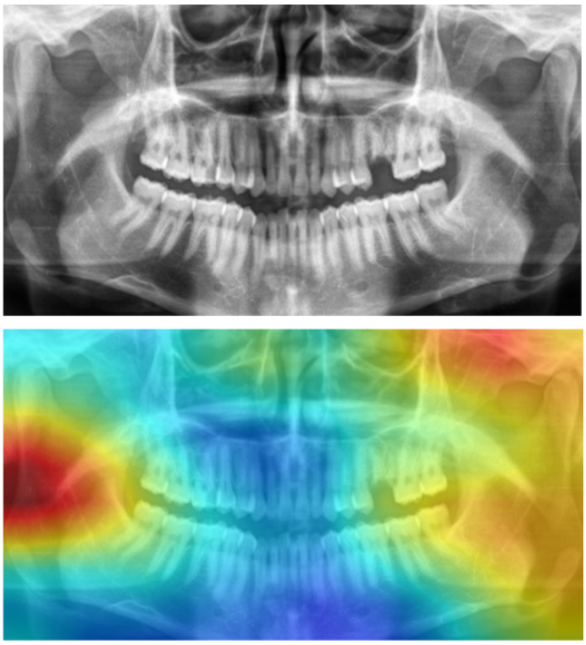
Model prediction: 0.409
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



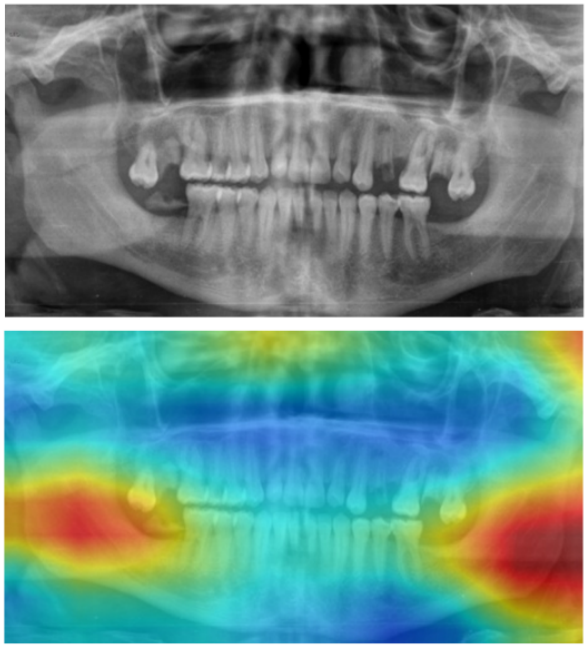
Model prediction: 0.3052
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



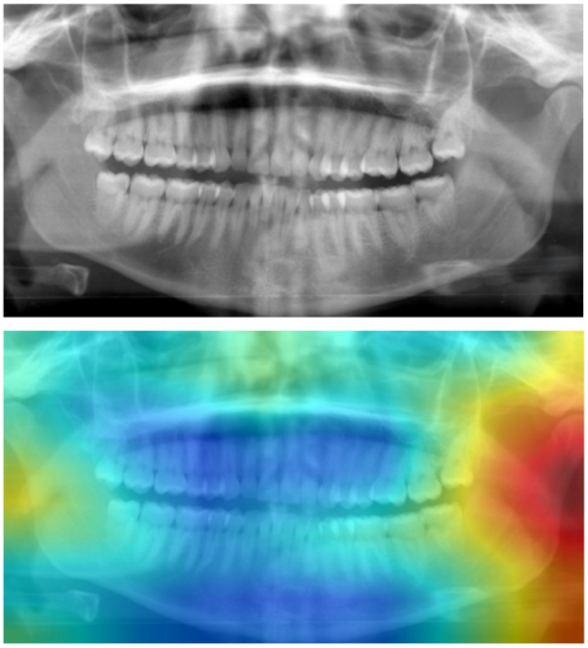
Model prediction: 0.3988
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



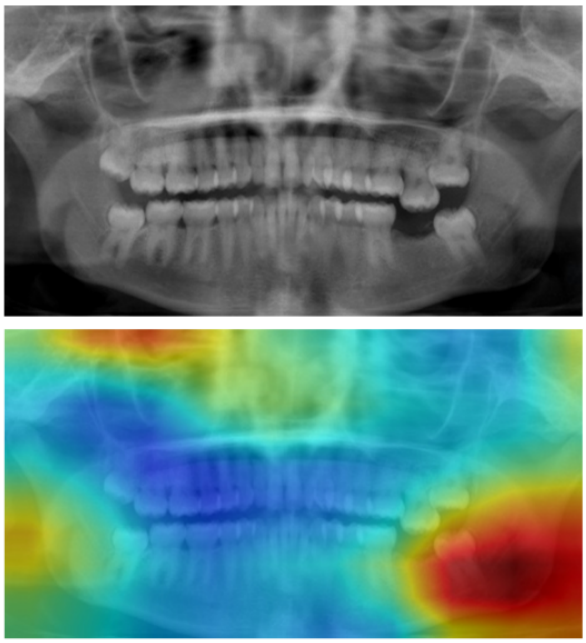
Model prediction: 0.4561
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



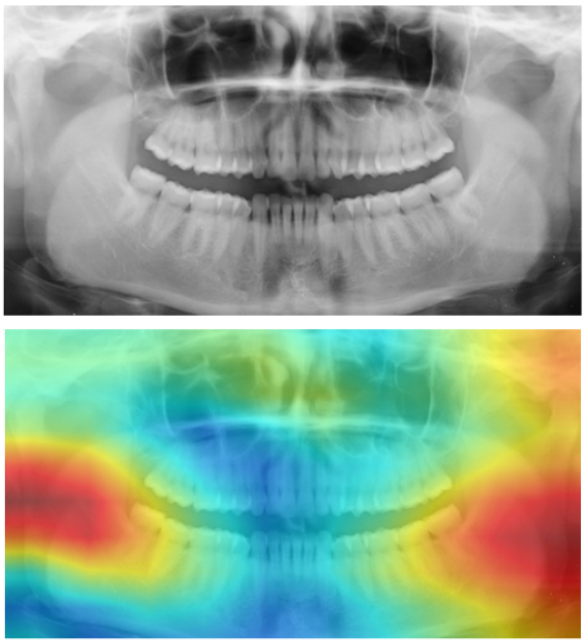
Model prediction: 0.3521
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



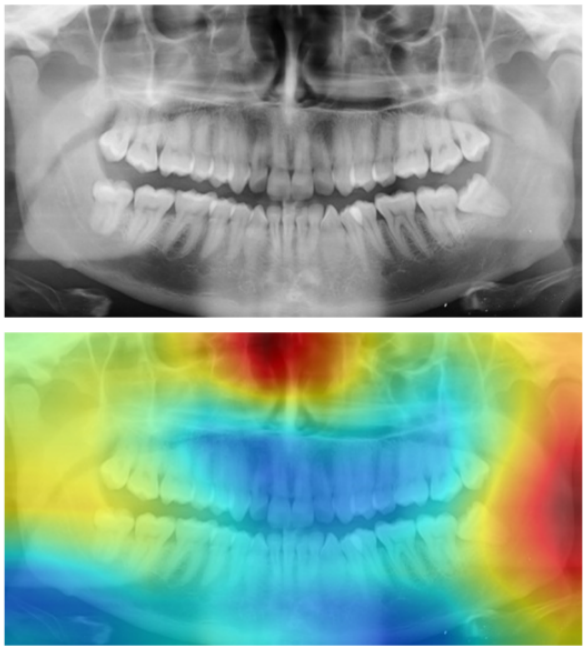
Model prediction: 0.4594
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



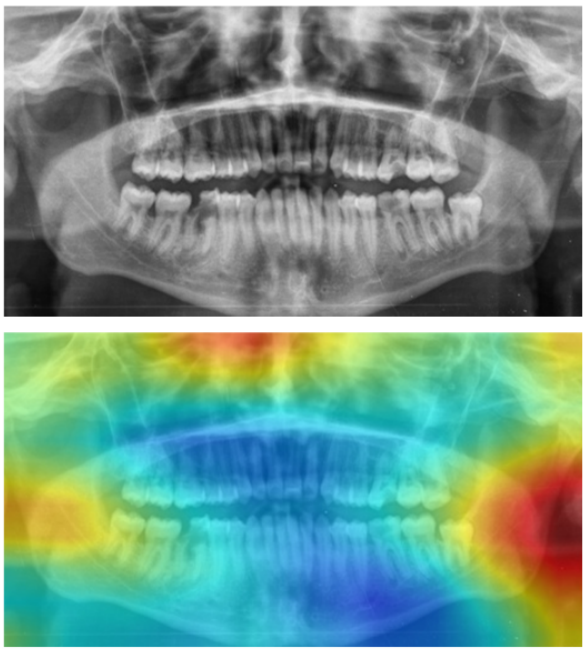
Model prediction: 0.3932
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



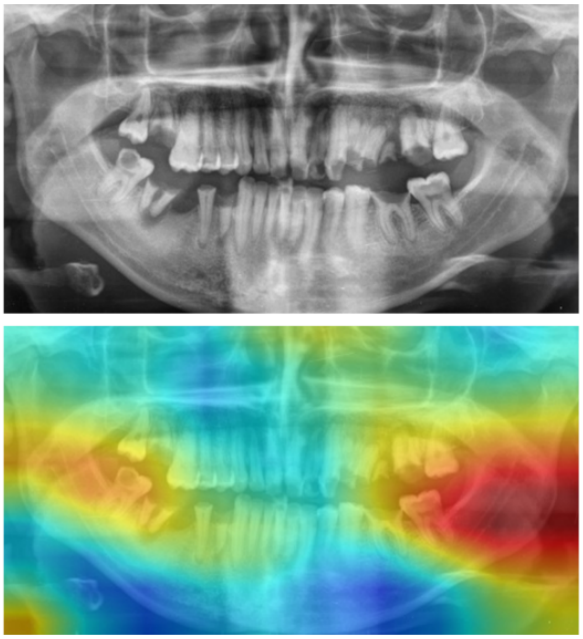
Model prediction: 0.4267
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



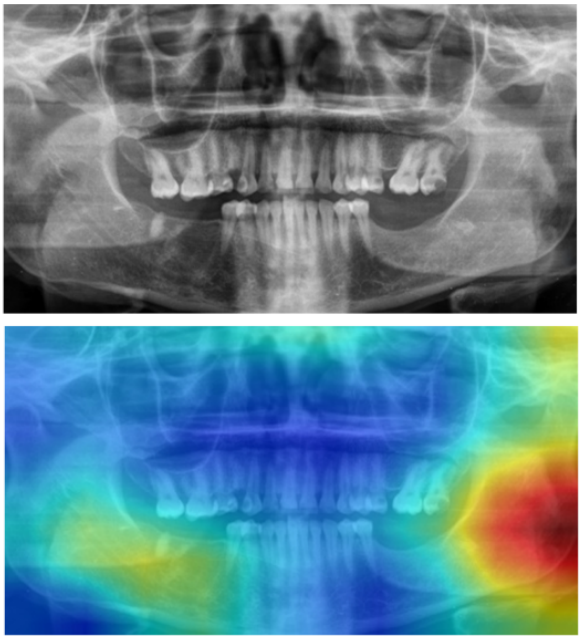
Model prediction: 0.4792
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



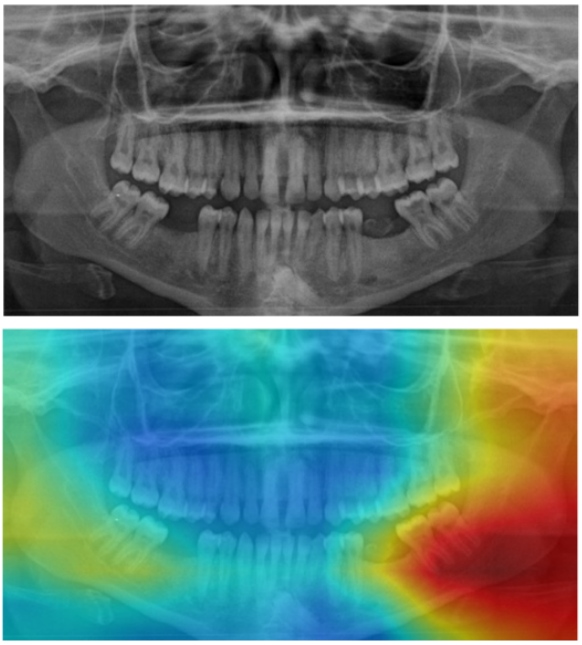
Model prediction: 0.4104
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes



Model prediction: 0.2291
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes

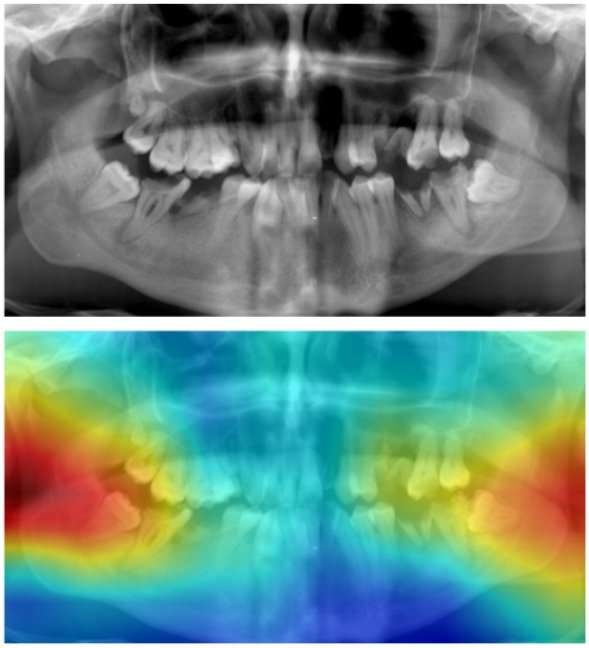


Model prediction: 0.3156
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes

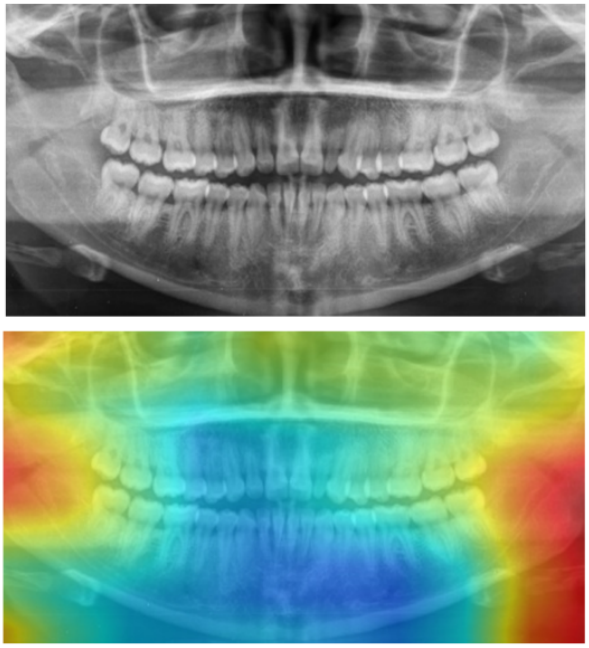


Model prediction: 0.3409
Actual Label: 24_30
Model classification: 24_30
Correct classification: Yes

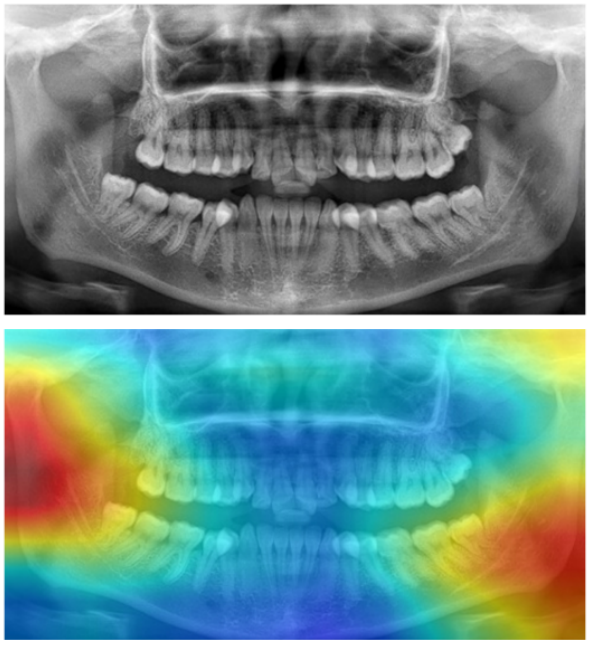
Anexo 4, IV – Heatmaps de OPG da classe “24_30” classificadas como “16_23”



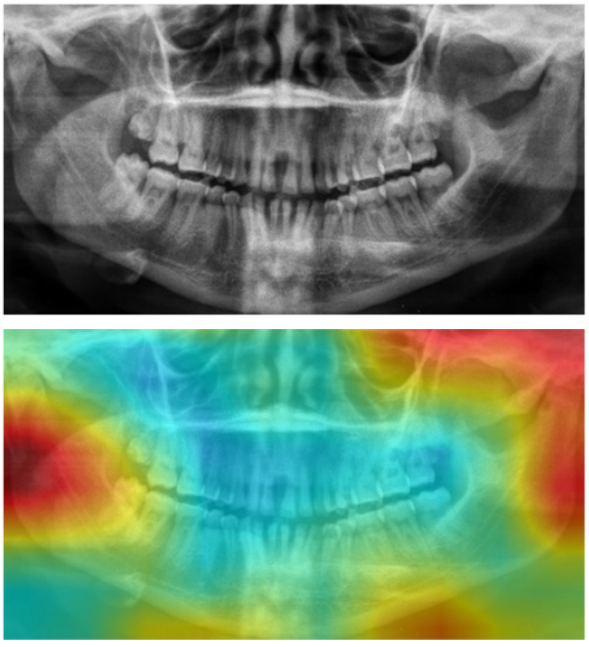
Model prediction: 0.6508
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



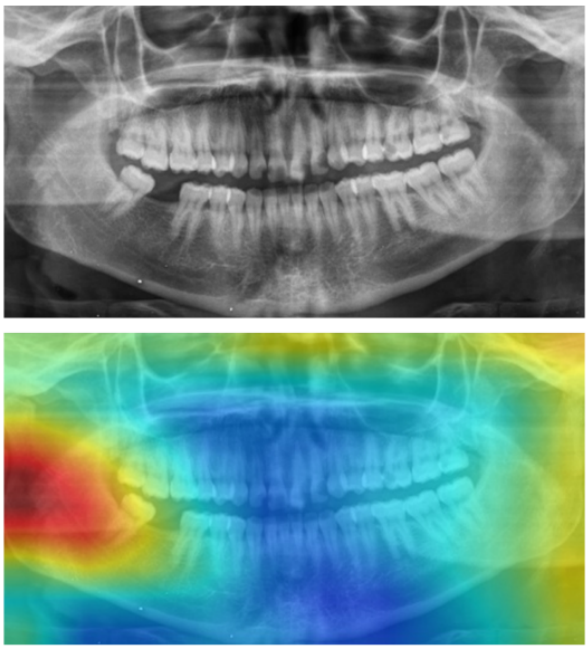
Model prediction: 0.5527
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



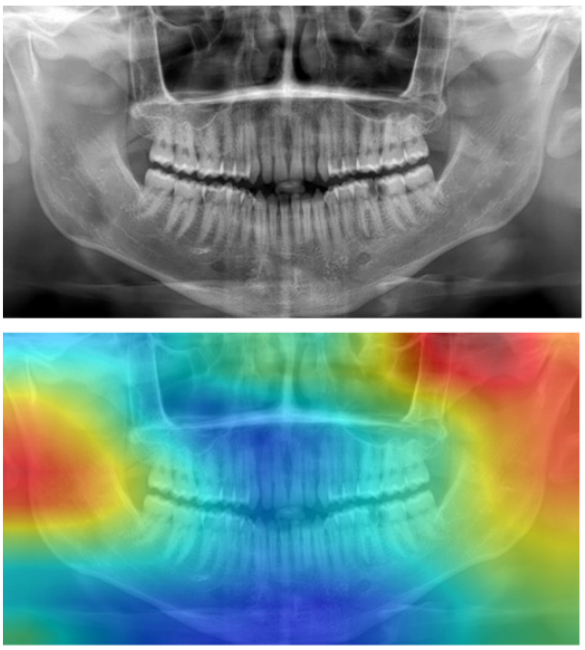
Model prediction: 0.6532
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



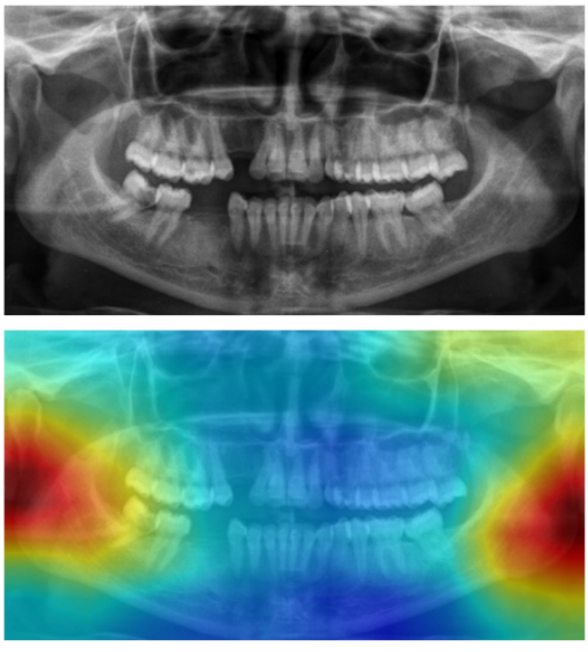
Model prediction: 0.5554
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



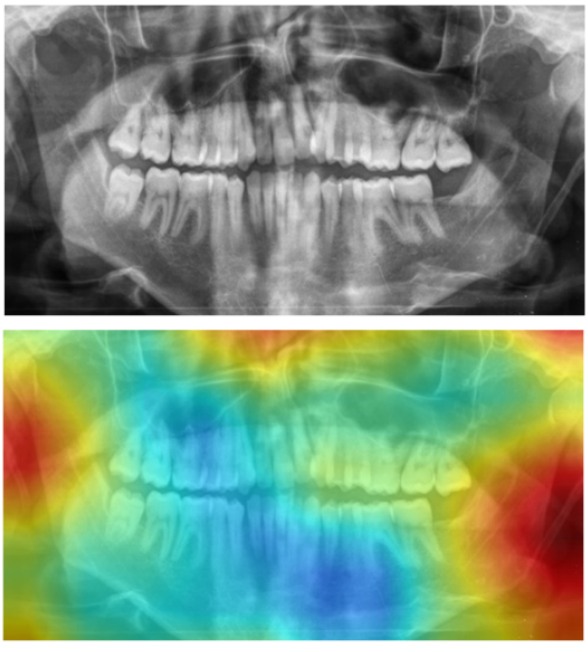
Model prediction: 0.5722
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



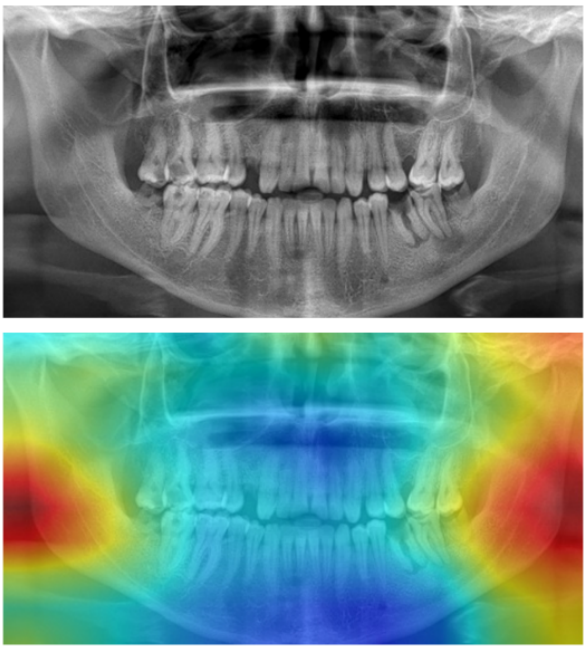
Model prediction: 0.5773
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



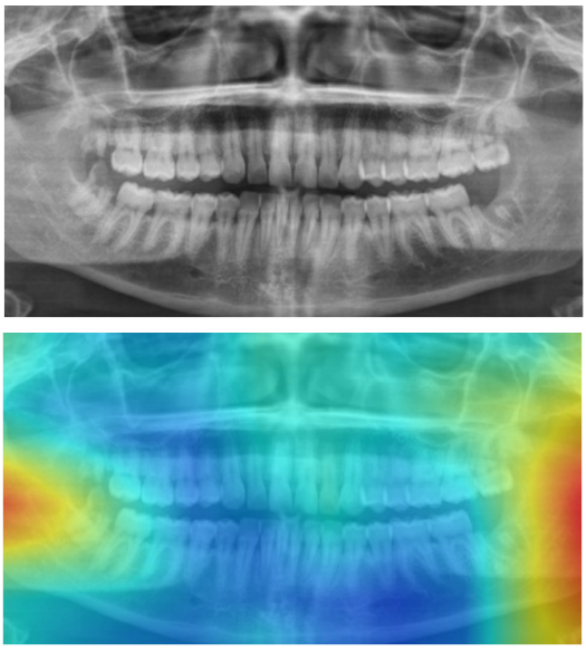
Model prediction: 0.7198
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



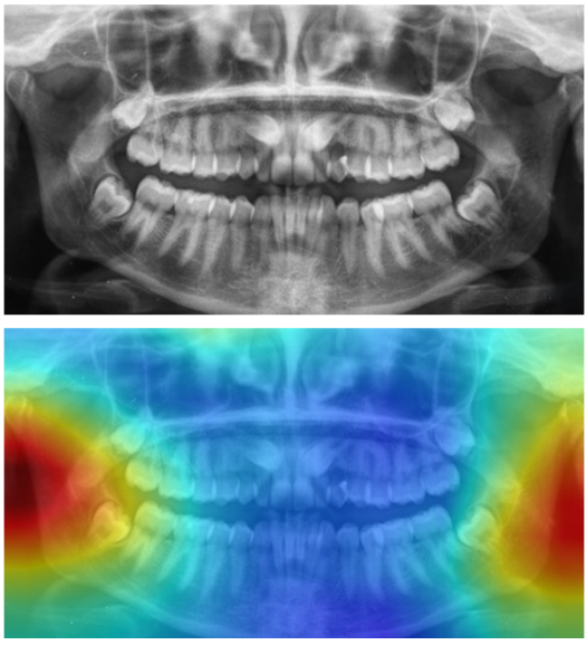
Model prediction: 0.5481
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



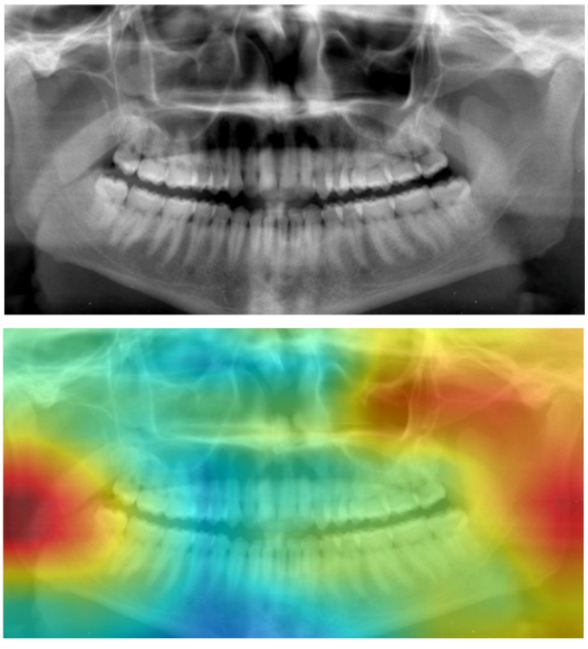
Model prediction: 0.5024
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



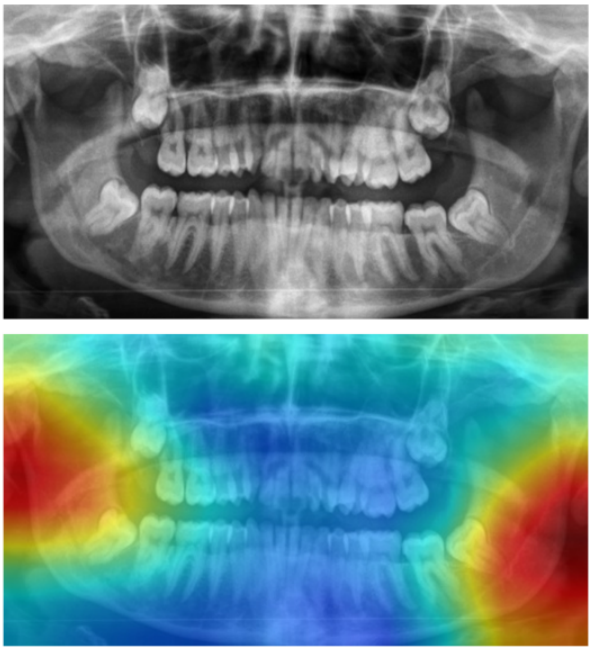
Model prediction: 0.5641
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



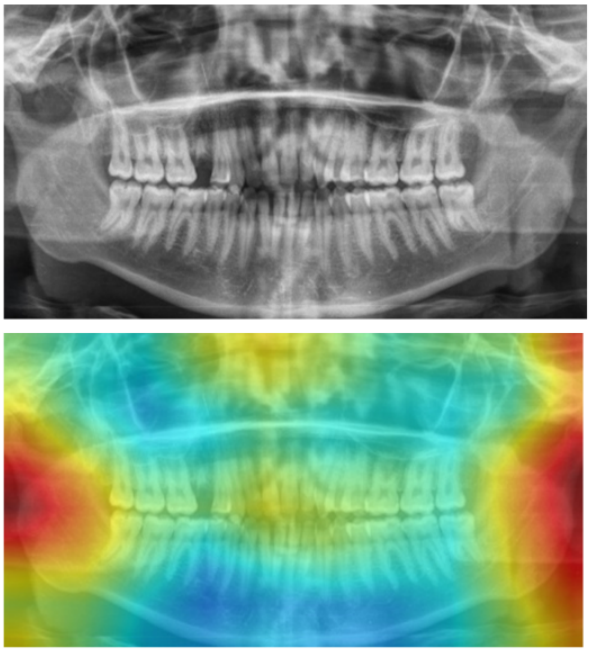
Model prediction: 0.8258
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



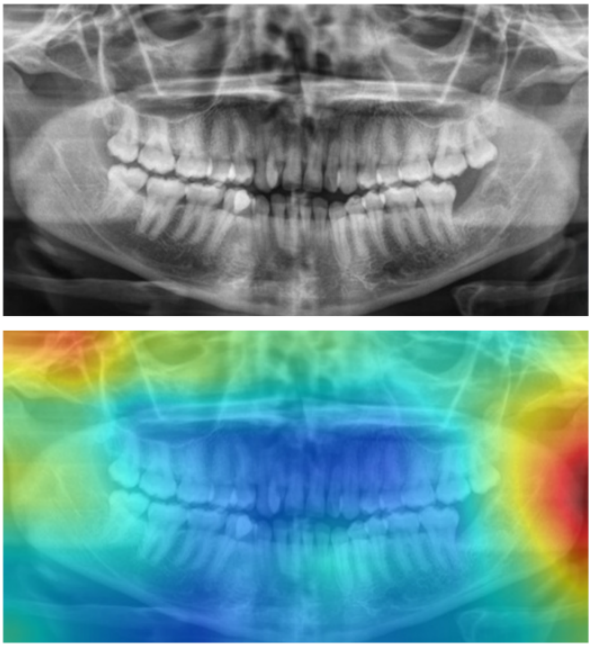
Model prediction: 0.5389
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



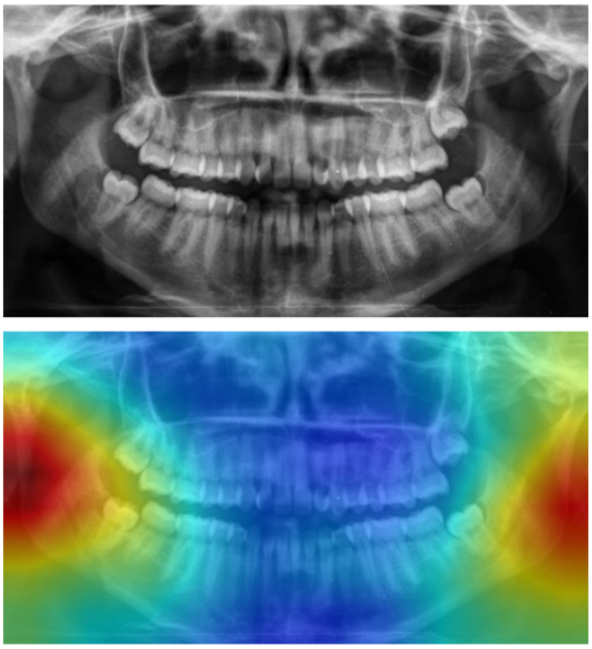
Model prediction: 0.6924
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



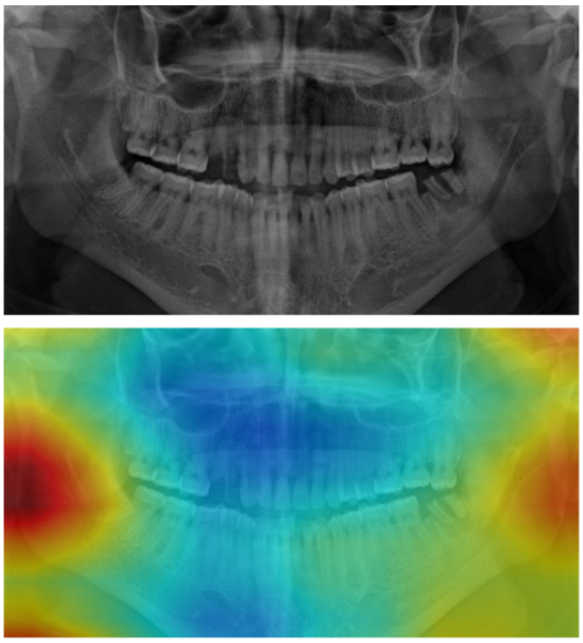
Model prediction: 0.5668
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



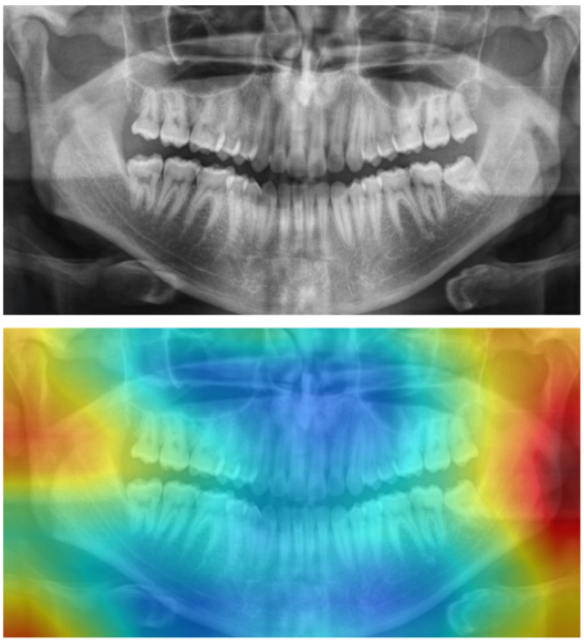
Model prediction: 0.5297
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



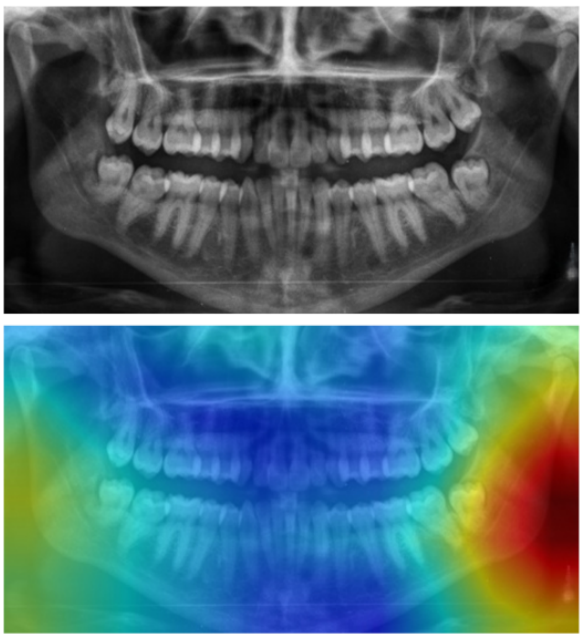
Model prediction: 0.8132
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



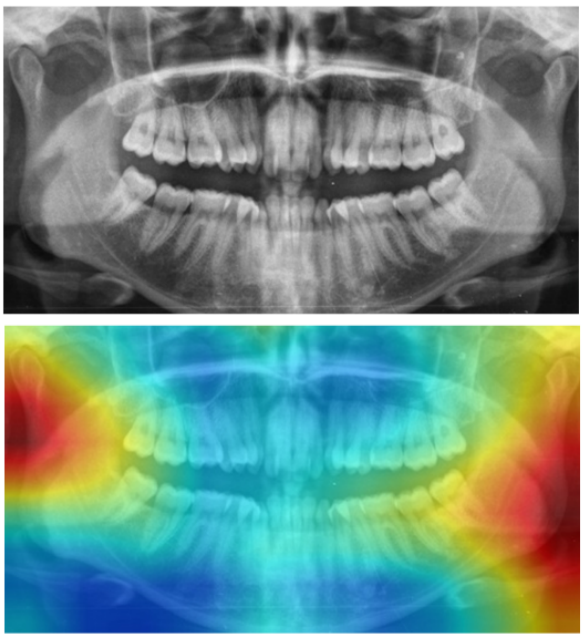
Model prediction: 0.5183
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



Model prediction: 0.5072
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



Model prediction: 0.5142
Actual Label: 24_30
Model classification: 16_23
Correct classification: No



Model prediction: 0.5825
Actual Label: 24_30
Model classification: 16_23
Correct classification: No

Anexo 5 – *Heatmaps* de Identificação Positiva

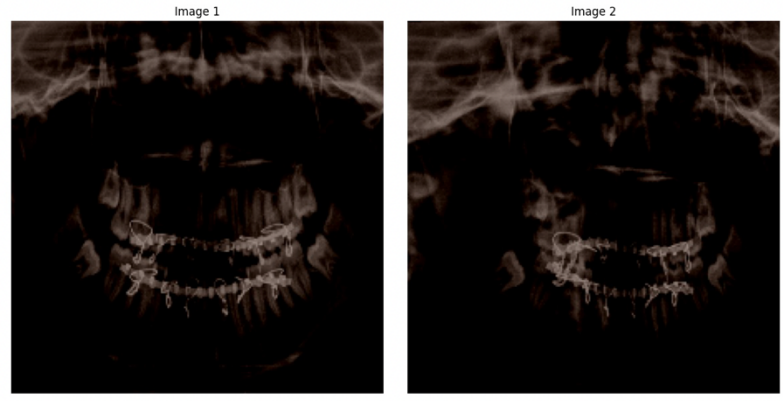
I – *Heatmaps* de OPG da classe "*Same*" classificadas como "*Same*"

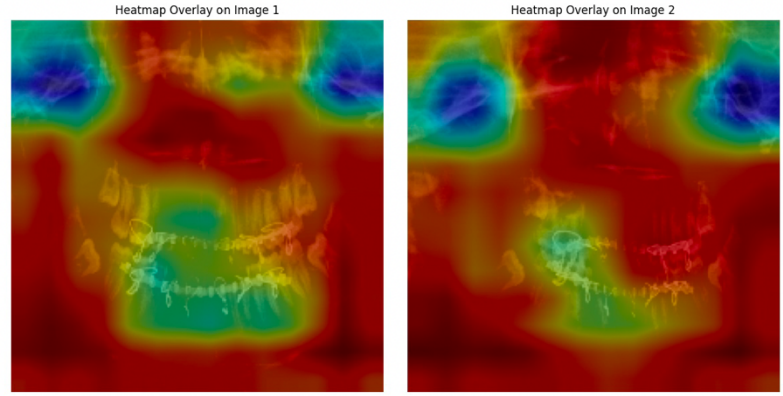
II – *Heatmaps* de OPG da classe "*Same*" classificadas como "*Different*"

III – *Heatmaps* de OPG da classe "*Different*" classificadas como "*Different*"

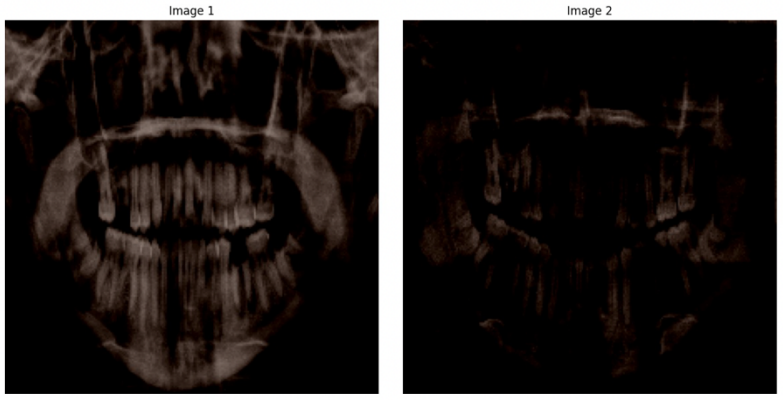
IV – *Heatmaps* de OPG da classe "*Different*" classificadas como "*Same*"

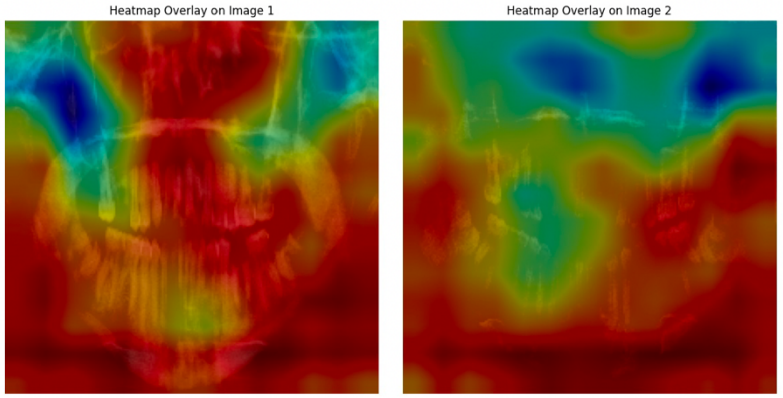
Anexo 5, I – *Heatmaps* de OPG da classe "*Same*" classificadas como "*Same*"



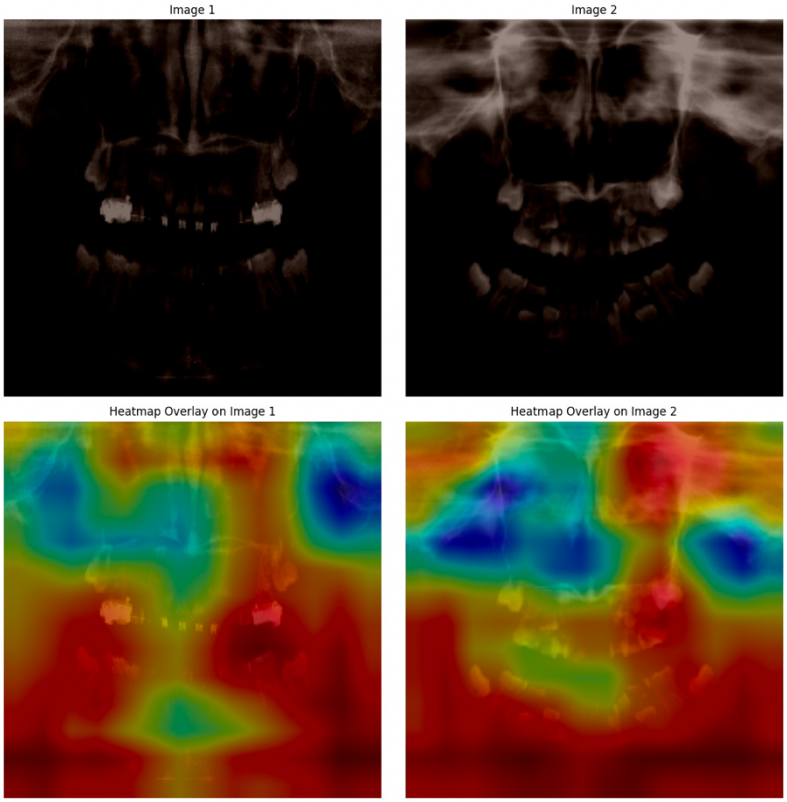



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.8606
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 8
```

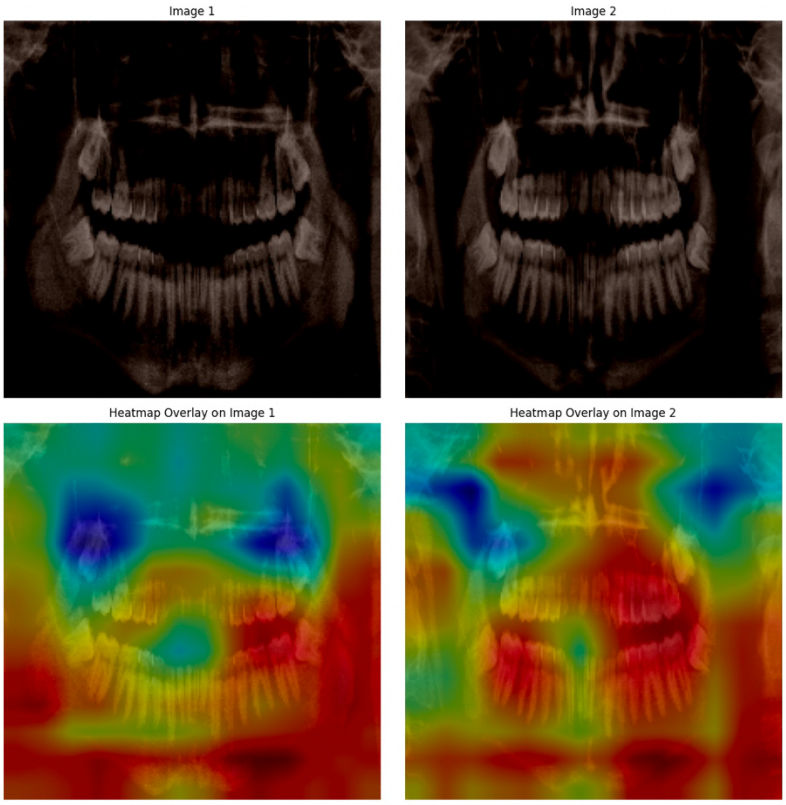




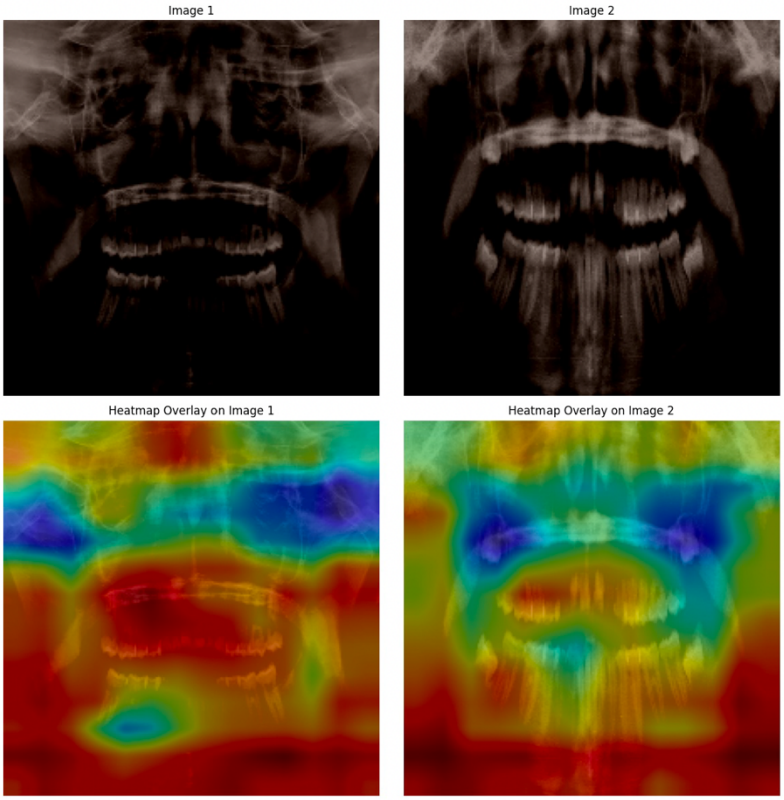

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 24ms/step
Model prediction: 0.5664
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 10
```



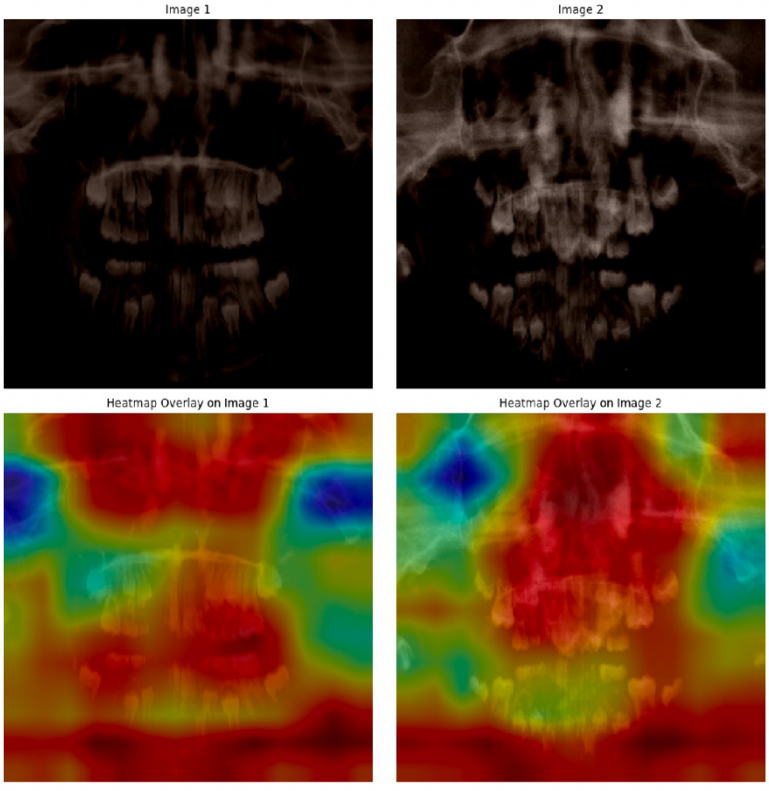

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.7067
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 15
```



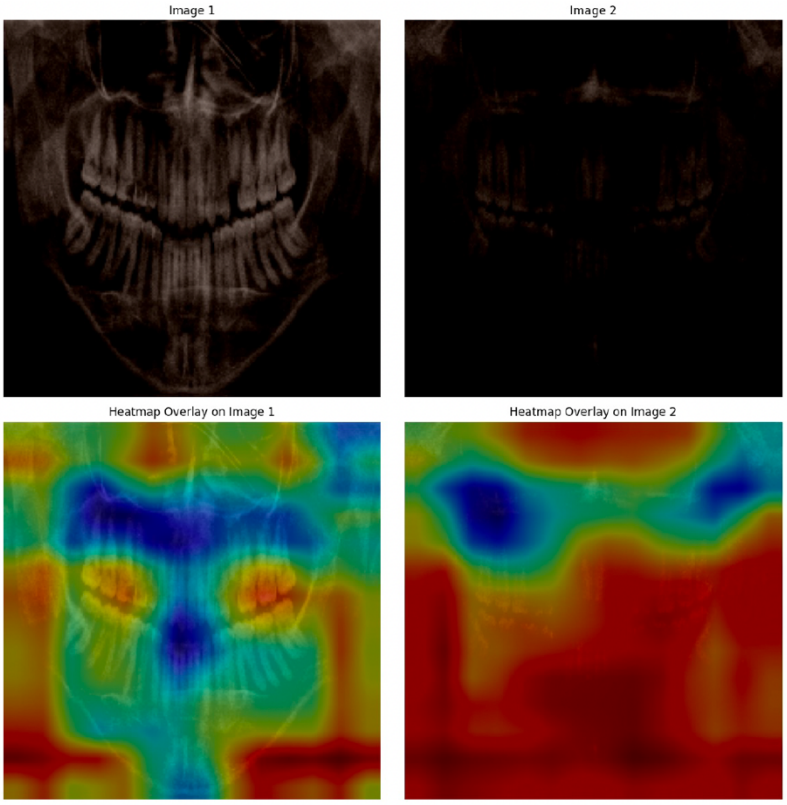

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.5857
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 26
```



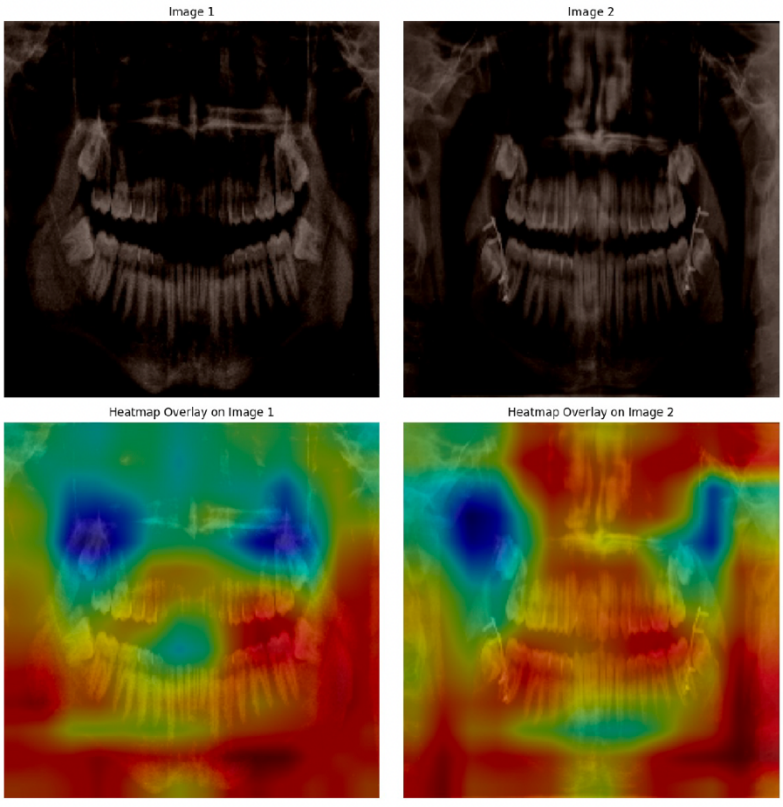

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 26ms/step
Model prediction: 0.5158
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 27
```



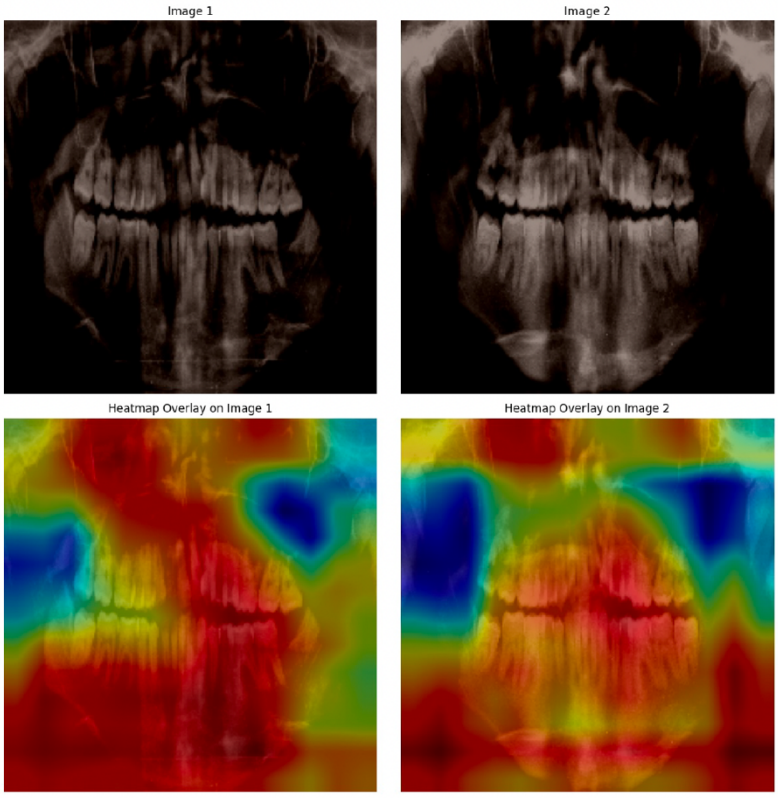

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 38ms/step
Model prediction: 0.8384
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 35
```



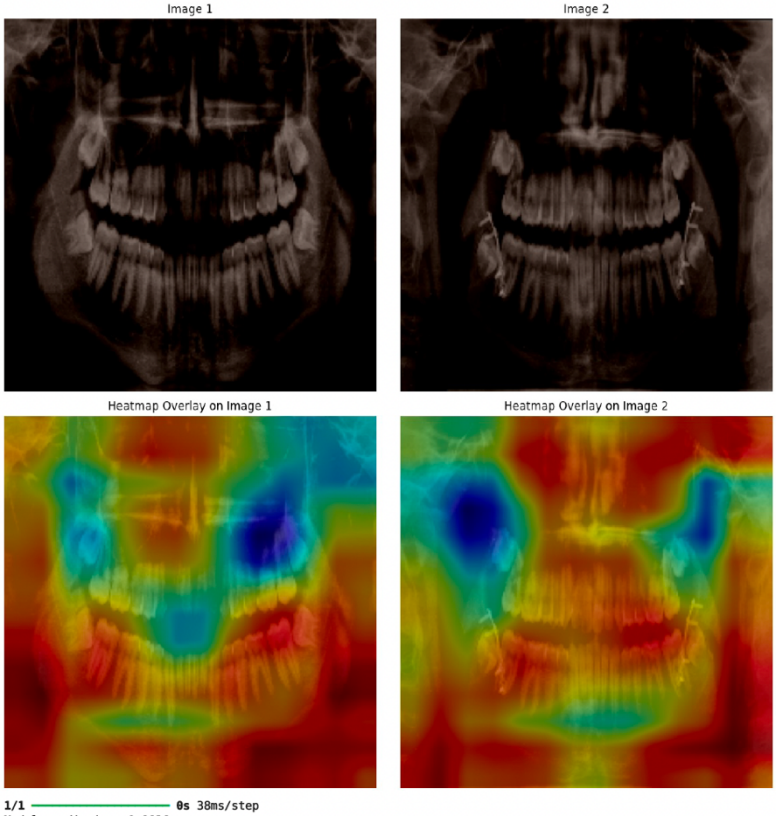

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 35ms/step
Model prediction: 0.5764
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 39
```



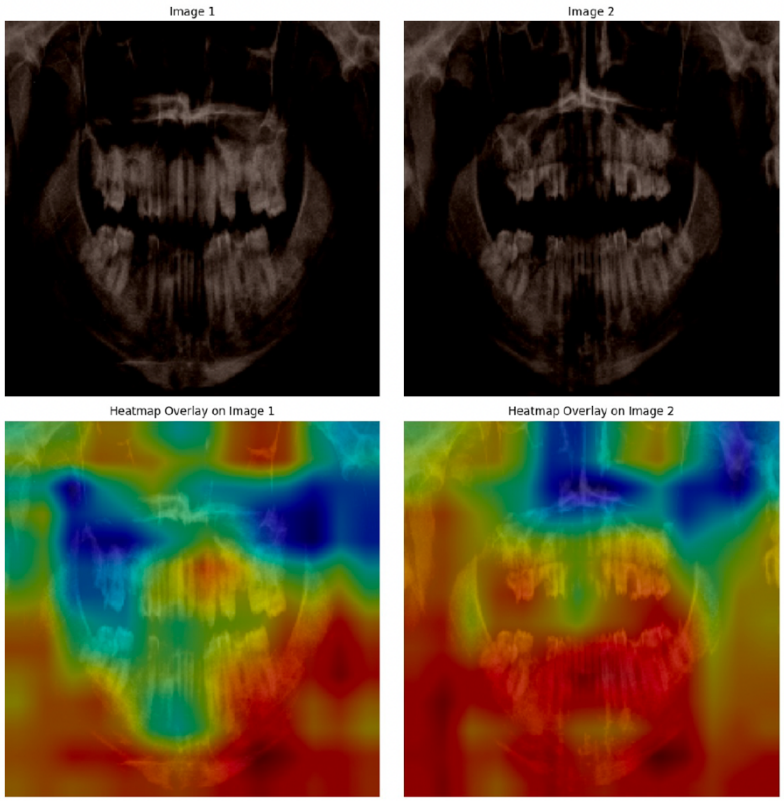

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 49ms/step
Model prediction: 0.8184
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 42
```



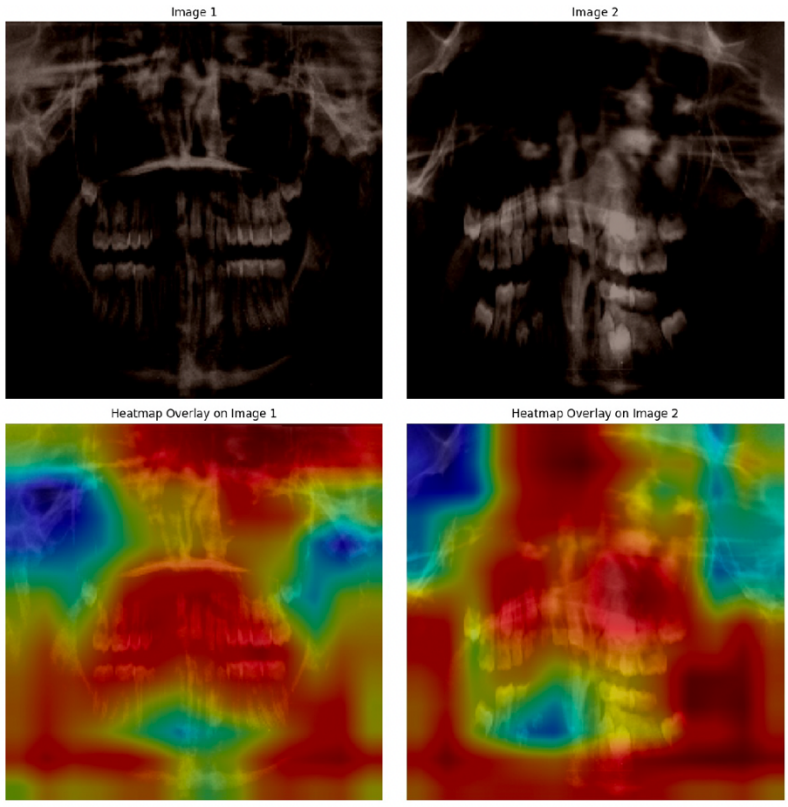

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 30ms/step
Model prediction: 0.5219
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 43
```



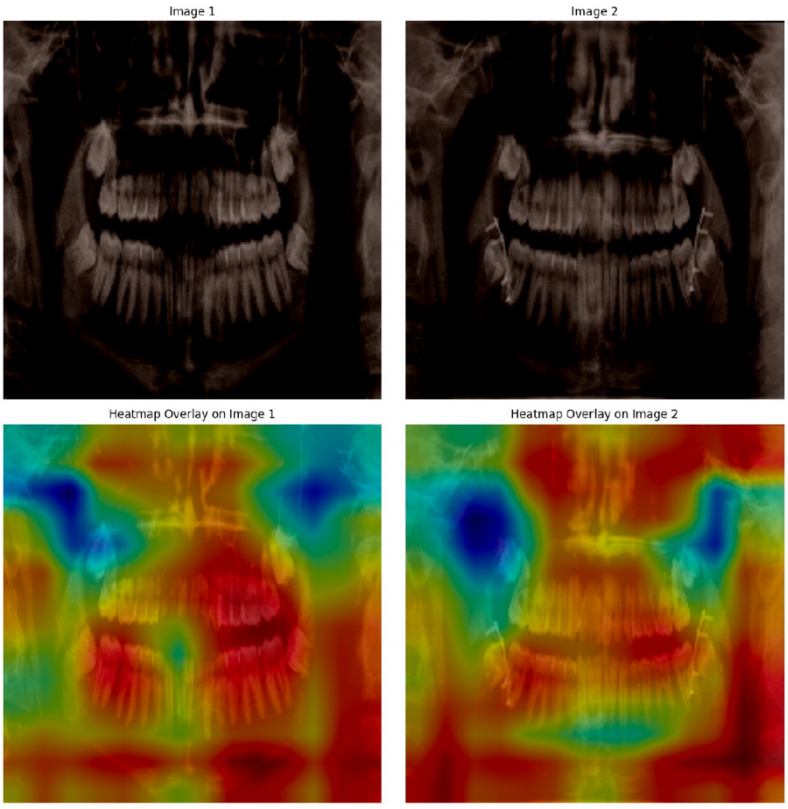

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 38ms/step
Model prediction: 0.8836
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 44
```



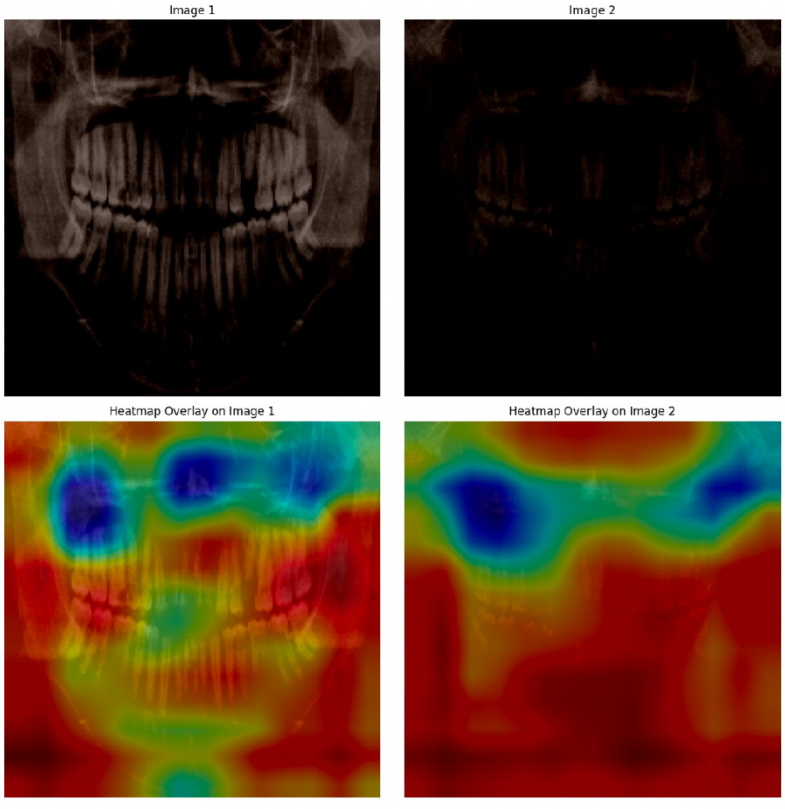

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 42ms/step
Model prediction: 0.6656
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 46
```



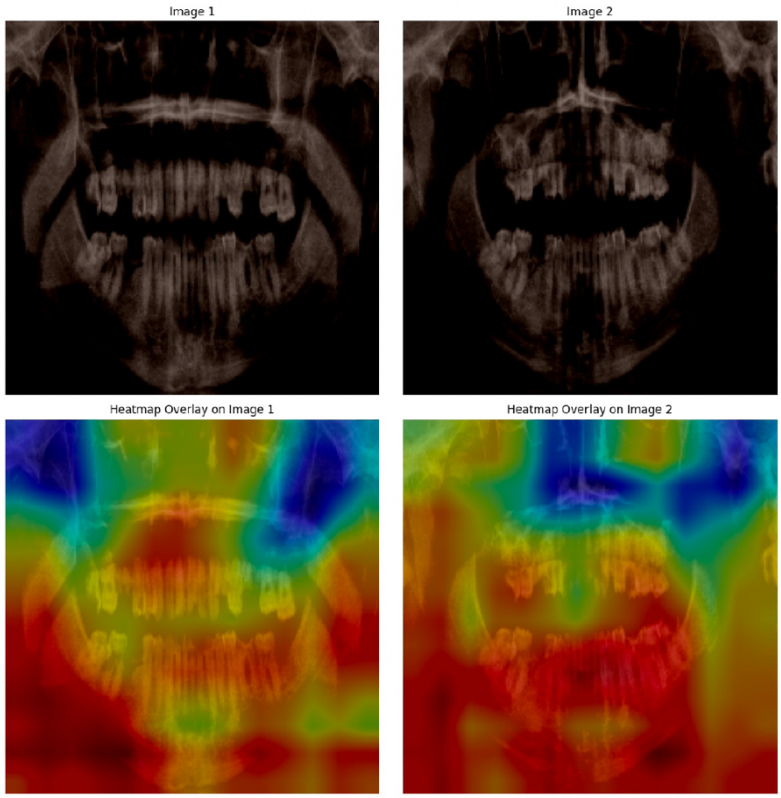

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 32ms/step
Model prediction: 0.8355
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 61
```



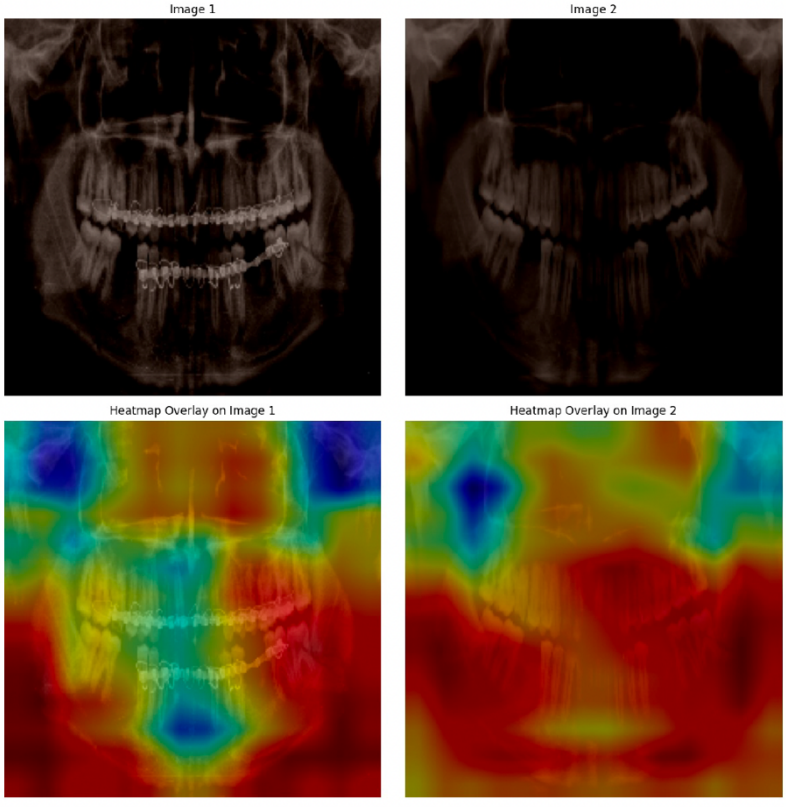

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 44ms/step
Model prediction: 0.8444
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 72
```



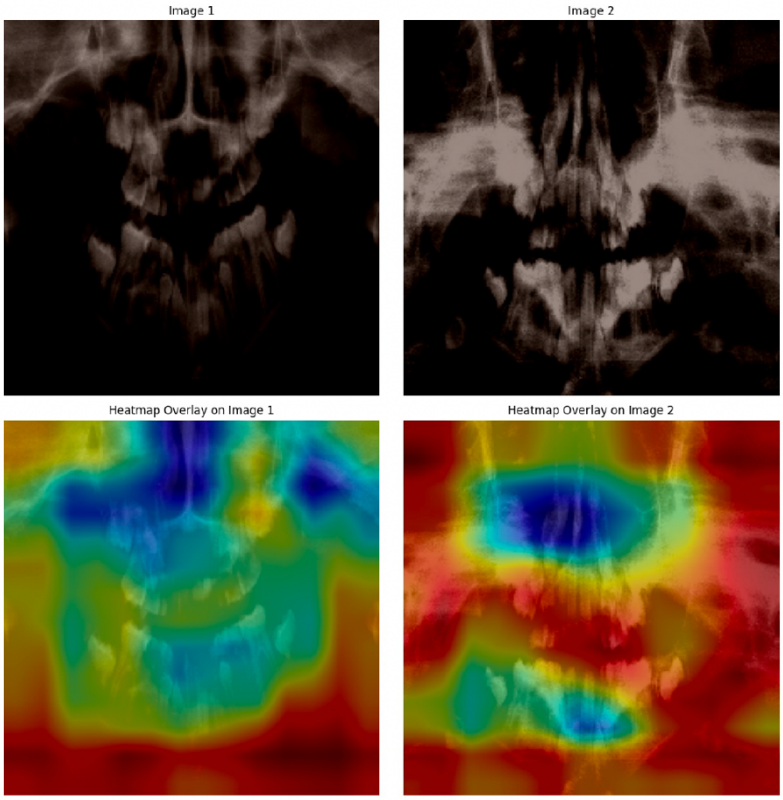

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 29ms/step
Model prediction: 0.6817
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 76
```



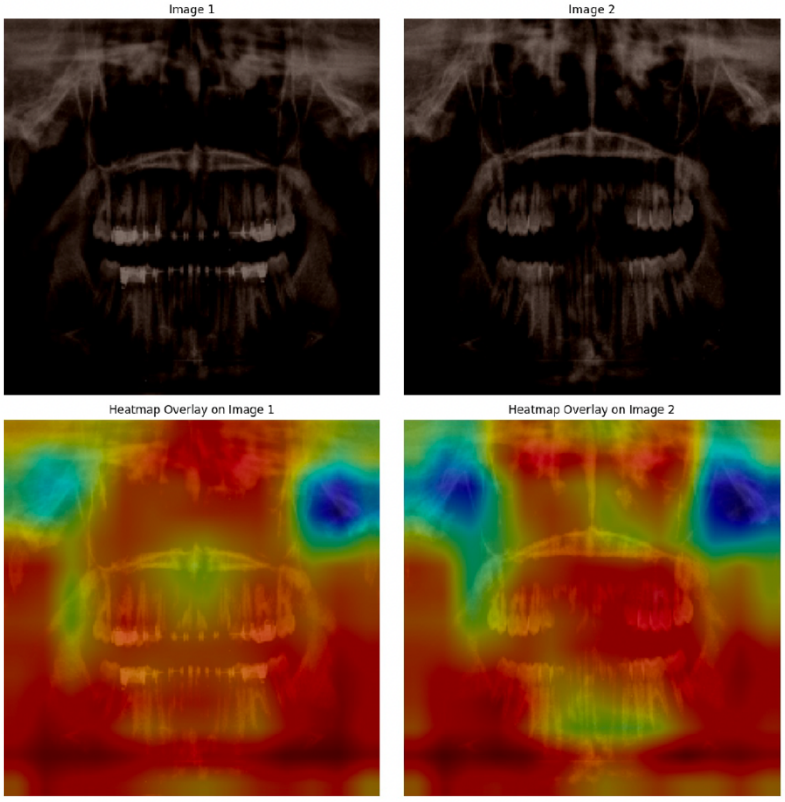

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.5154
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 81
```



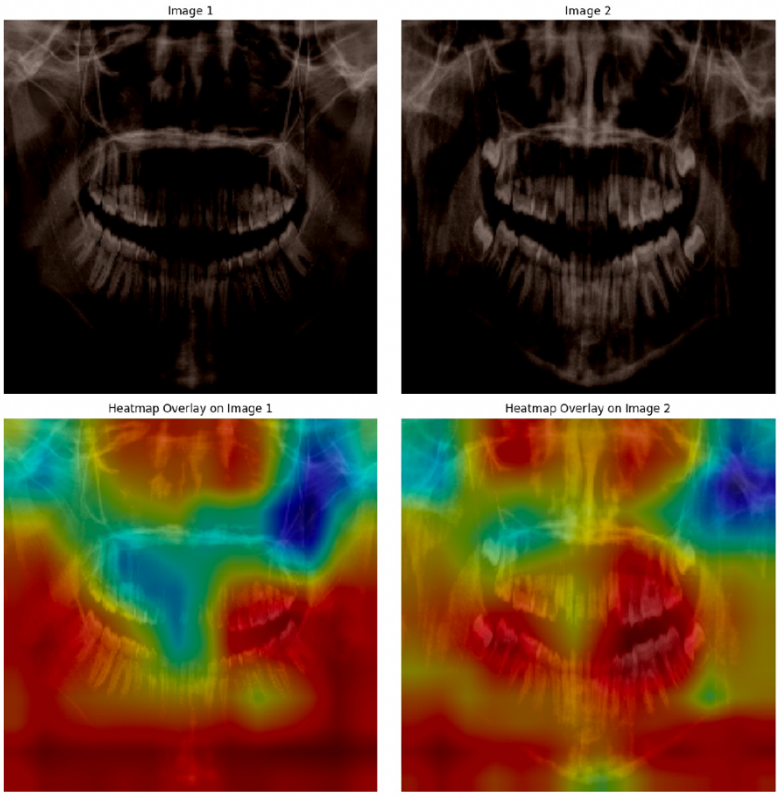

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 36ms/step
Model prediction: 0.7846
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 85
```



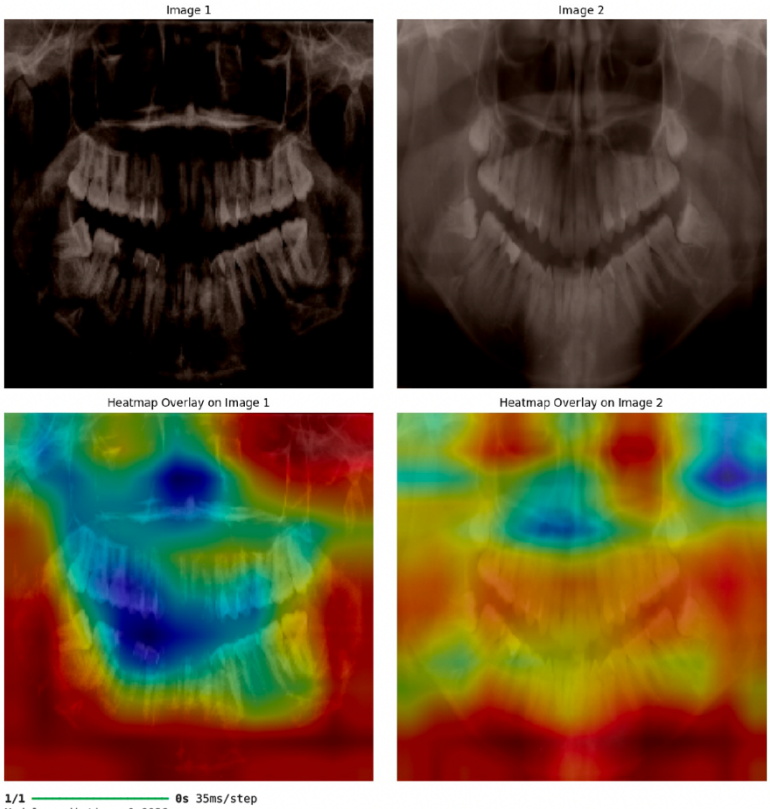

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.7538
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 92
```



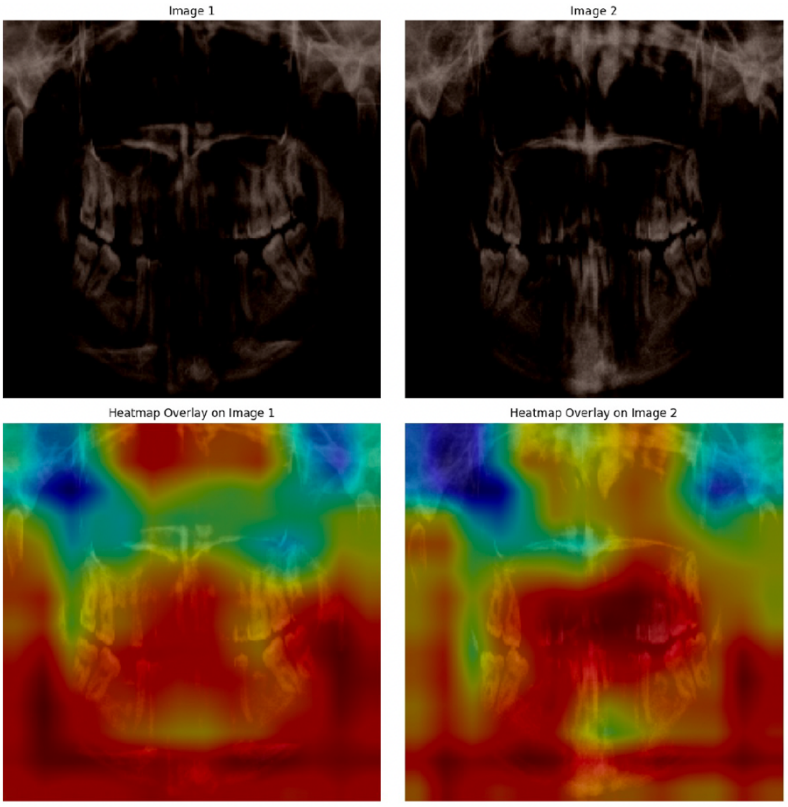

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 24ms/step
Model prediction: 0.8011
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 96
```



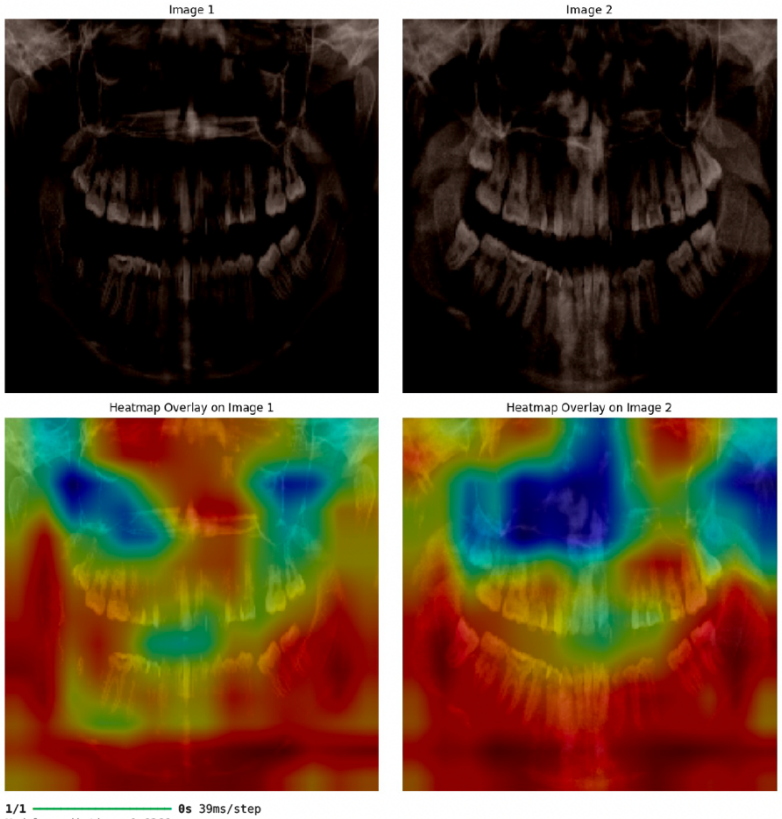

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 44ms/step
Model prediction: 0.5359
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 107
```



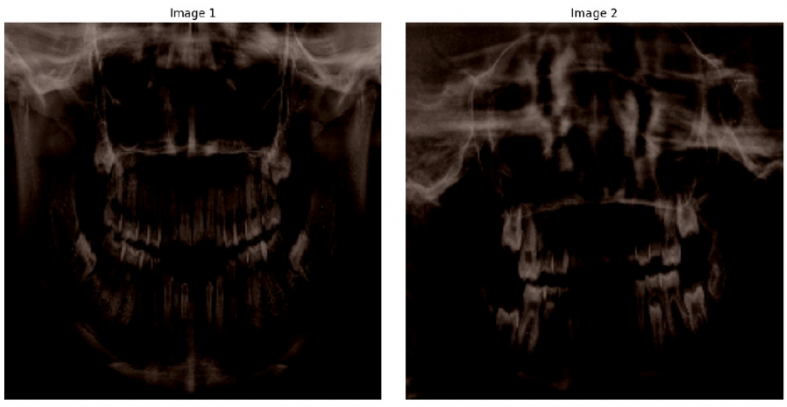

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 35ms/step
Model prediction: 0.8938
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 124
```

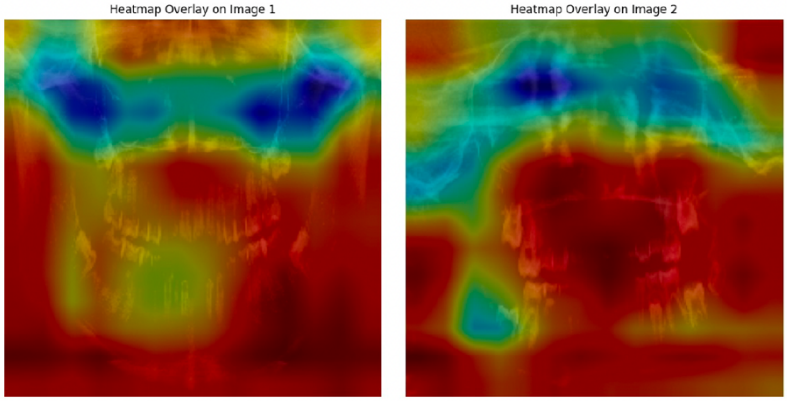



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 39ms/step
Model prediction: 0.5721
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 140
```

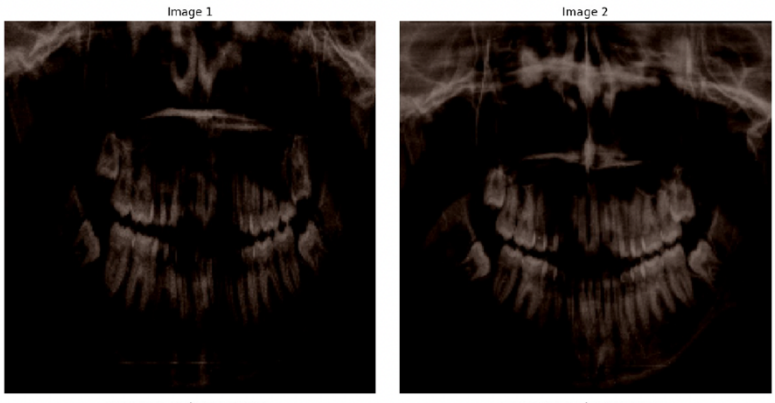


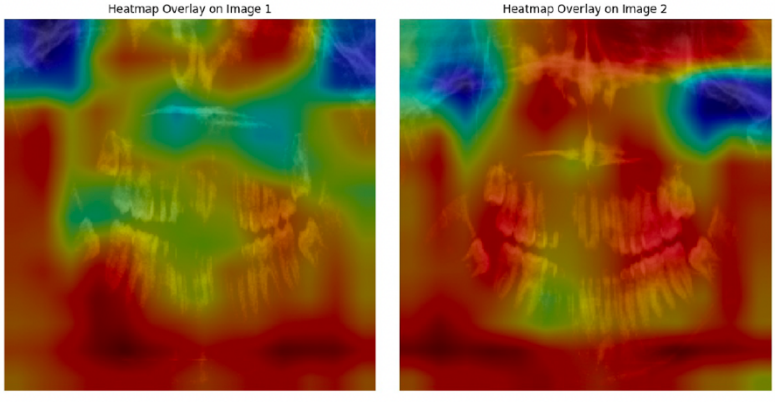

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 39ms/step
Model prediction: 0.6368
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 141
```



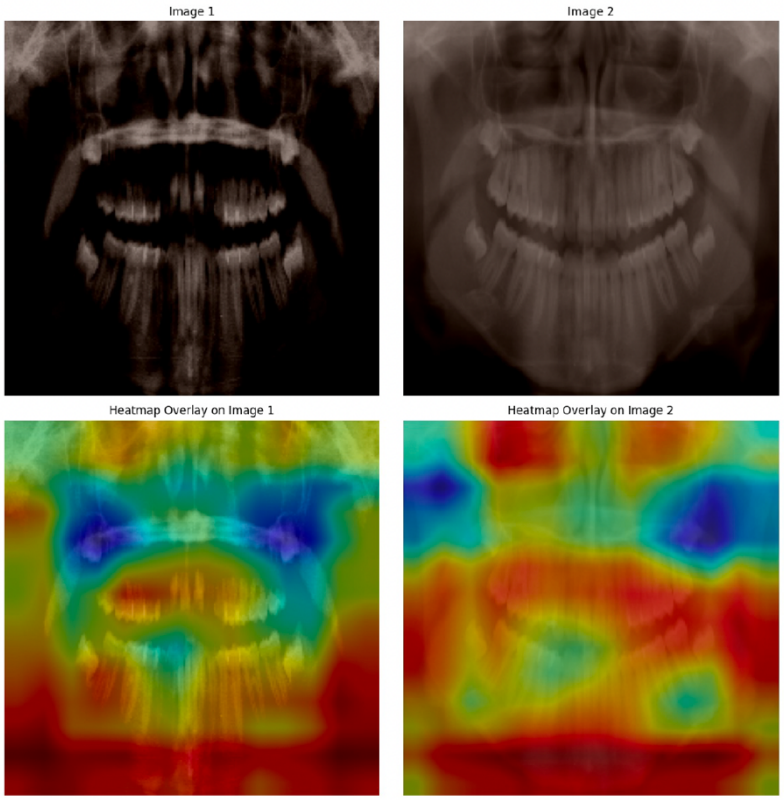



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 32ms/step
Model prediction: 0.6772
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 143
```

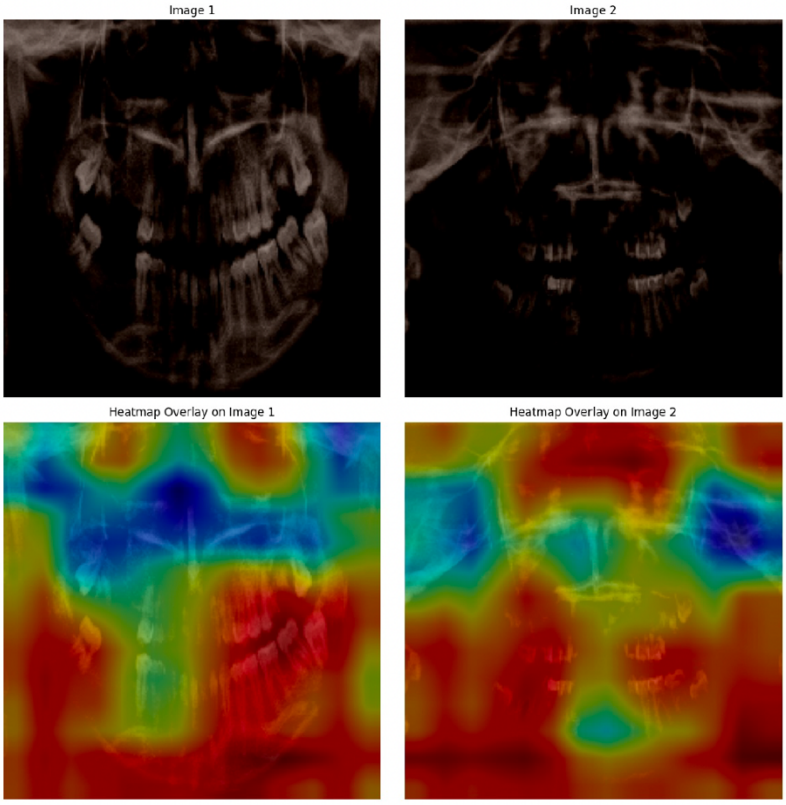




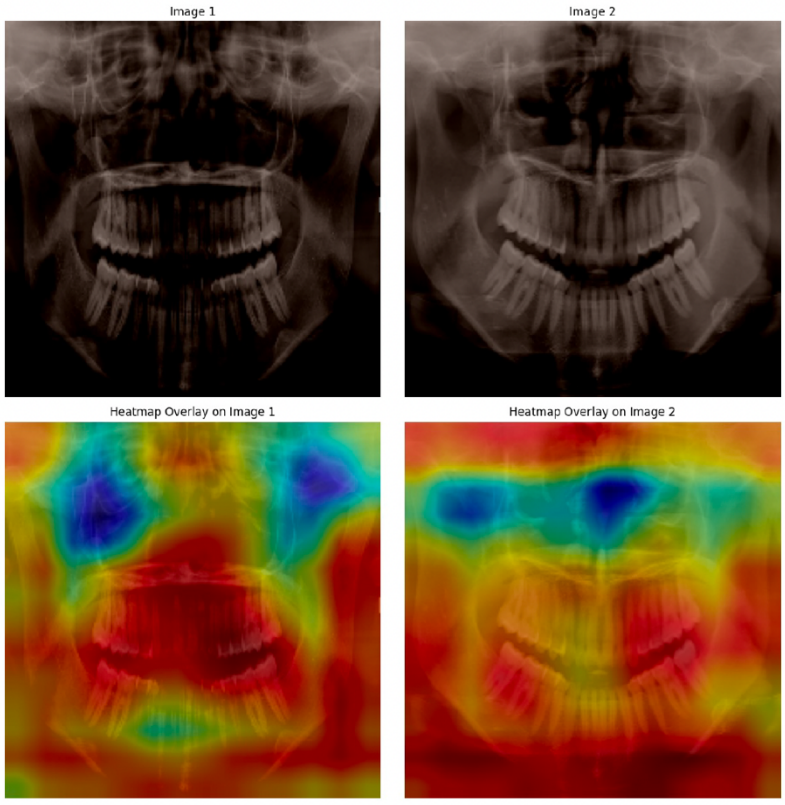

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.8420
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 146
```



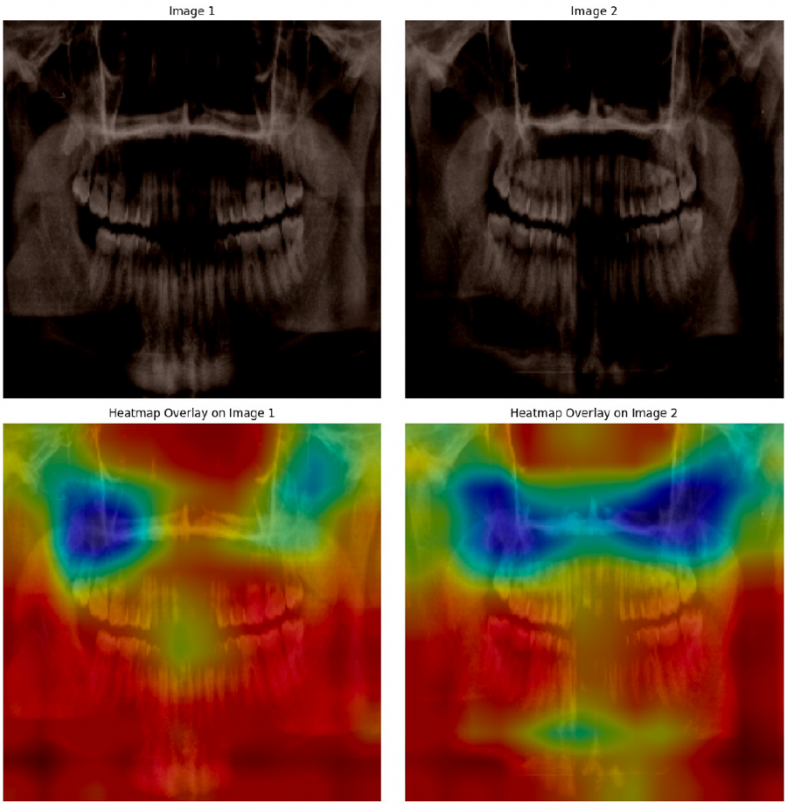

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.8776
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 153
```



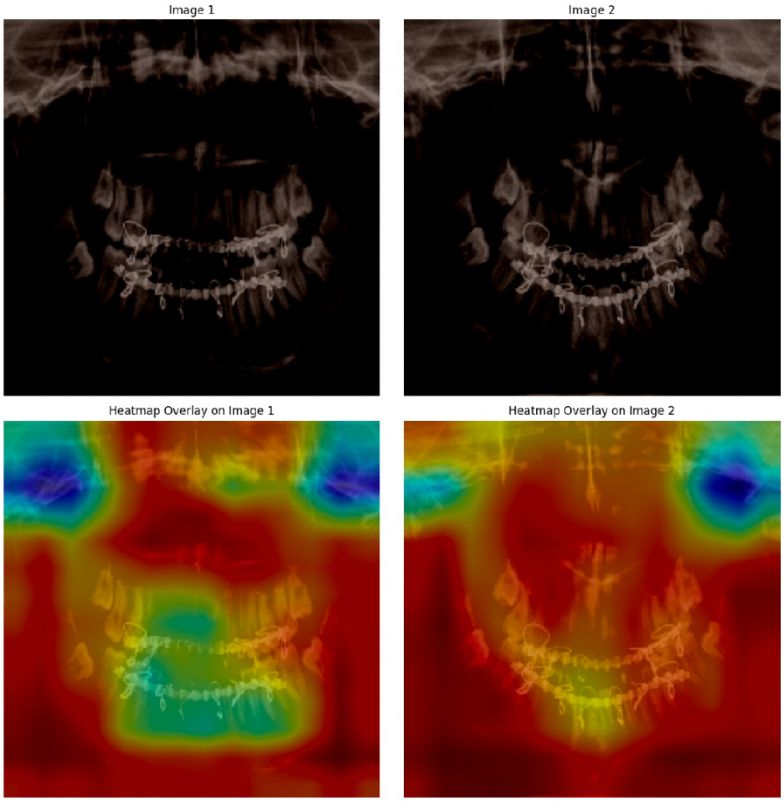

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 41ms/step
Model prediction: 0.6224
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 154
```




```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.7882
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 147
```

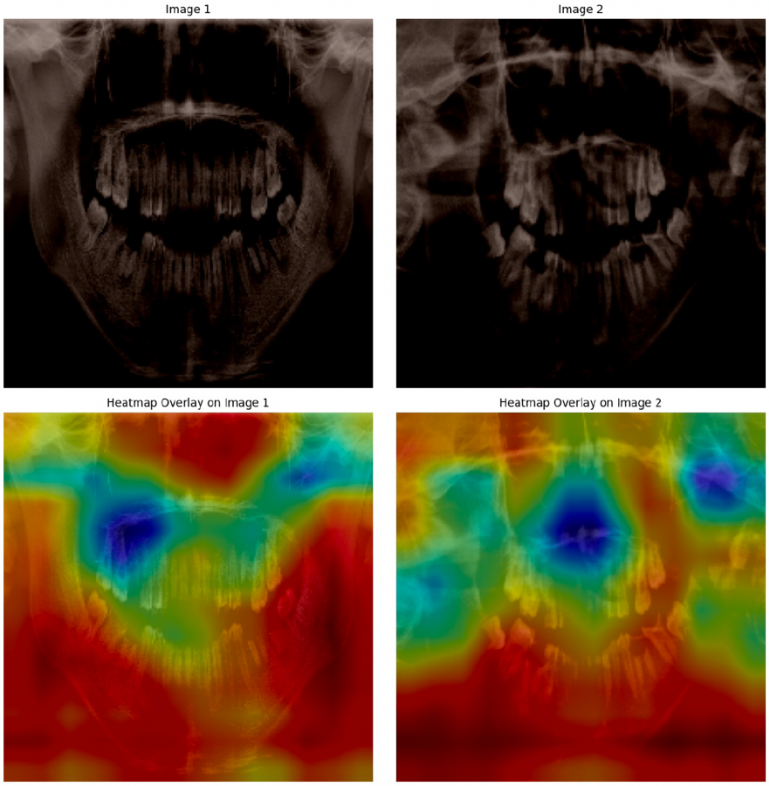



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 39ms/step
Model prediction: 0.5524
Actual label: Same person
Model classification: Same person
Correct classification: Yes
```

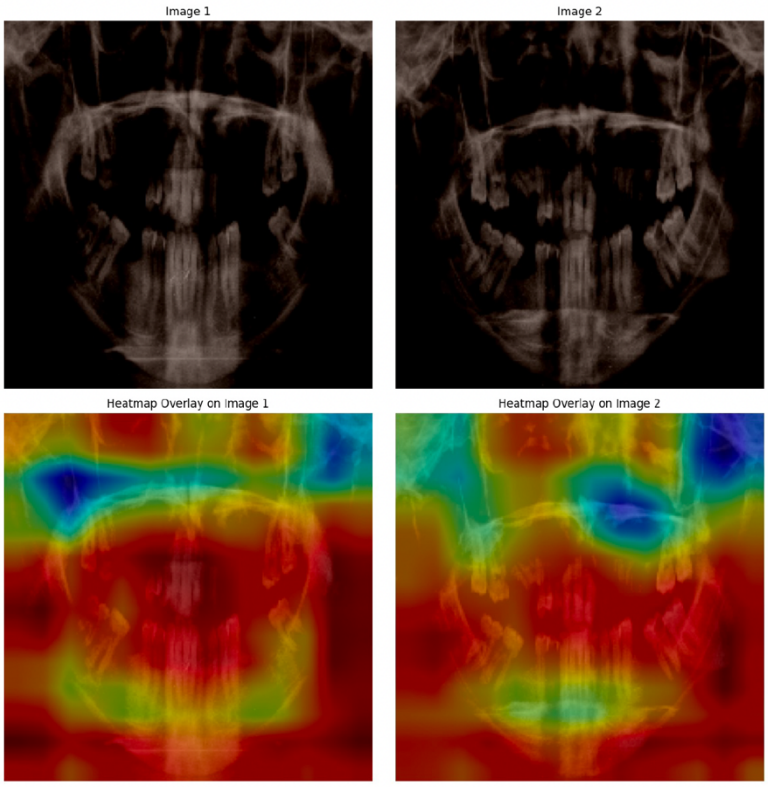



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.8813
Actual label: Same person
Model classification: Same person
Correct classification: Yes
Pair 159
```

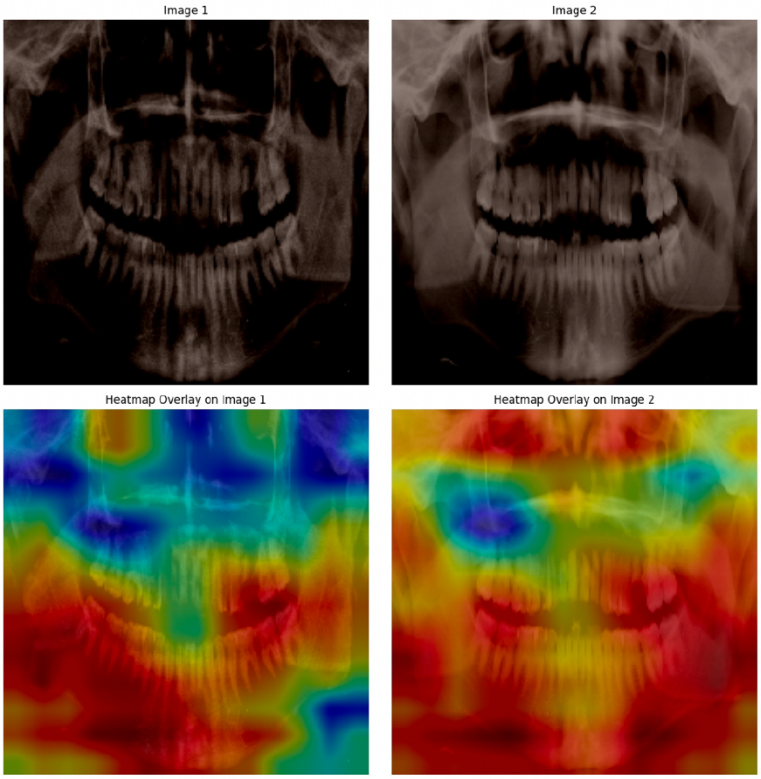
Anexo 5, II – *Heatmaps* de OPG da classe "*Same*" classificadas como "*Different*"



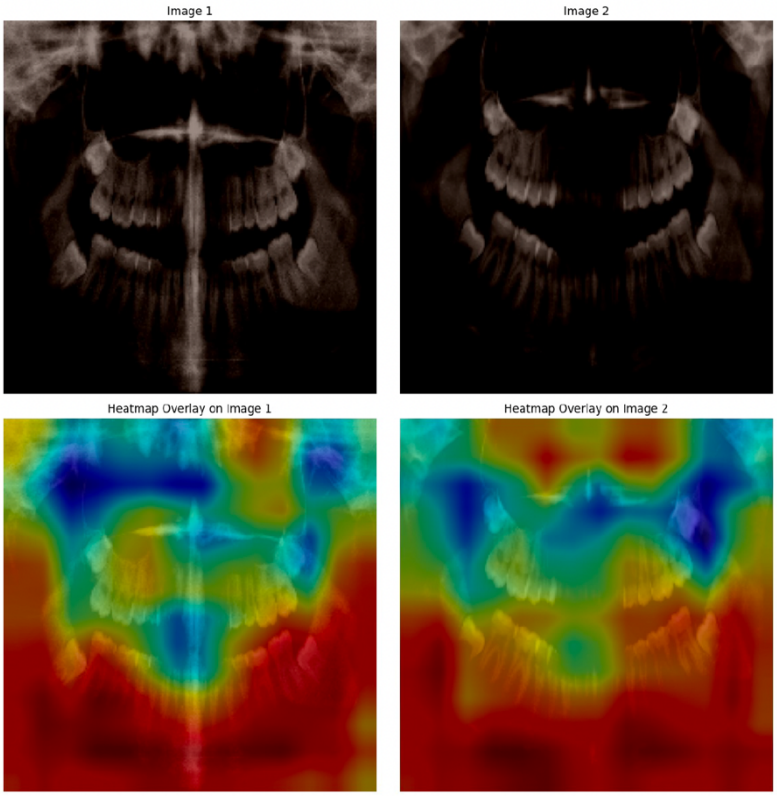

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.4785
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 12
```



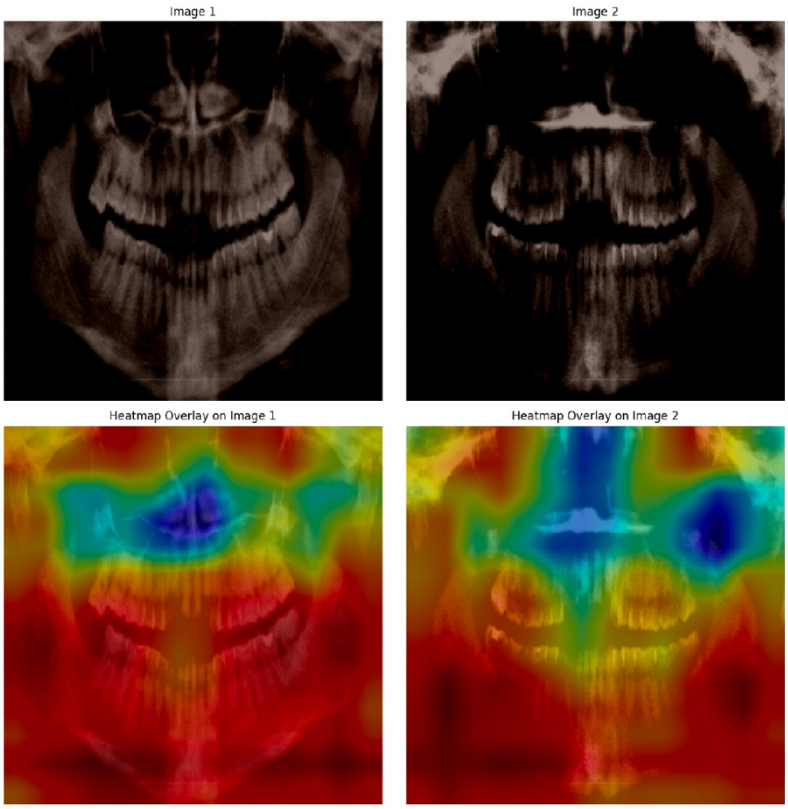

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 39ms/step
Model prediction: 0.3818
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 33
```



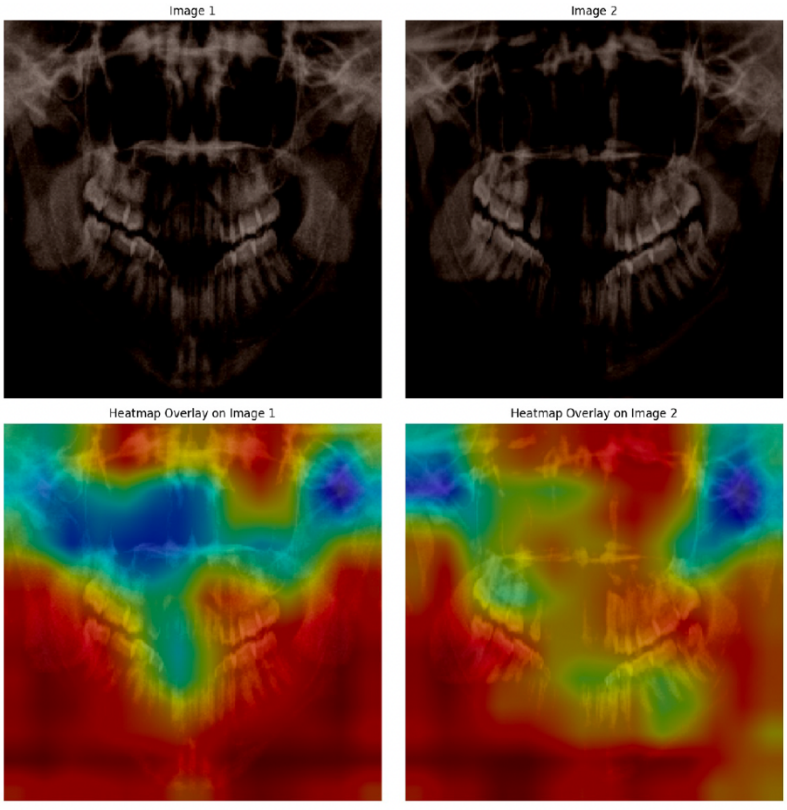

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 37ms/step
Model prediction: 0.3190
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 52
```



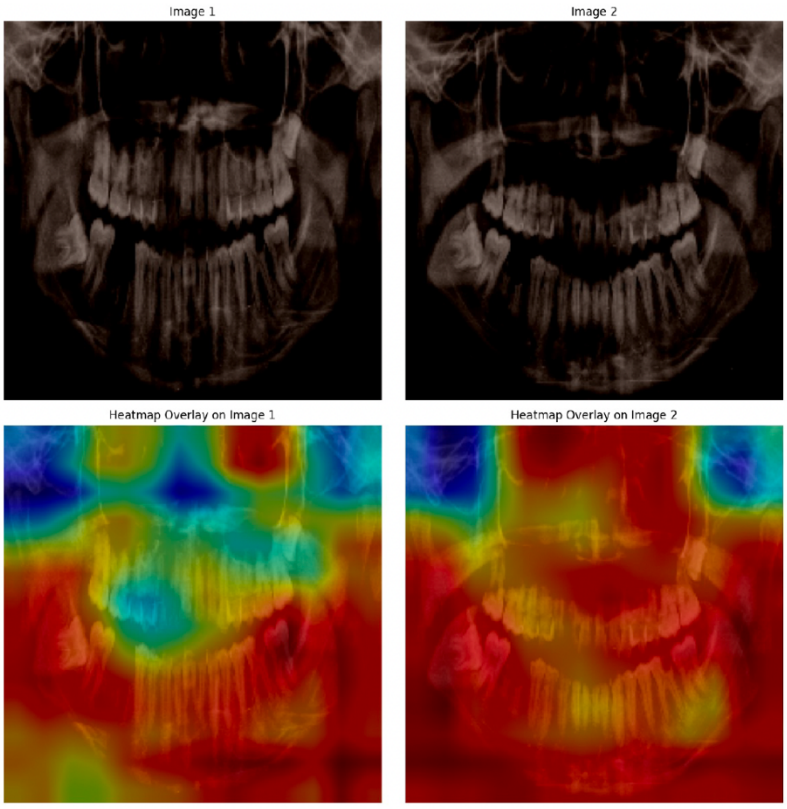

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 23ms/step
Model prediction: 0.4319
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 53
```



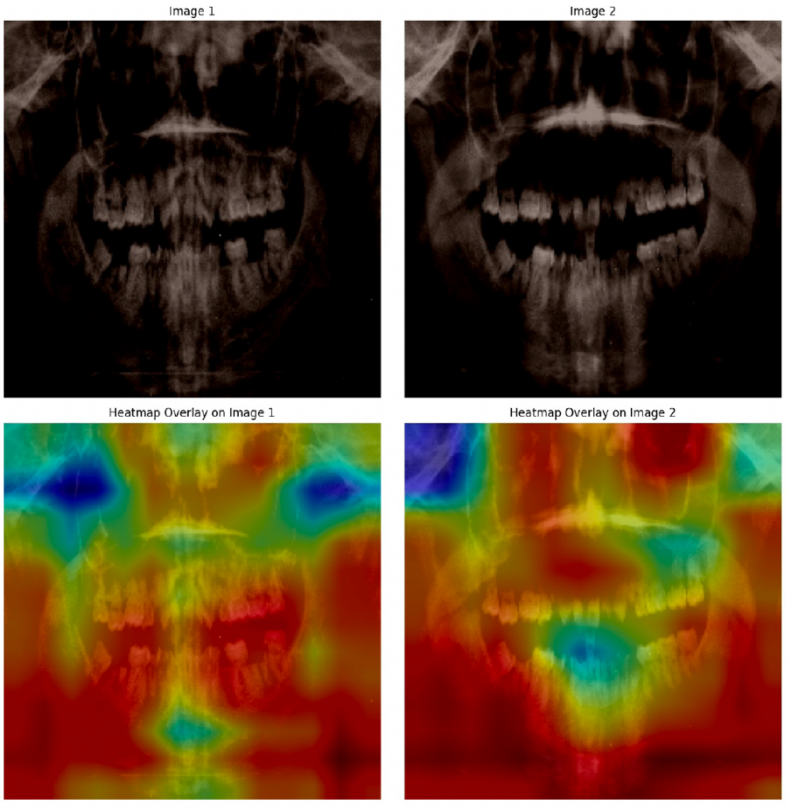

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 30ms/step
Model prediction: 0.1617
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 67
```



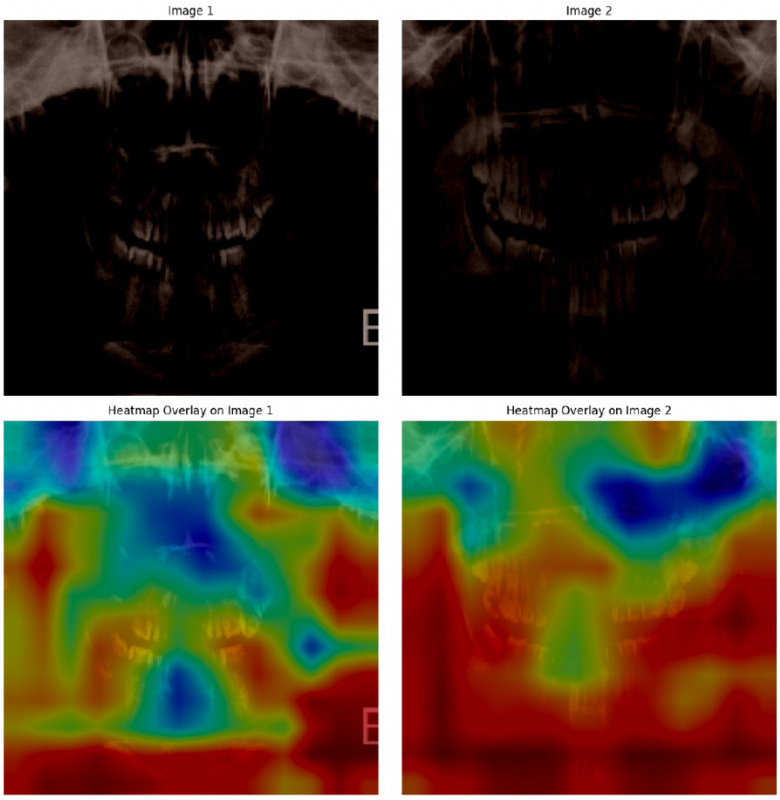

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.4678
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 69
```



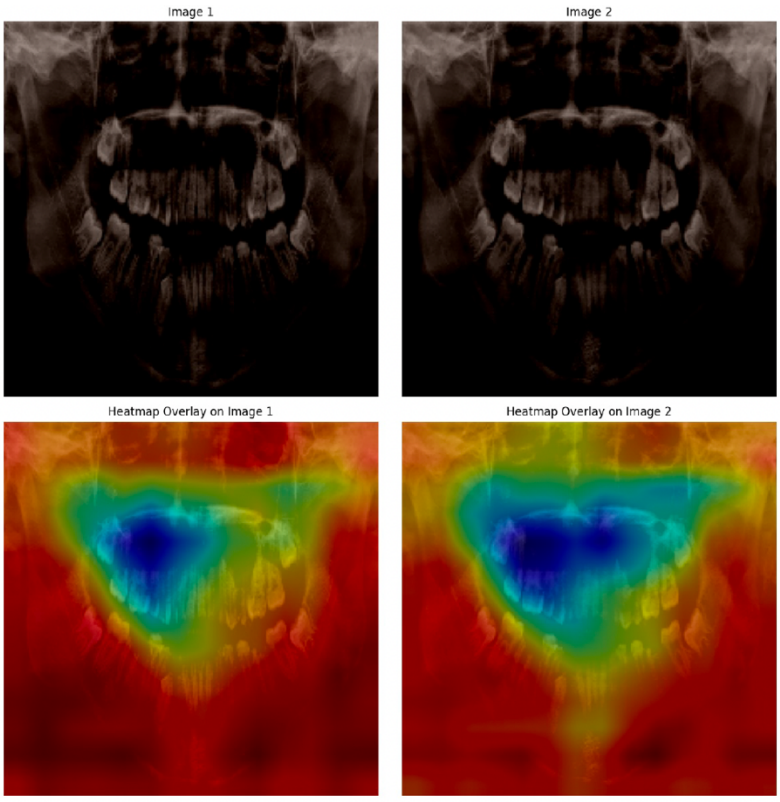

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 44ms/step
Model prediction: 0.1837
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 89
```



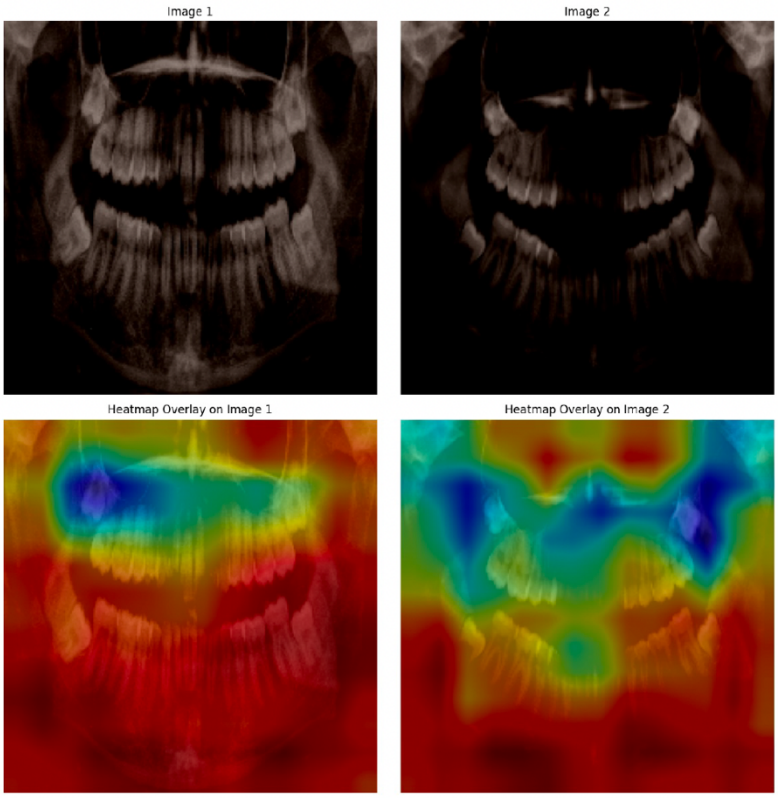

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 49ms/step
Model prediction: 0.1726
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 100
```



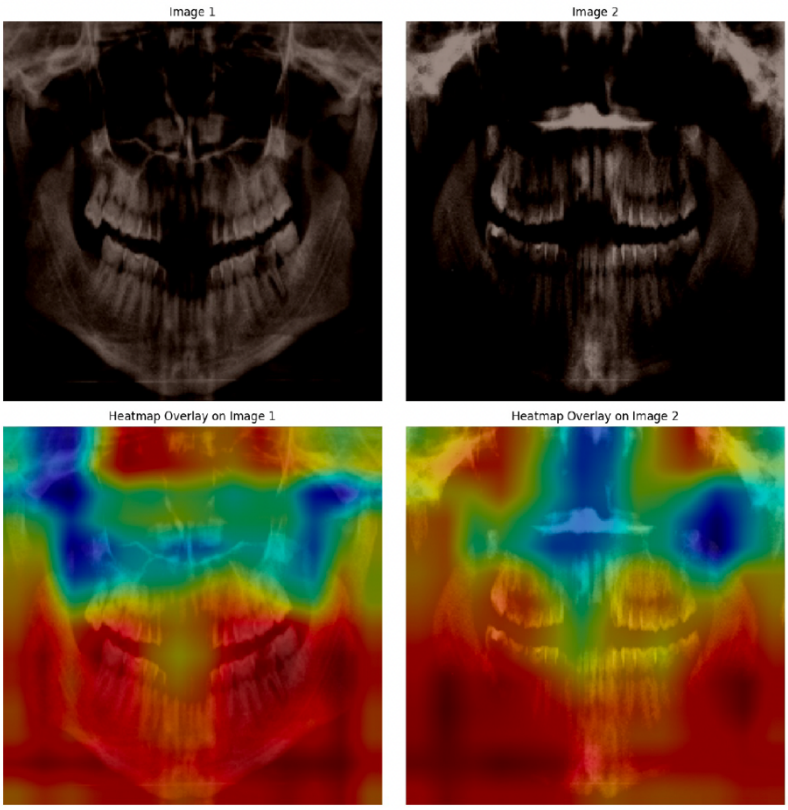

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 37ms/step
Model prediction: 0.2428
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 102
```



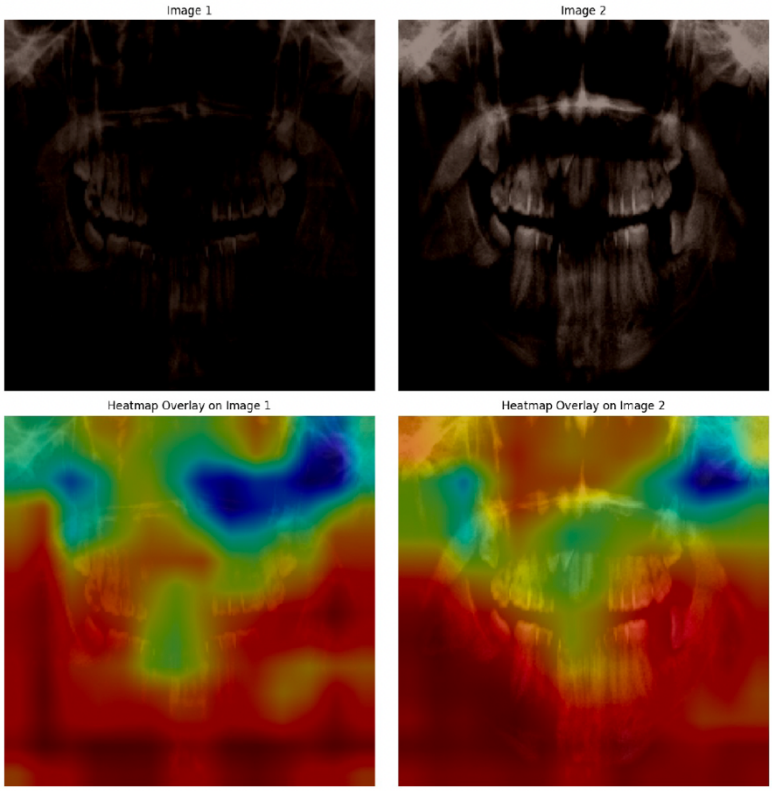

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 29ms/step
Model prediction: 0.1876
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 109
```



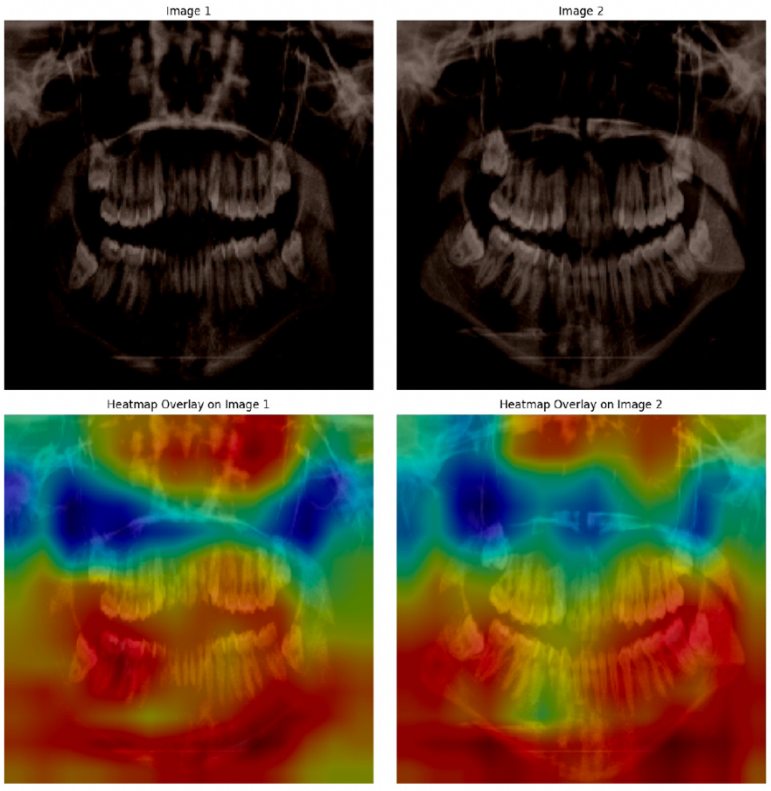

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.3945
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 115
```




```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.2433
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 120
```

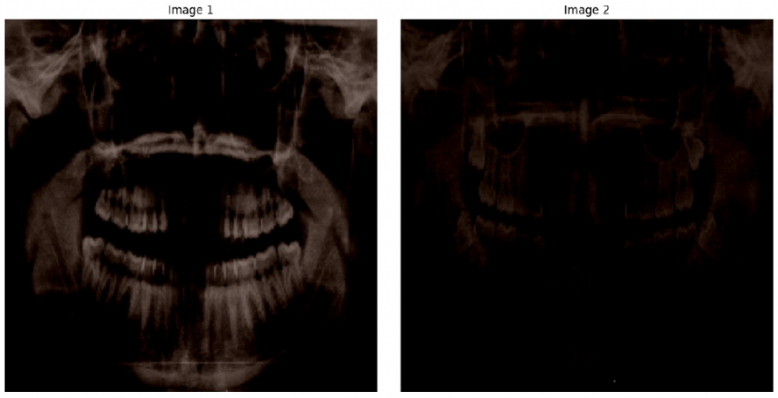



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 23ms/step
Model prediction: 0.2488
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 151
```

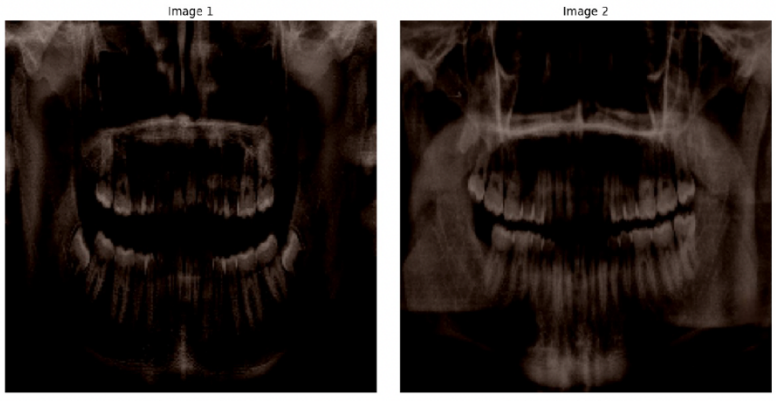



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 41ms/step
Model prediction: 0.3405
Actual label: Same person
Model classification: Different people
Correct classification: No
Pair 162
```

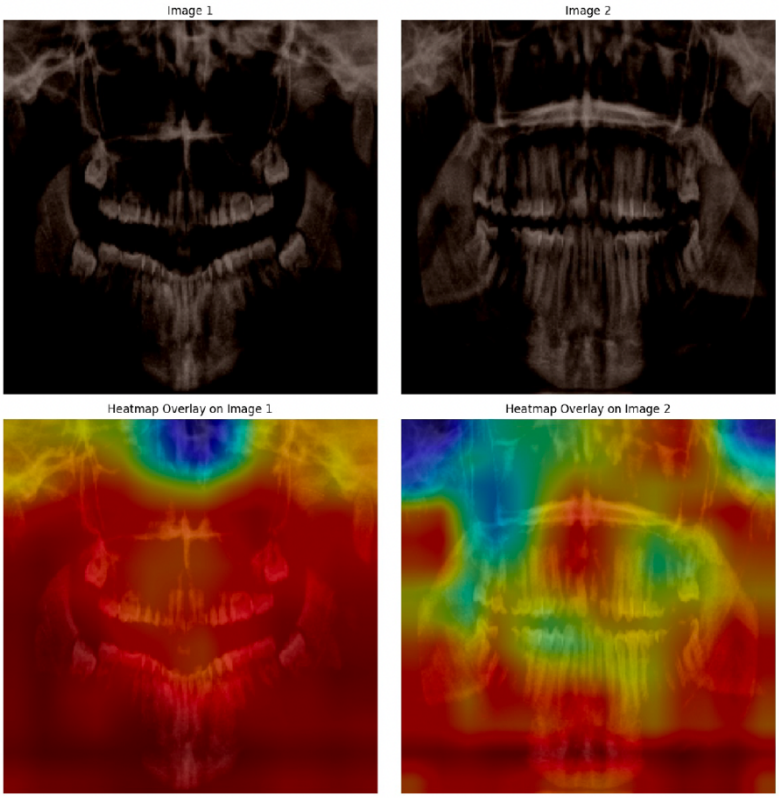
Anexo 5, III – *Heatmaps* de OPG da classe "*Different*" classificadas como "*Different*"



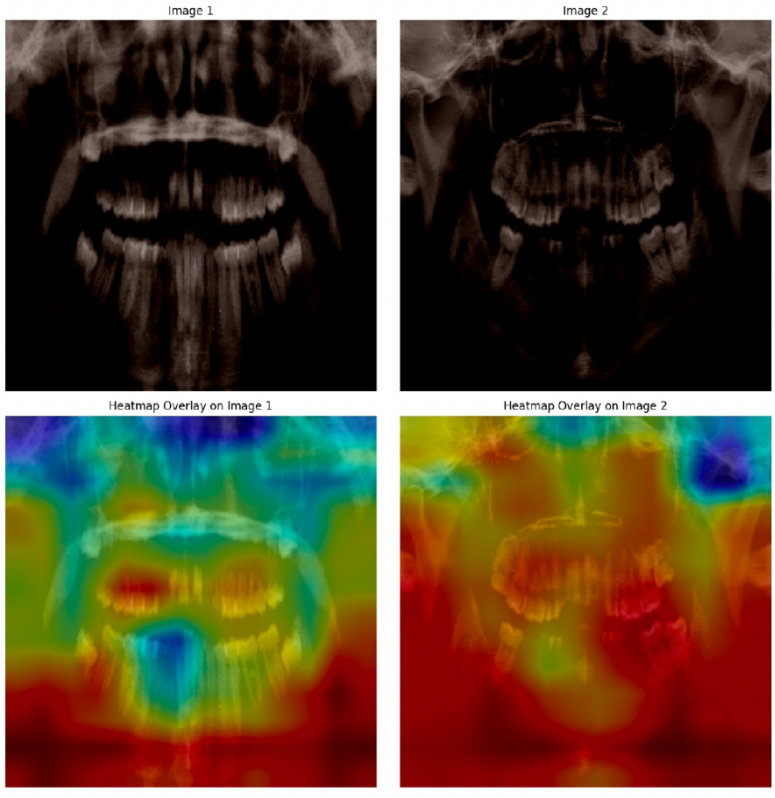

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.1677
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 2
```



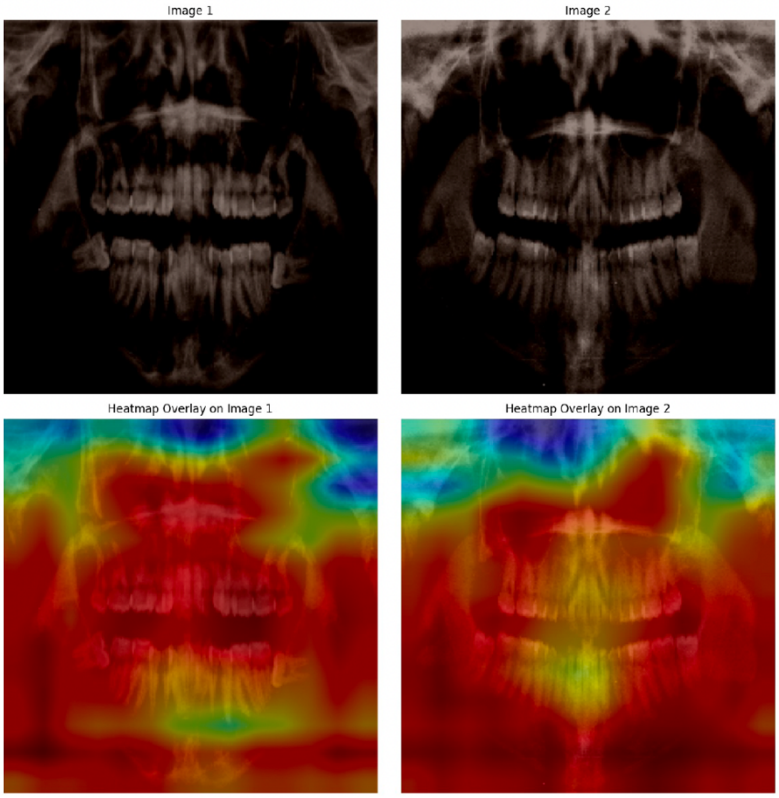

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.0408
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 3
```



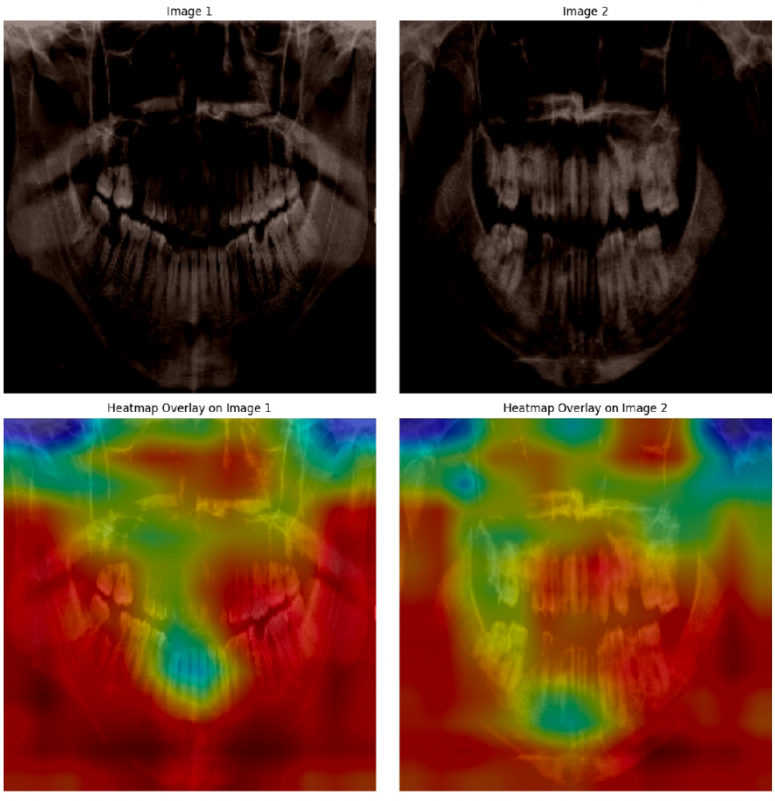

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.2305
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 5
```



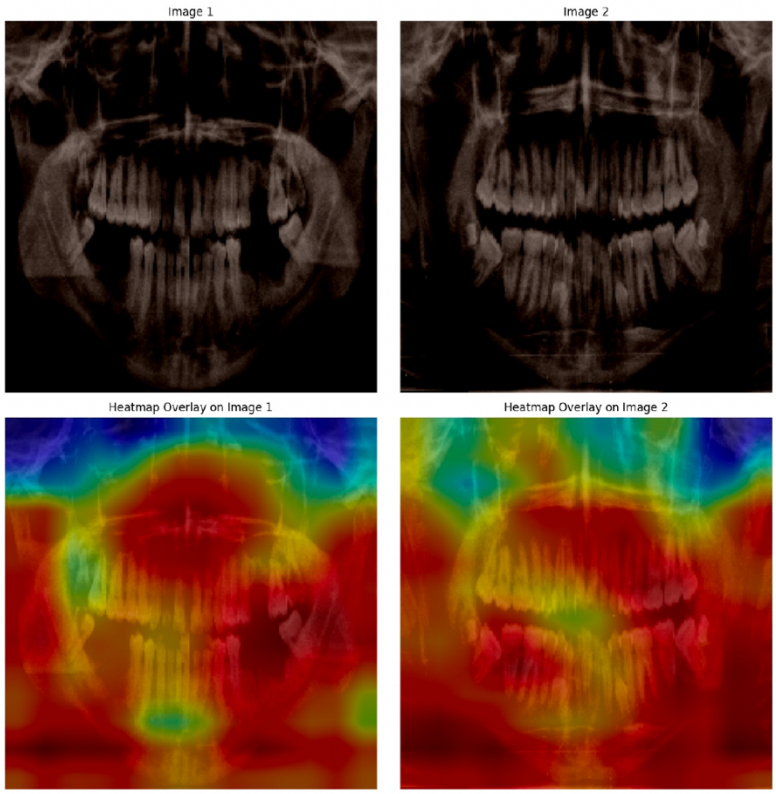

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.1247
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 6
```



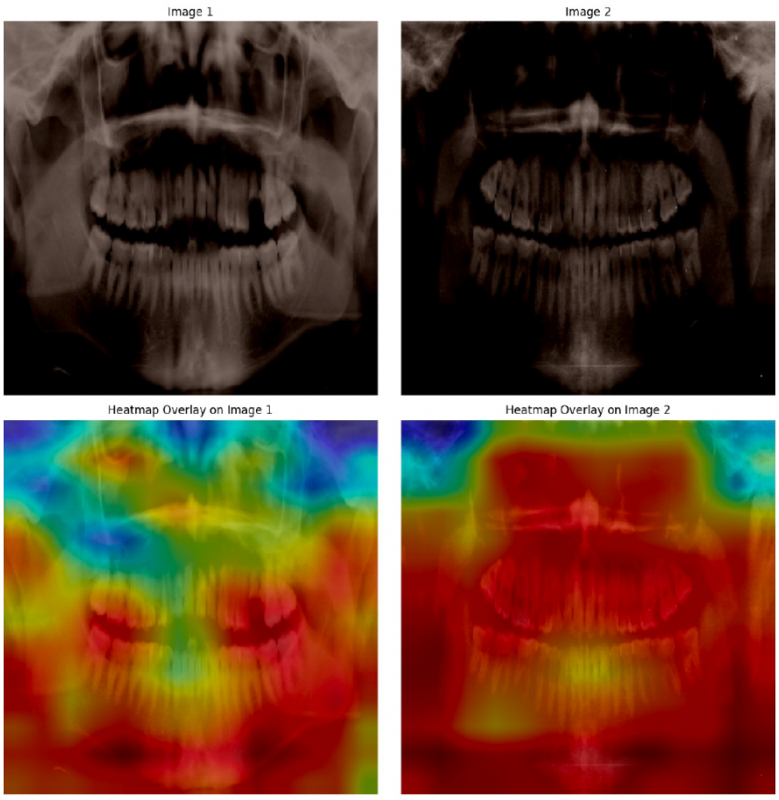

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.0553
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 7
```



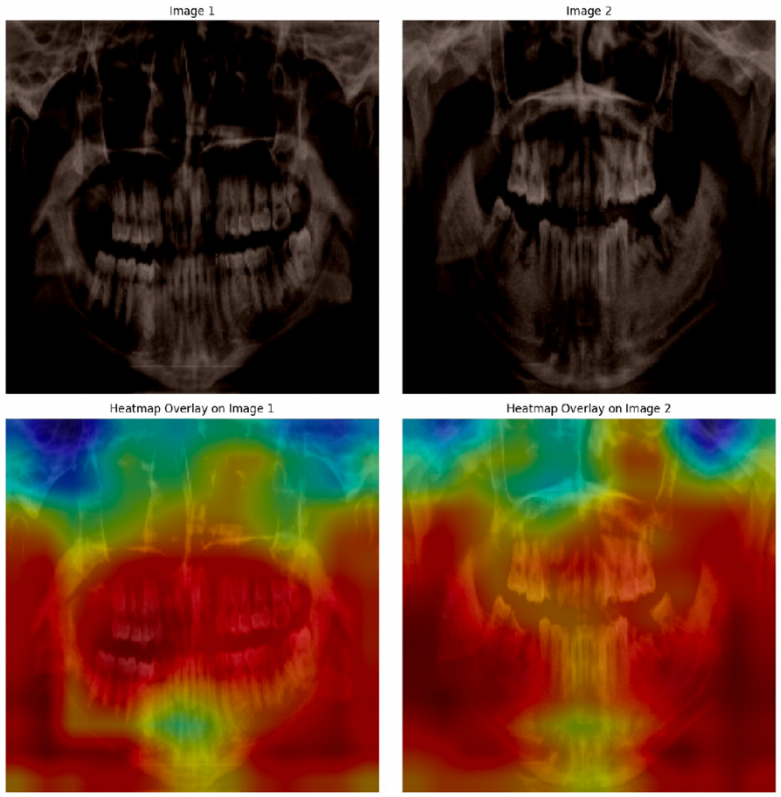

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.0121
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 9
```



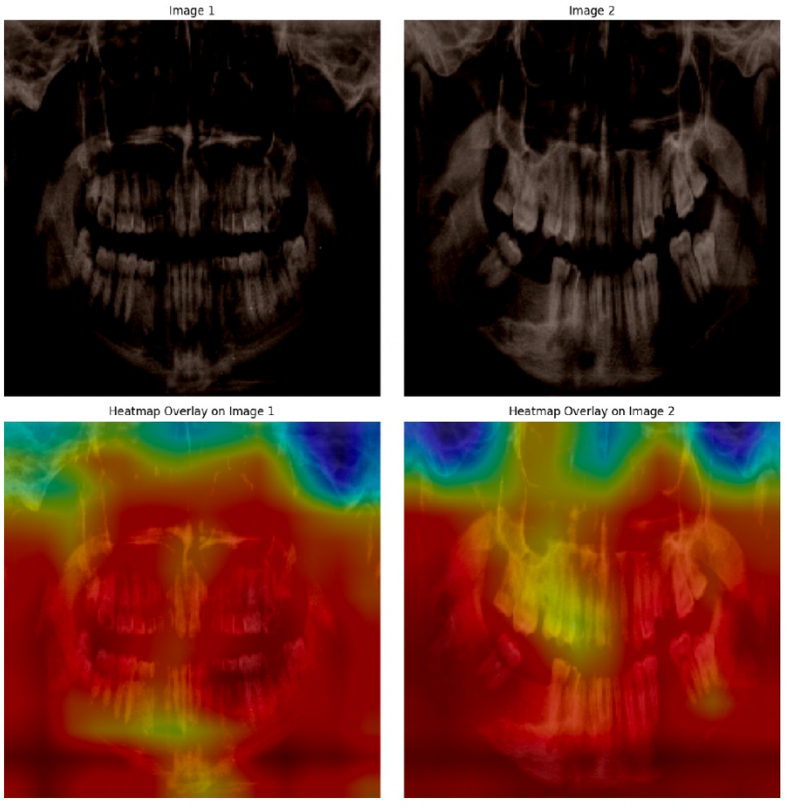

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.2282
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 11
```



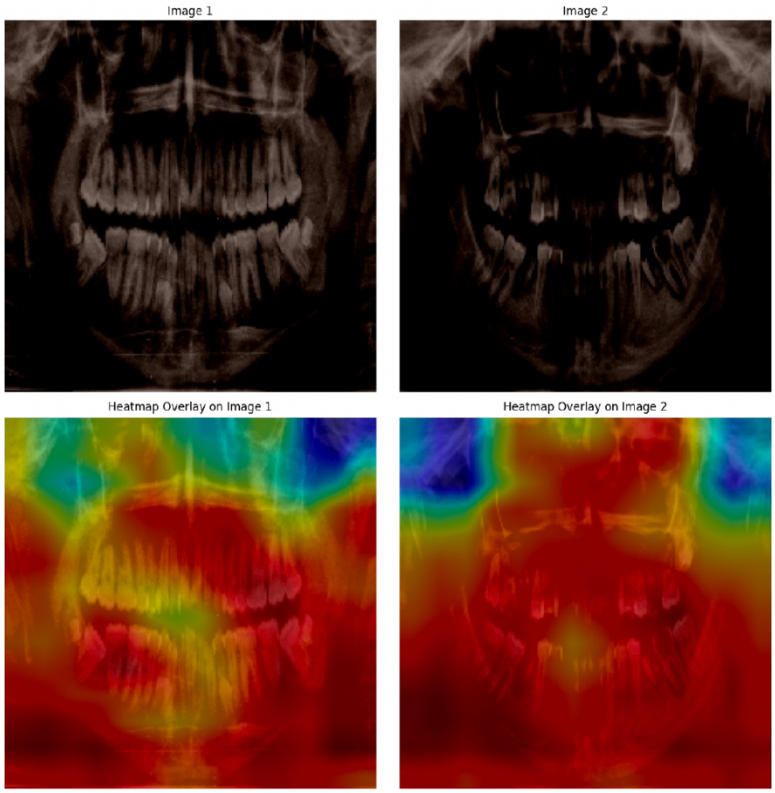

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.0578
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 13
```



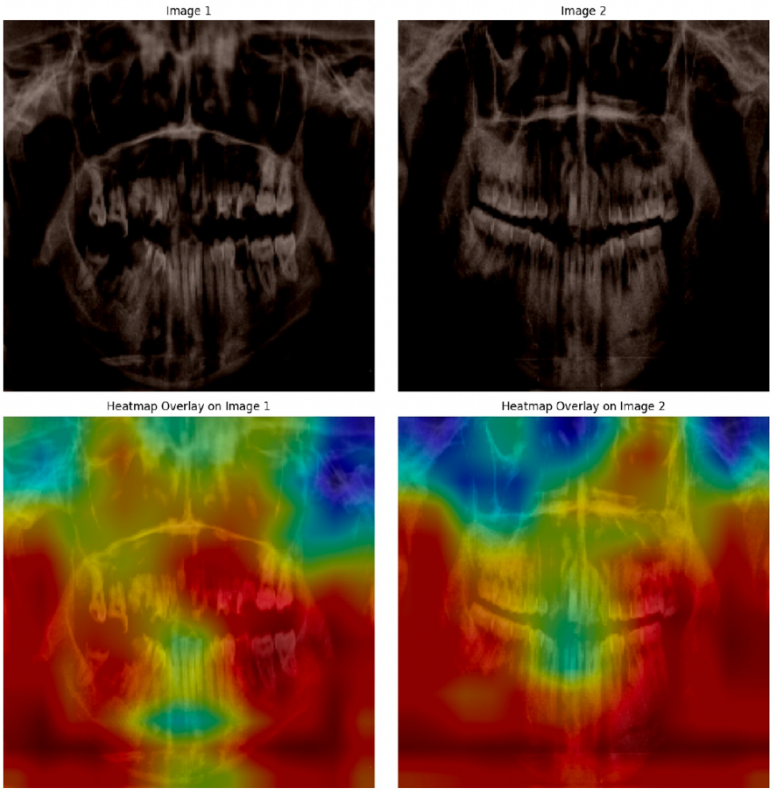

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.3918
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 14
```



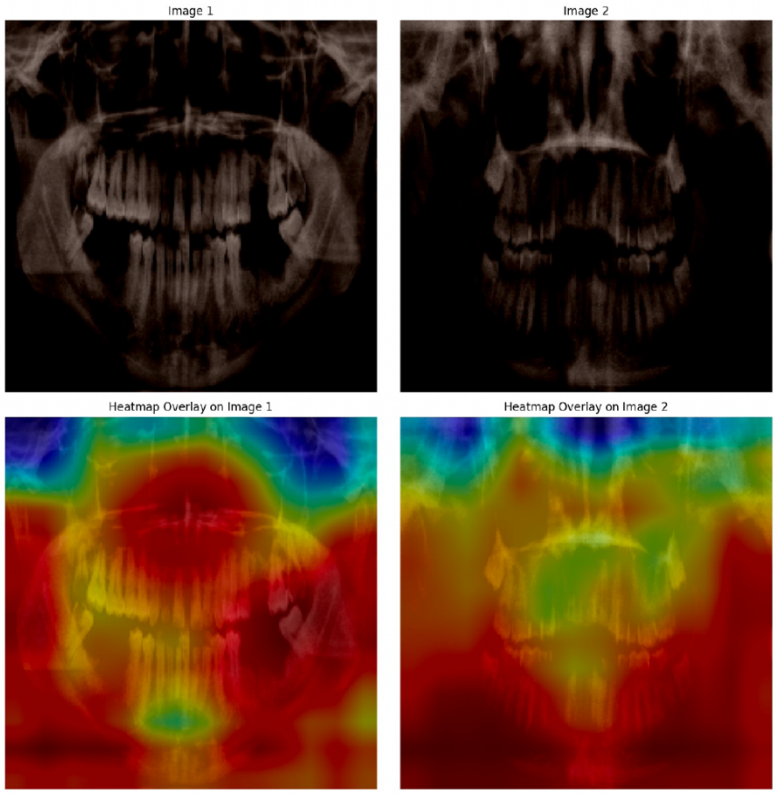

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.4567
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 16
```



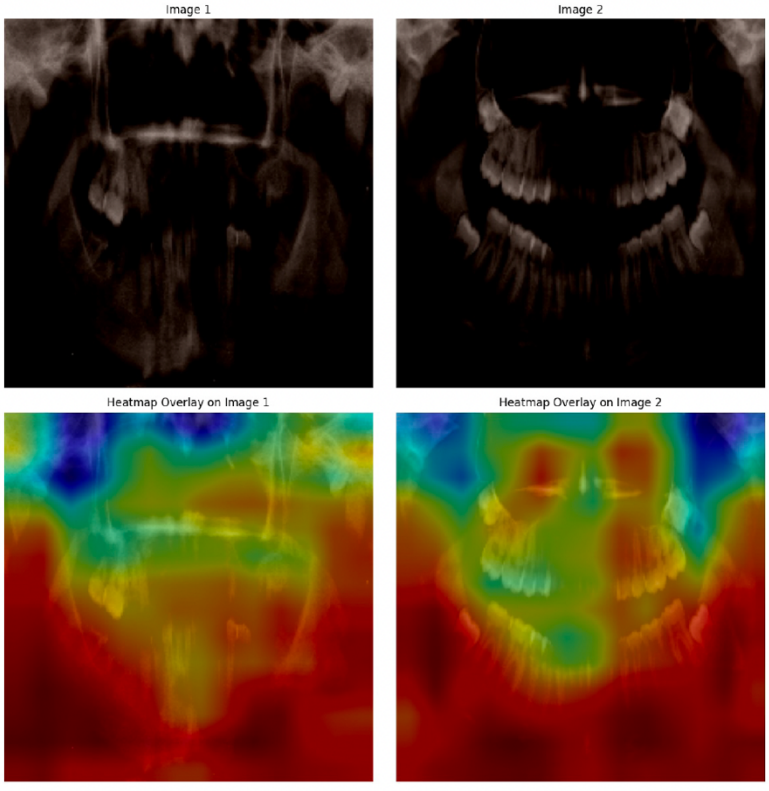

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 22ms/step
Model prediction: 0.1260
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 17
```



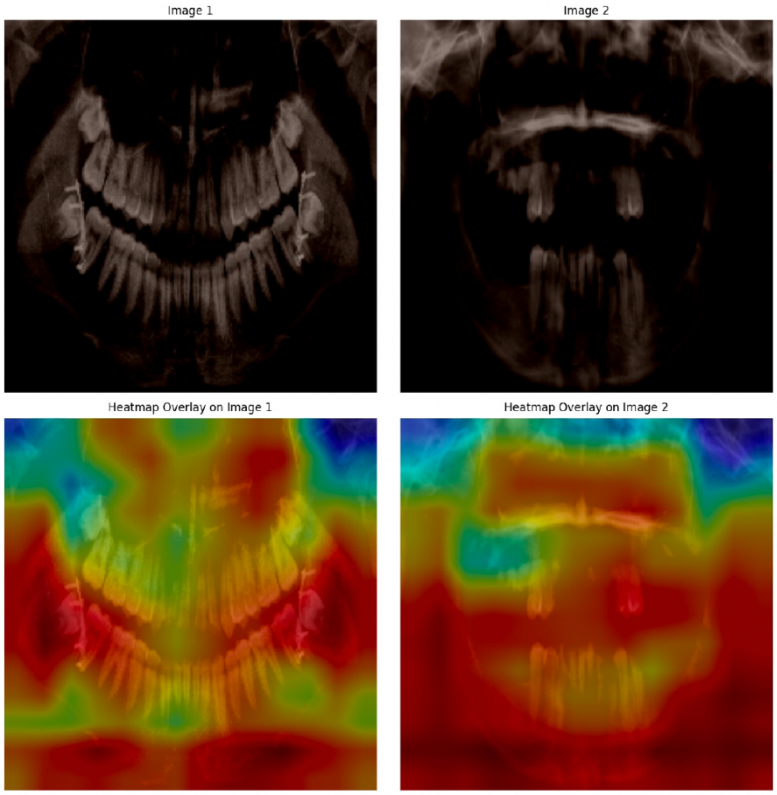

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.2280
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 18
```



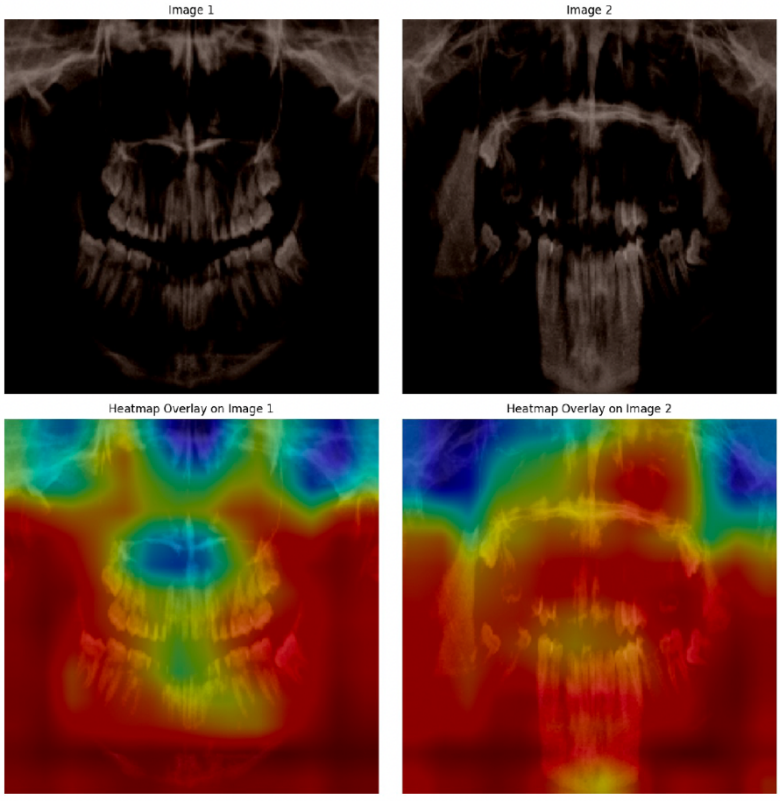

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.1578
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 19
```



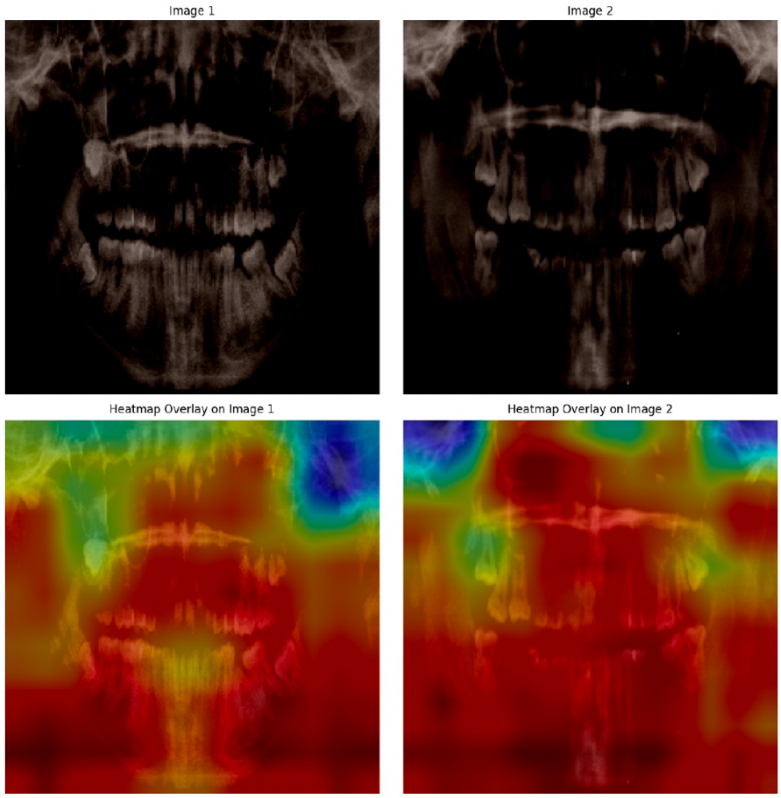

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.2719
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 20
```



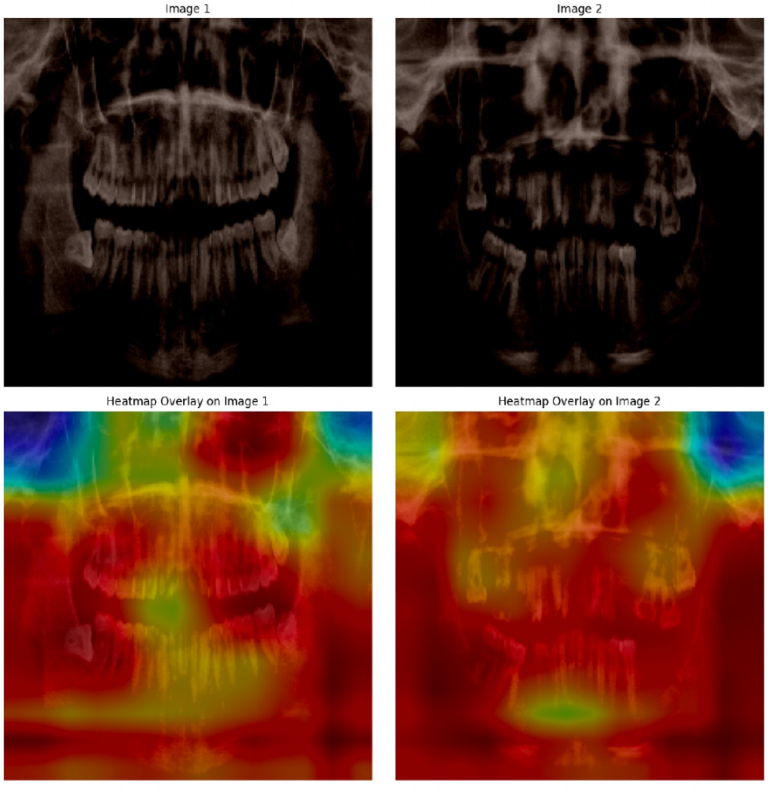

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.4533
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 21
```



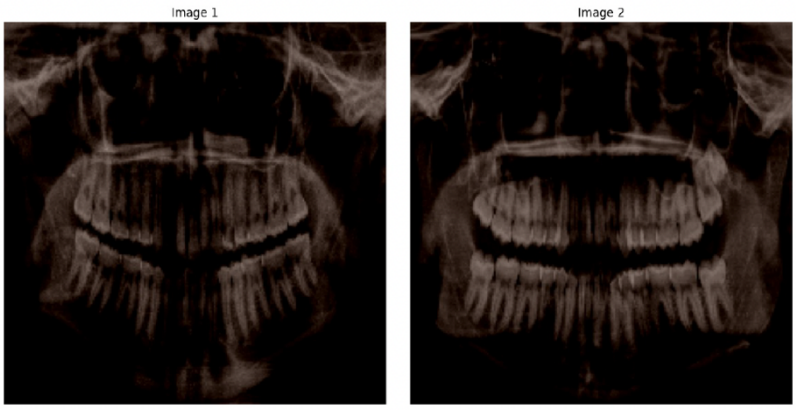

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 38ms/step
Model prediction: 0.2981
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 22
```

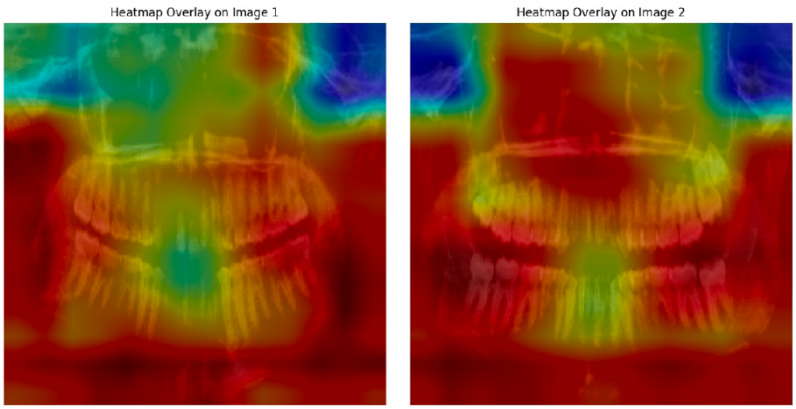



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.3245
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 23
```

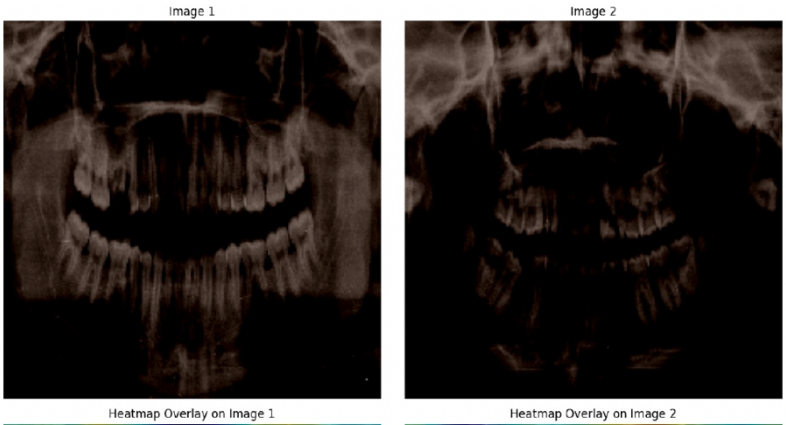


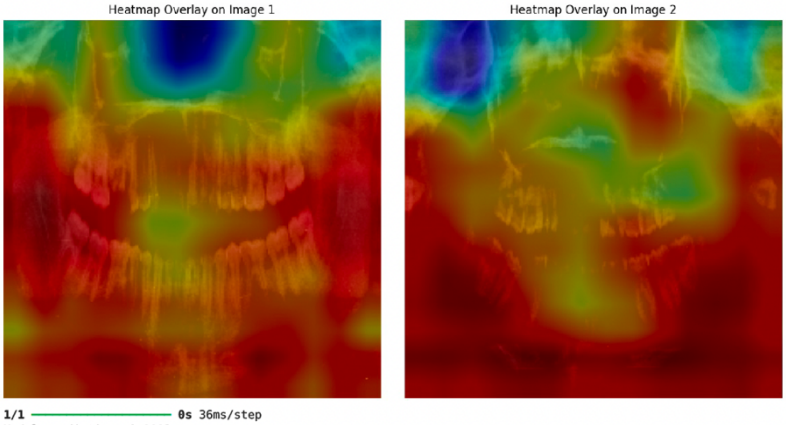

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.2813
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 24
```



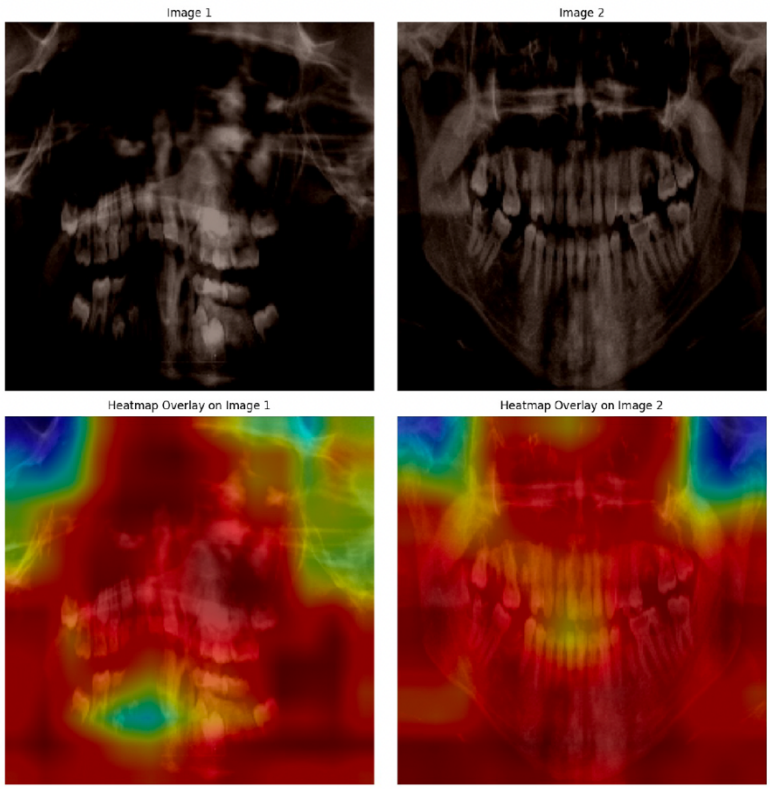



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.1371
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 25
```

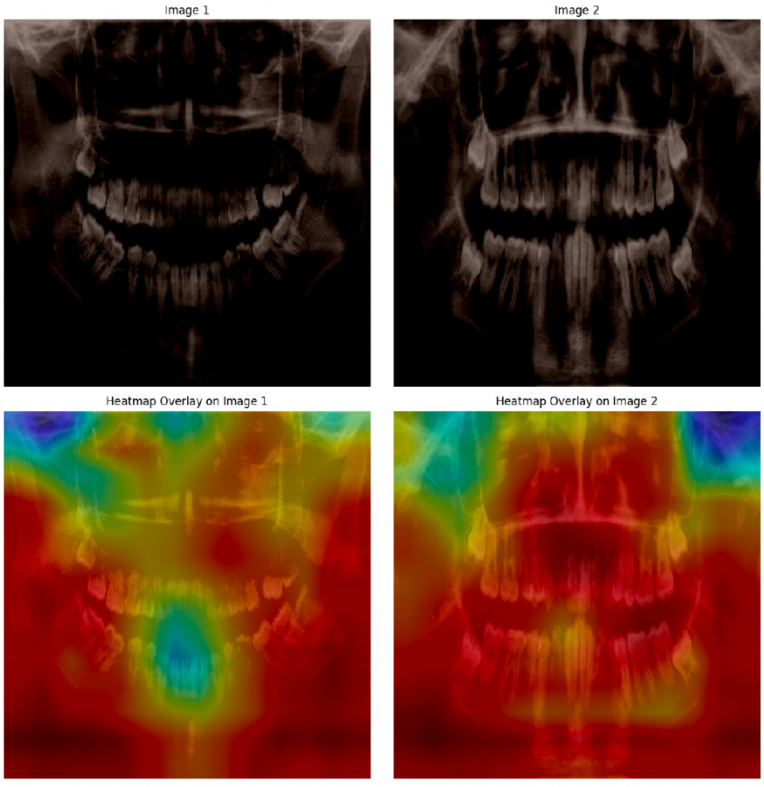




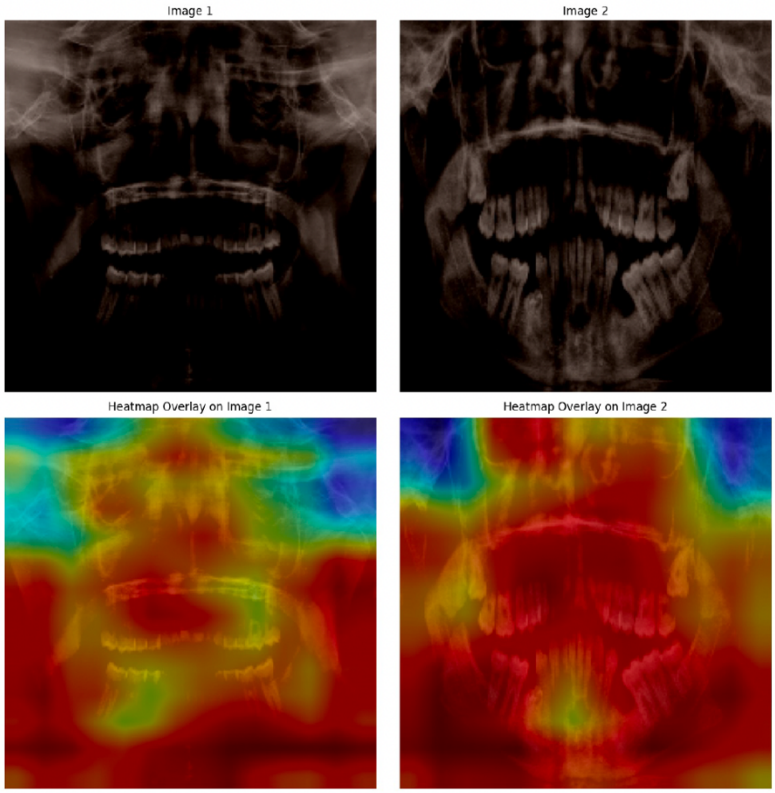

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 36ms/step
Model prediction: 0.1112
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 28
```



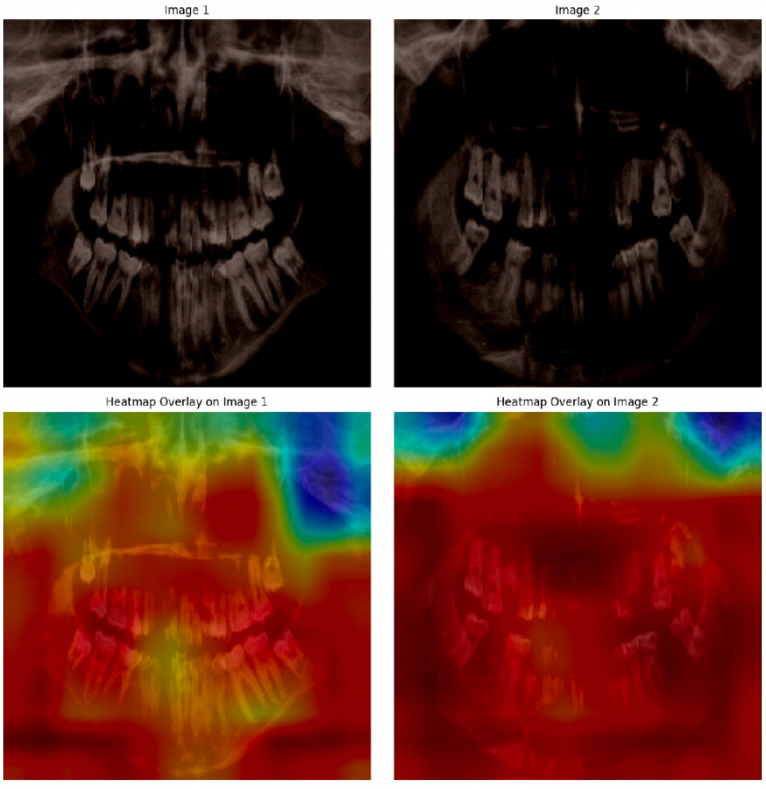

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 43ms/step
Model prediction: 0.1332
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 29
```



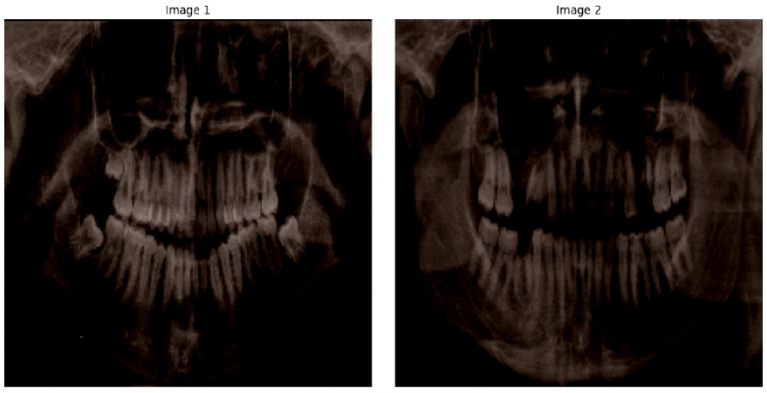

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 42ms/step
Model prediction: 0.0505
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 30
```

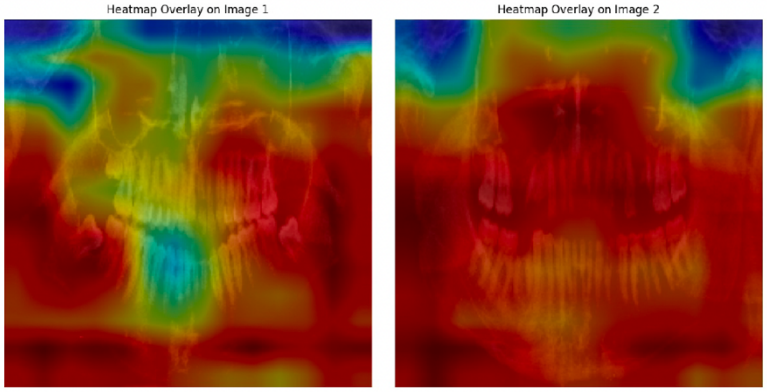



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 42ms/step
Model prediction: 0.4024
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 31
```

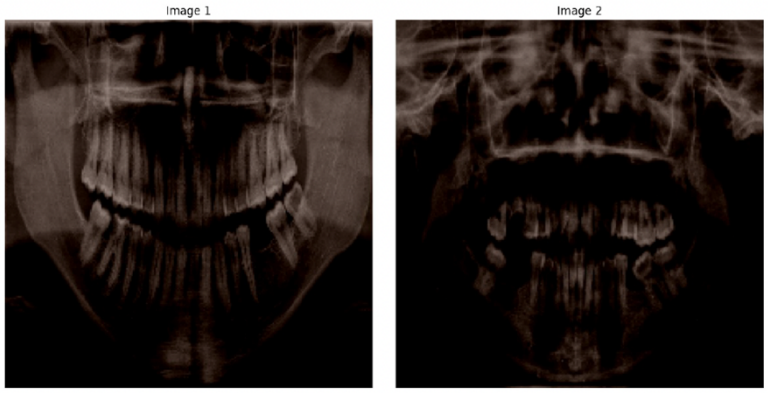


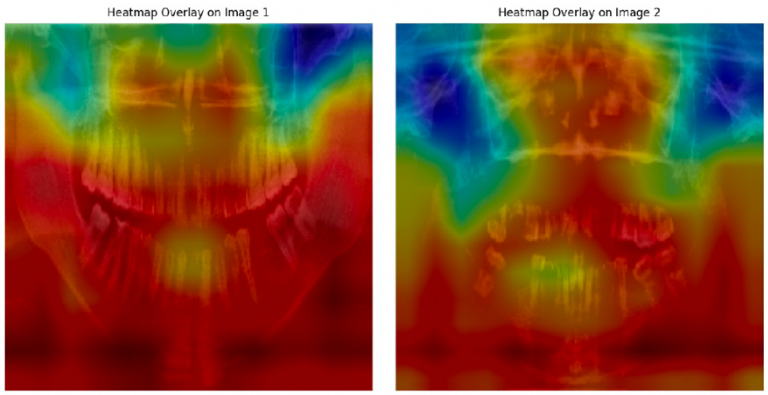

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.1531
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 32
```



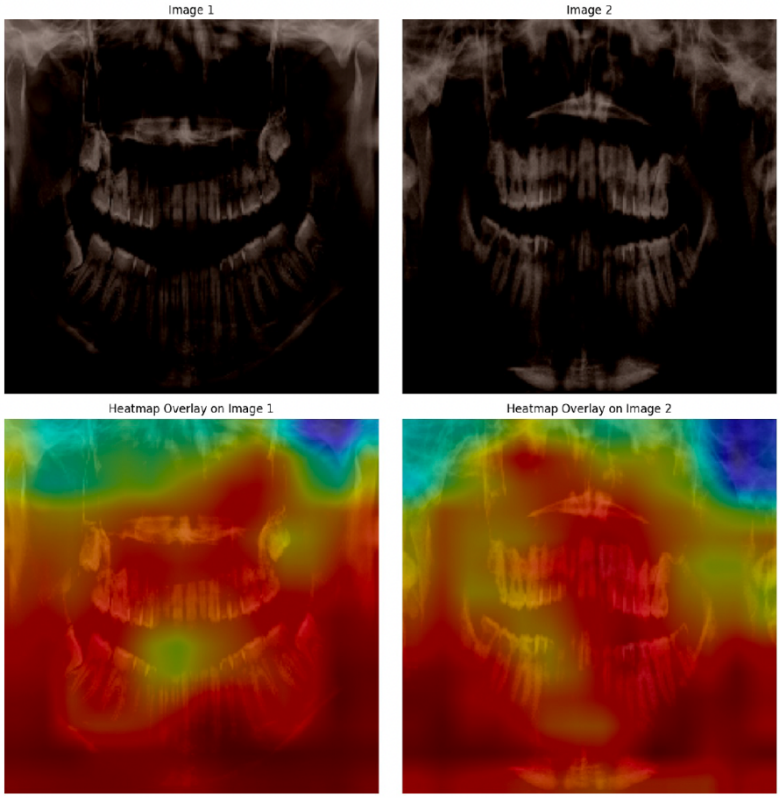



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 22ms/step
Model prediction: 0.1266
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 36
```

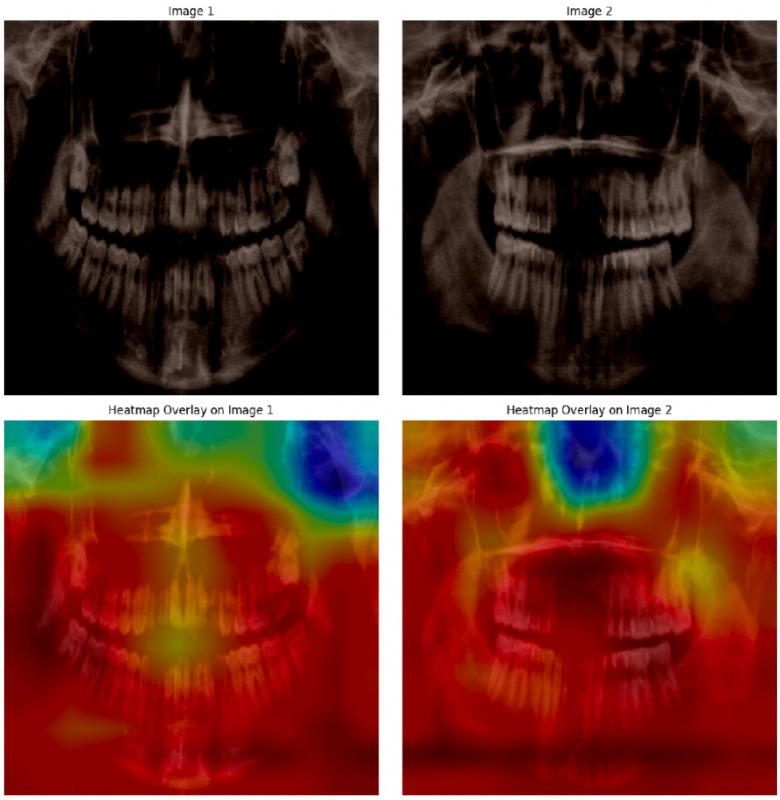




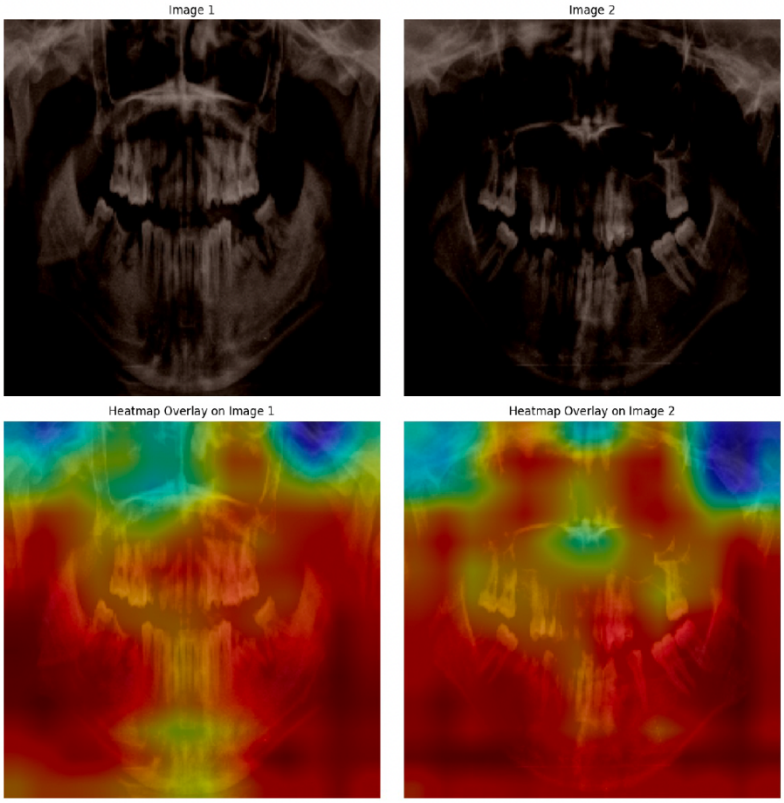

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 56ms/step
Model prediction: 0.1352
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 37
```



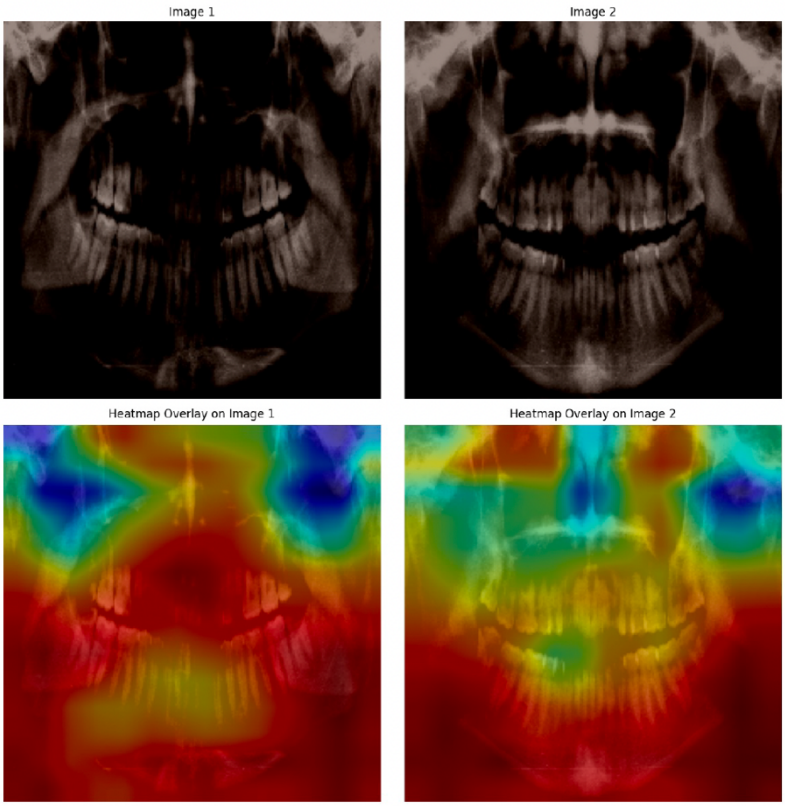

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.3161
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 38
```



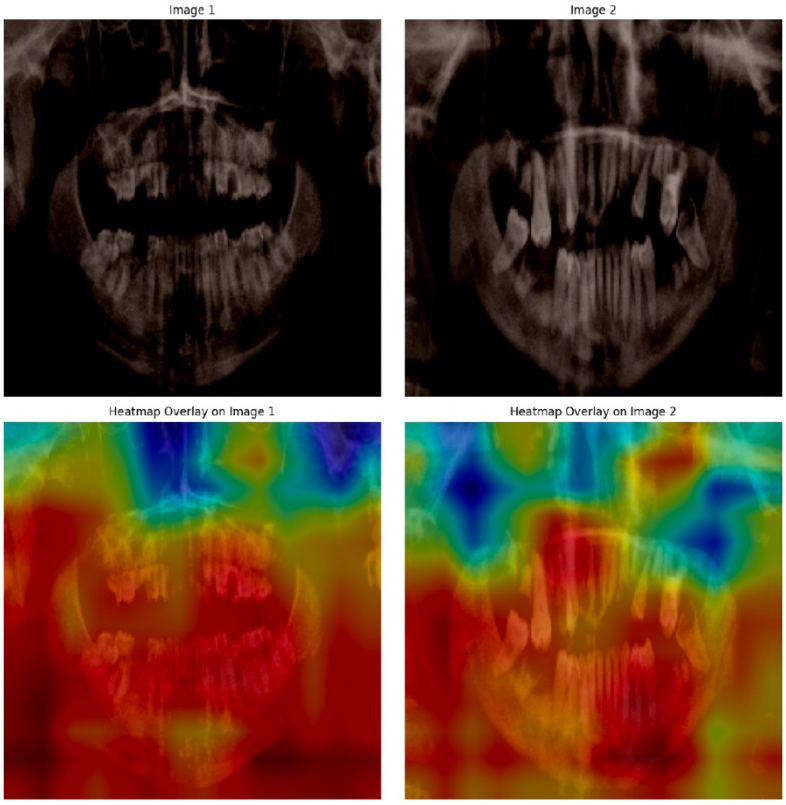

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 32ms/step
Model prediction: 0.2222
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 40
```



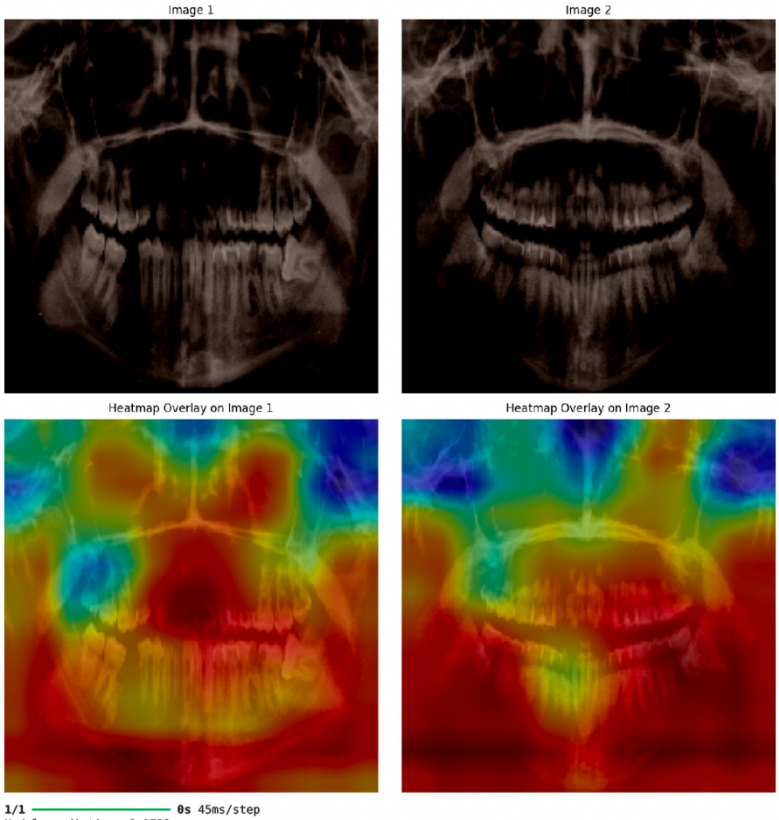

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.1867
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 41
```



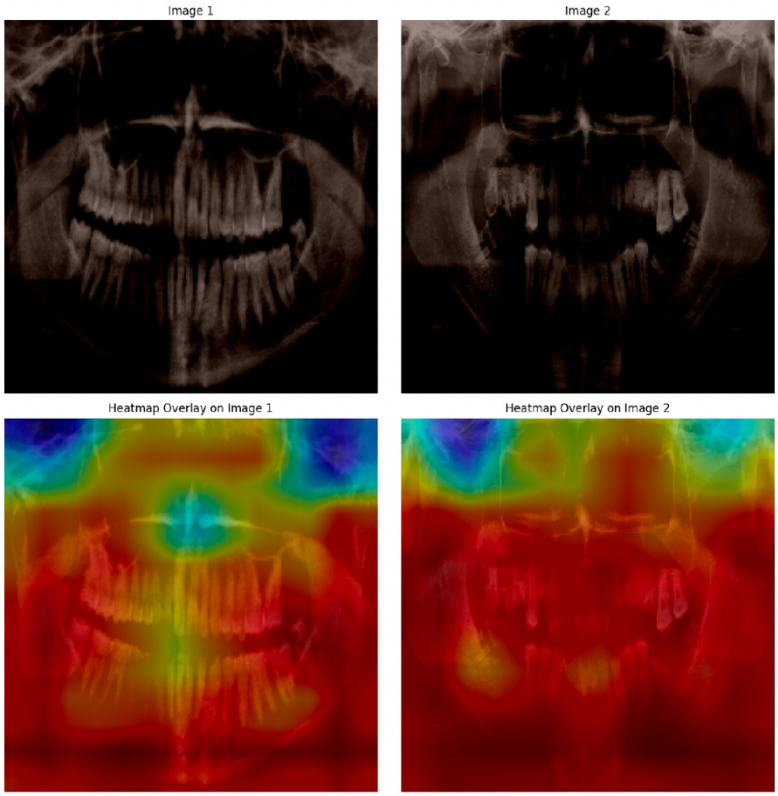

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 47ms/step
Model prediction: 0.3563
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 45
```



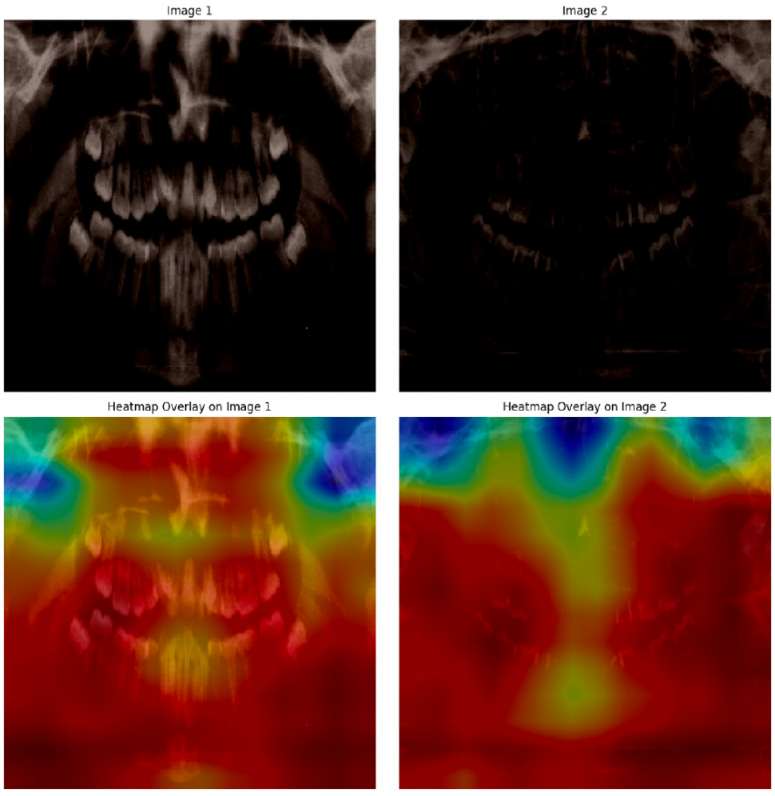

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 42ms/step
Model prediction: 0.4285
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 47
```



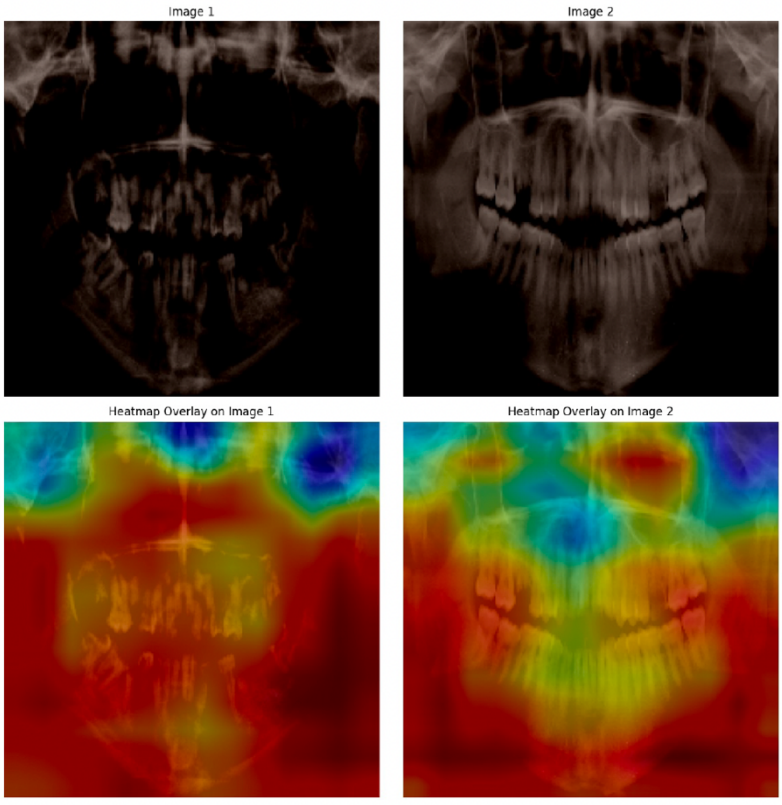

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 45ms/step
Model prediction: 0.1799
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 48
```



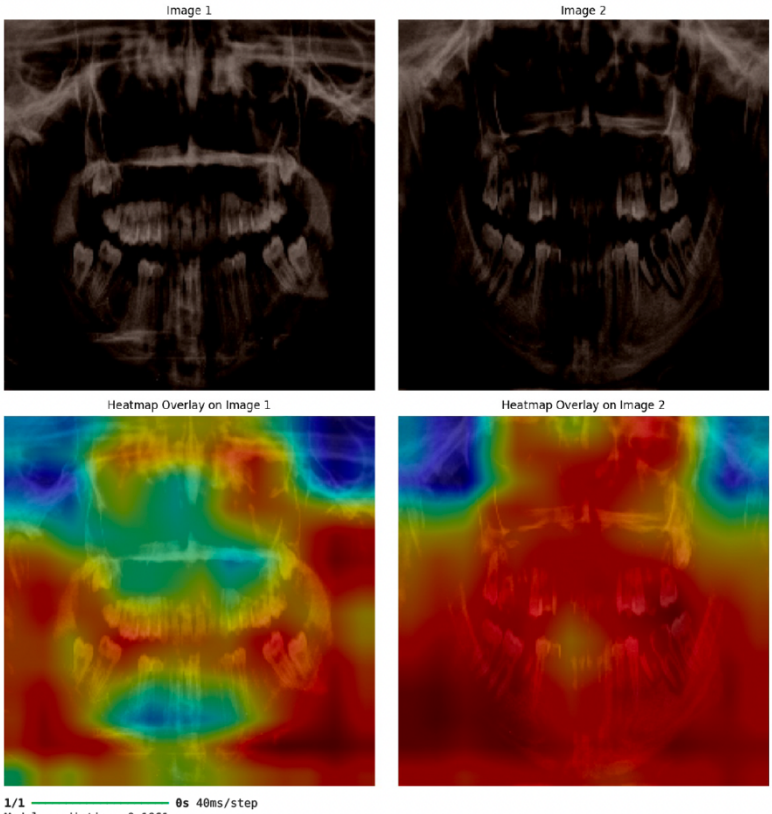

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 48ms/step
Model prediction: 0.0496
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 50
```



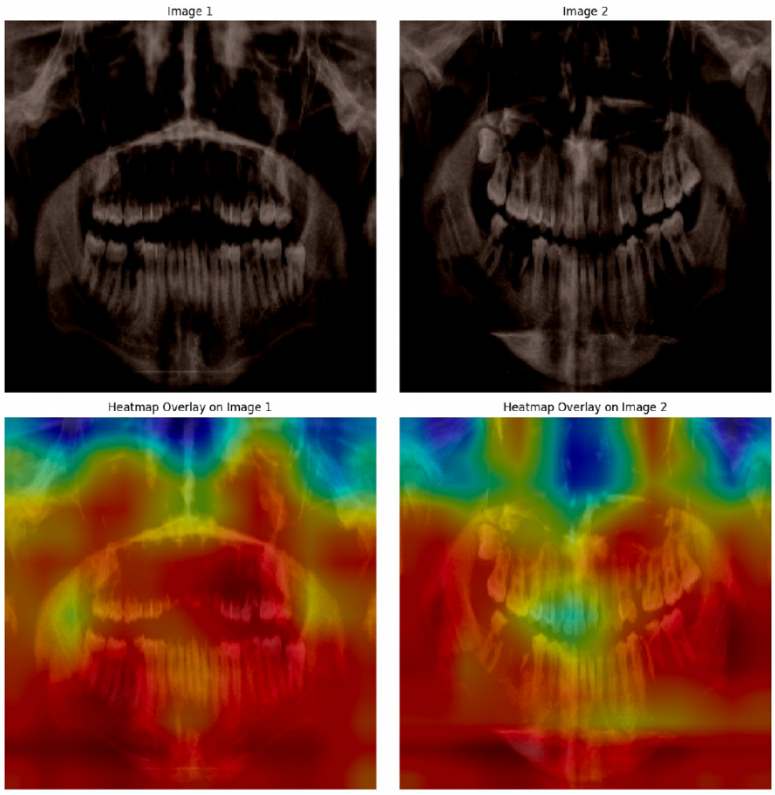

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 43ms/step
Model prediction: 0.1355
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 49
```



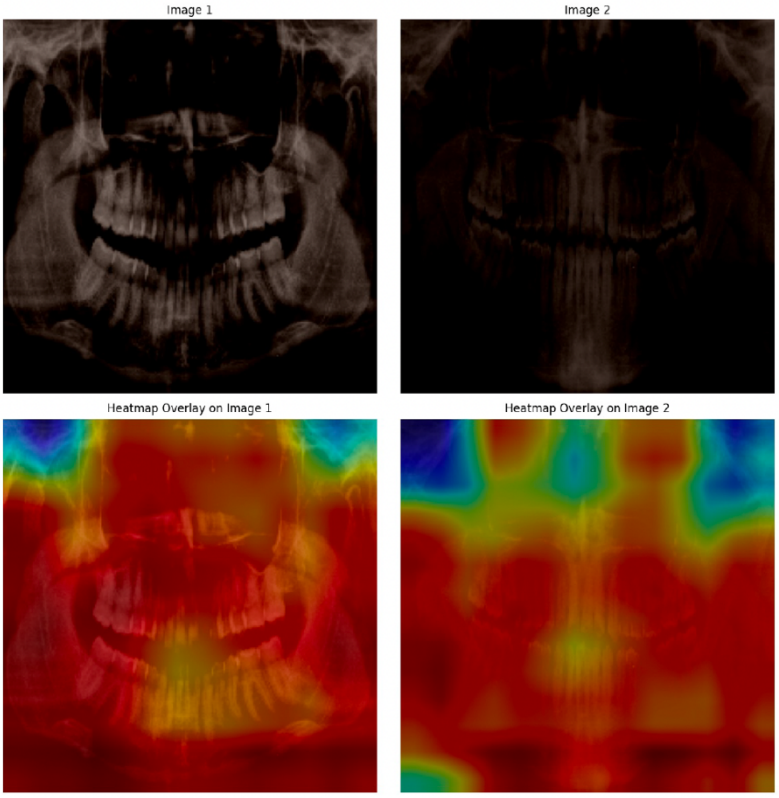

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 41ms/step
Model prediction: 0.3850
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 51
```



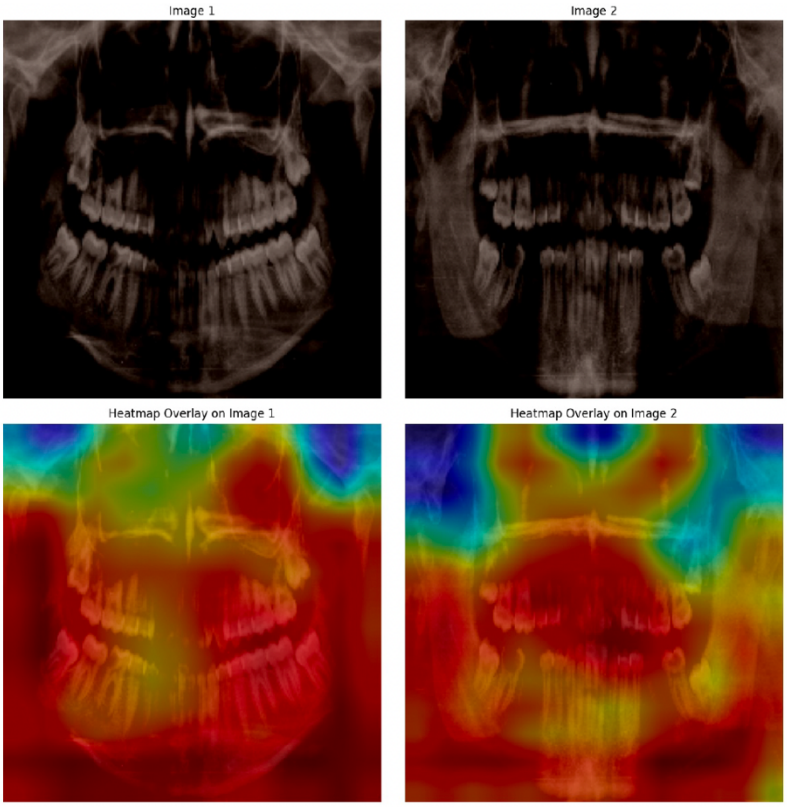

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.1061
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 54
```



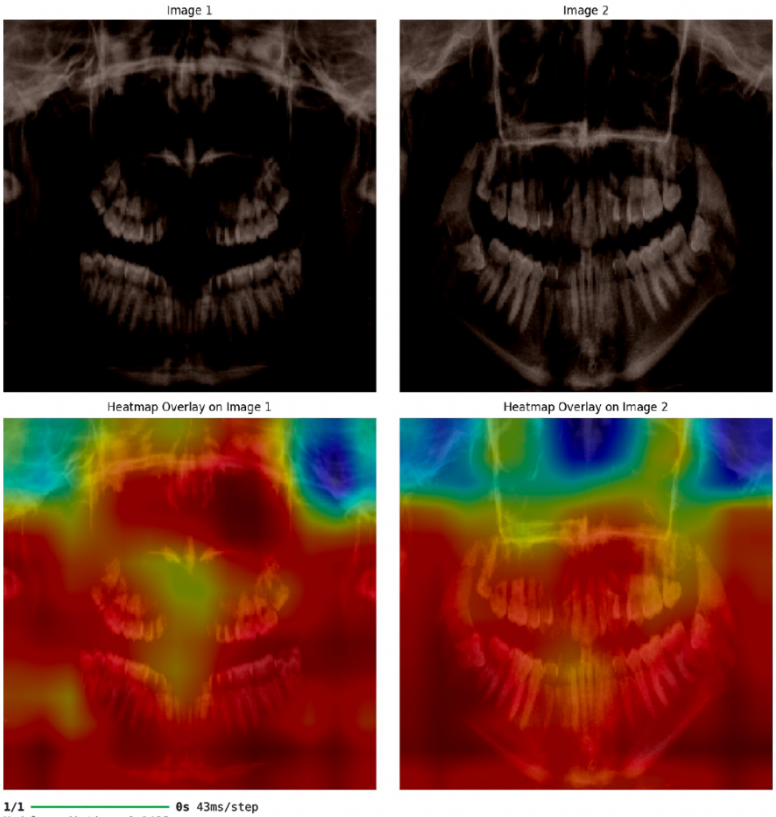

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 44ms/step
Model prediction: 0.2537
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 55
```



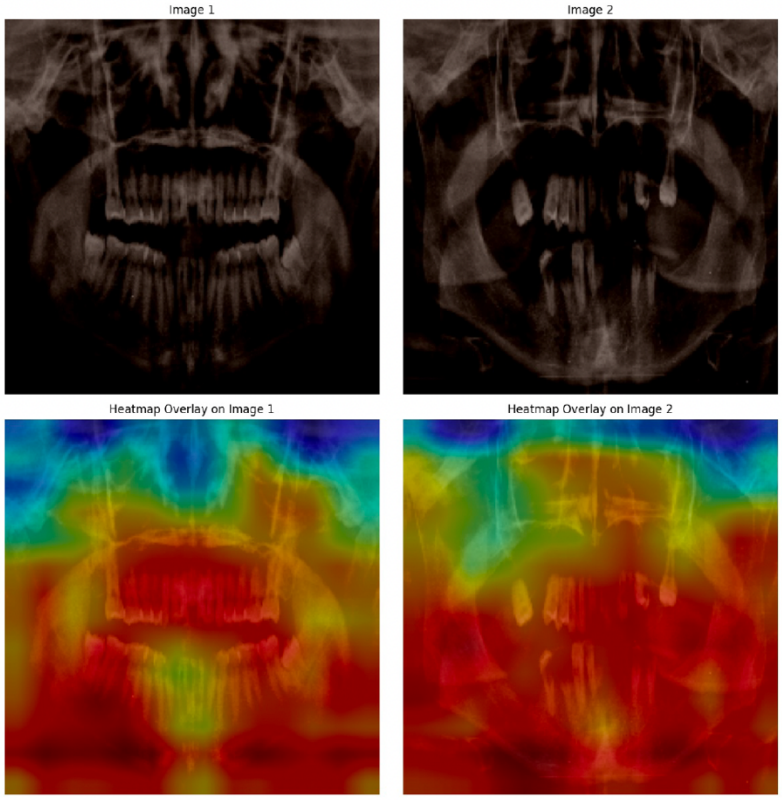

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 50ms/step
Model prediction: 0.1475
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 56
```



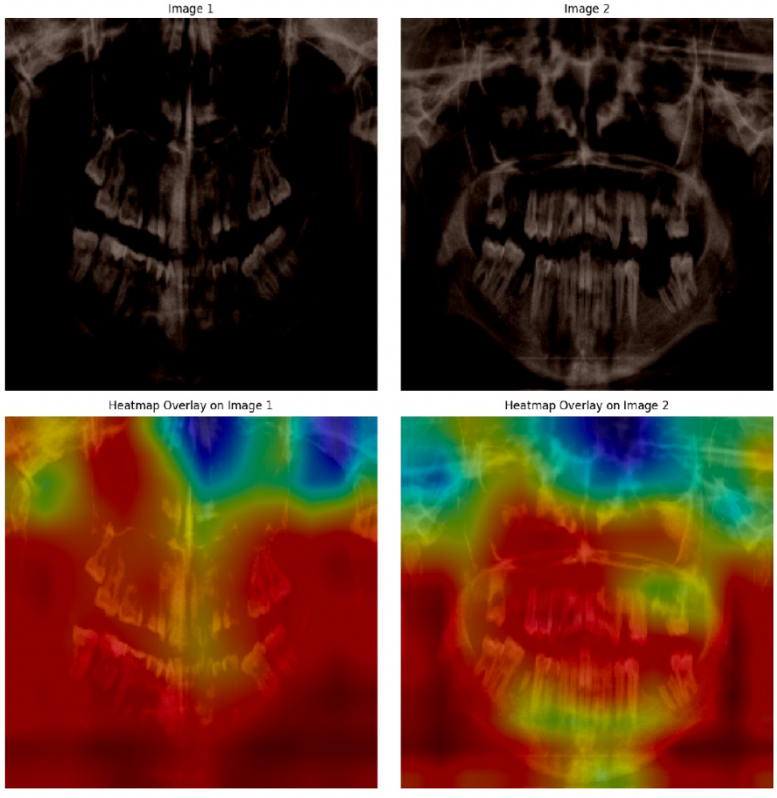

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 46ms/step
Model prediction: 0.0837
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 57
```



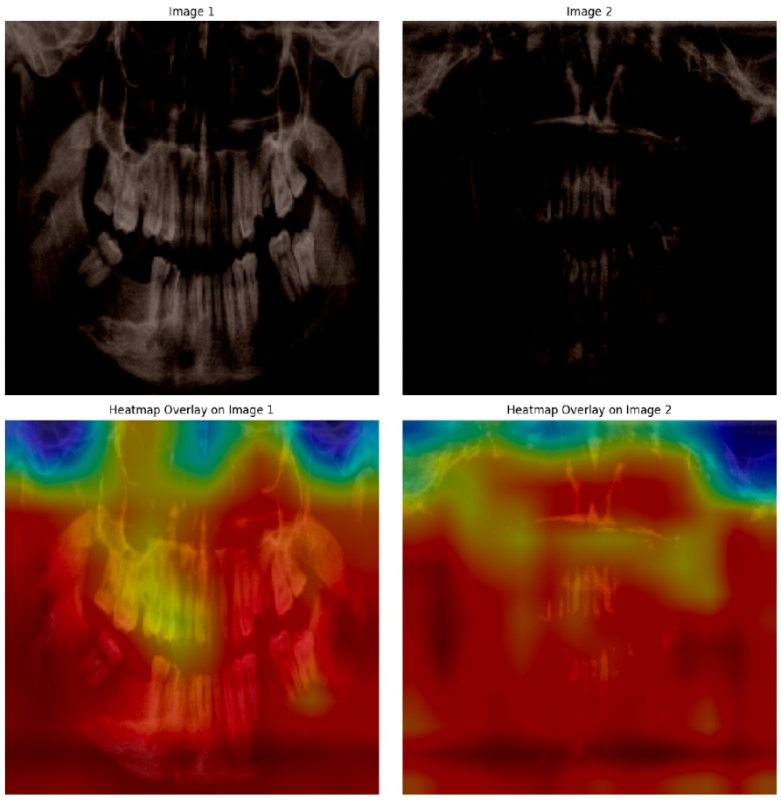

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 43ms/step
Model prediction: 0.1406
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 58
```



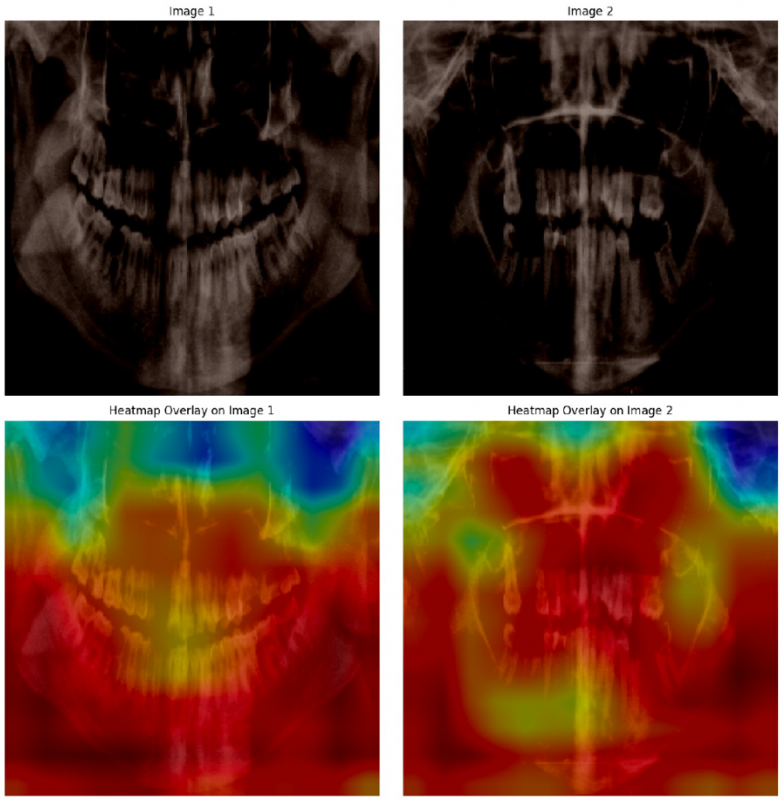

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 46ms/step
Model prediction: 0.2391
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 59
```



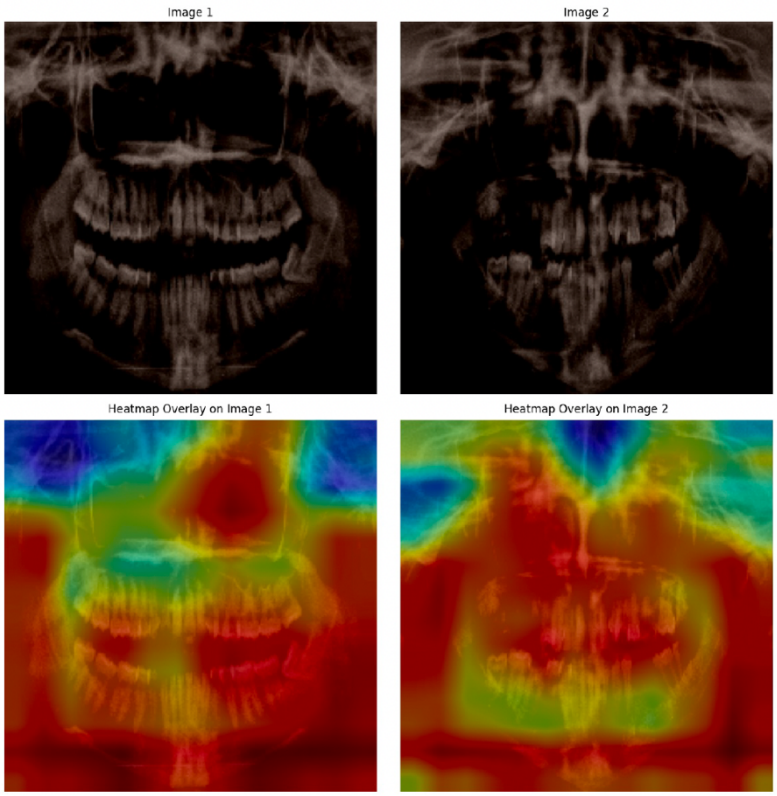

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 56ms/step
Model prediction: 0.3258
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 60
```



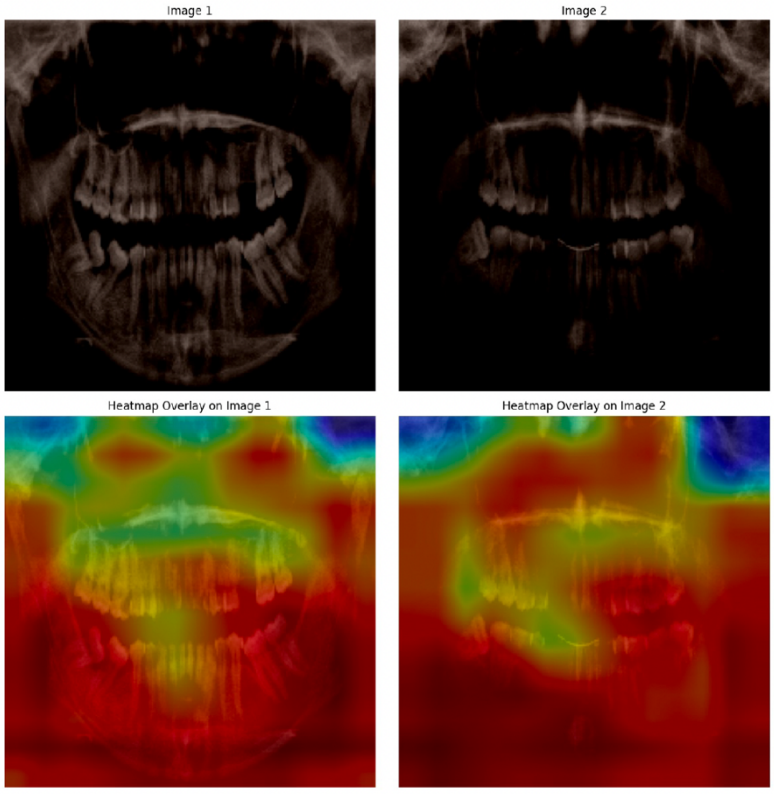

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 49ms/step
Model prediction: 0.2422
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 62
```



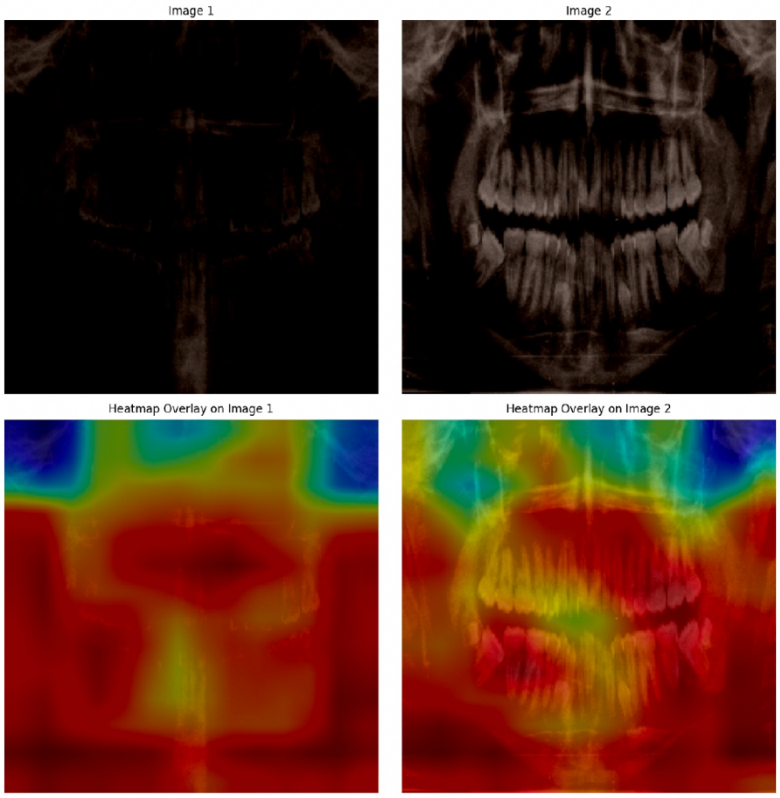

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 26ms/step
Model prediction: 0.2625
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 66
```



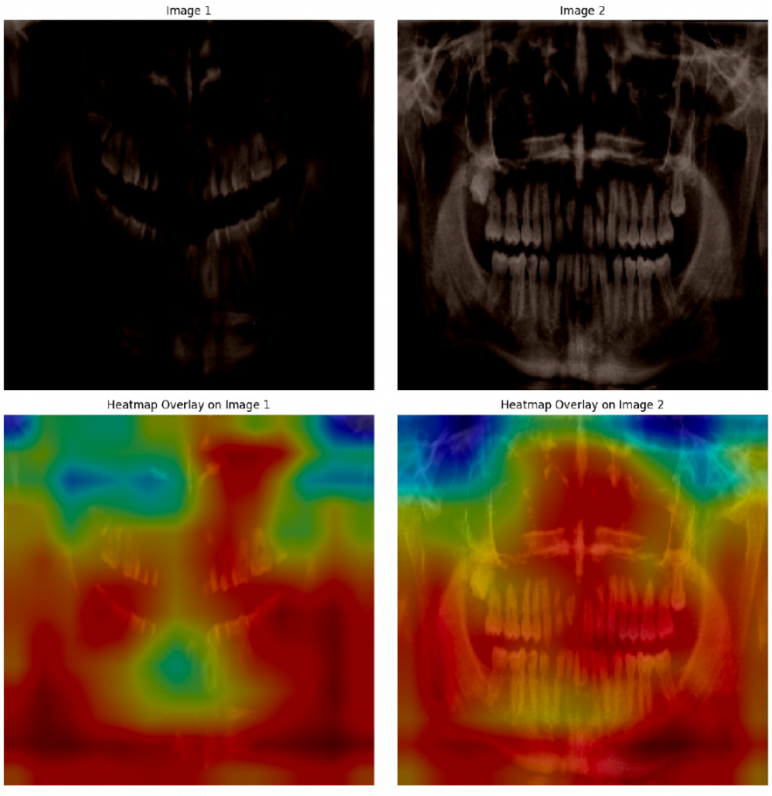

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 38ms/step
Model prediction: 0.0885
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 68
```



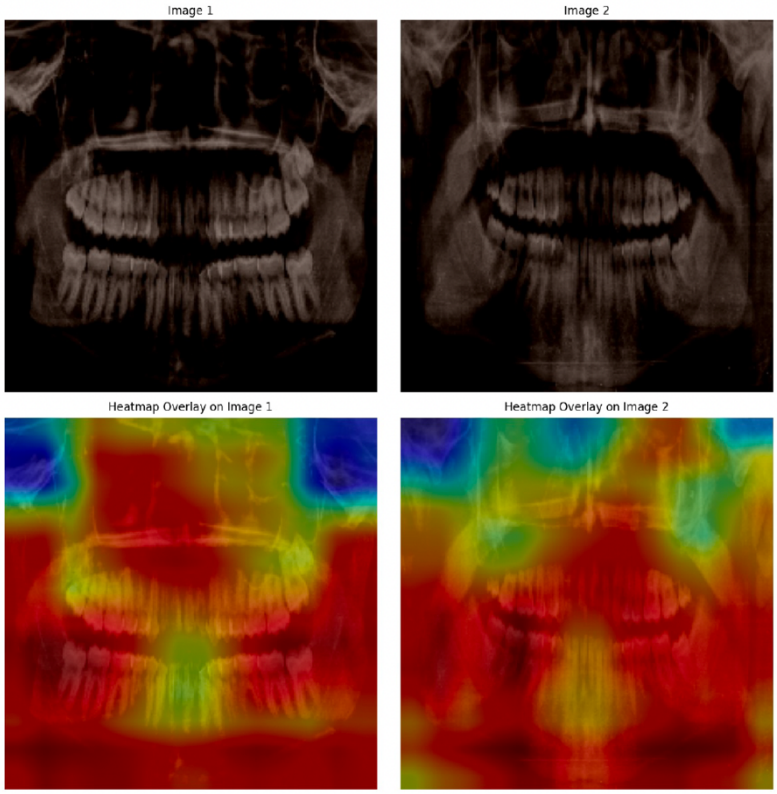

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 48ms/step
Model prediction: 0.2222
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 70
```



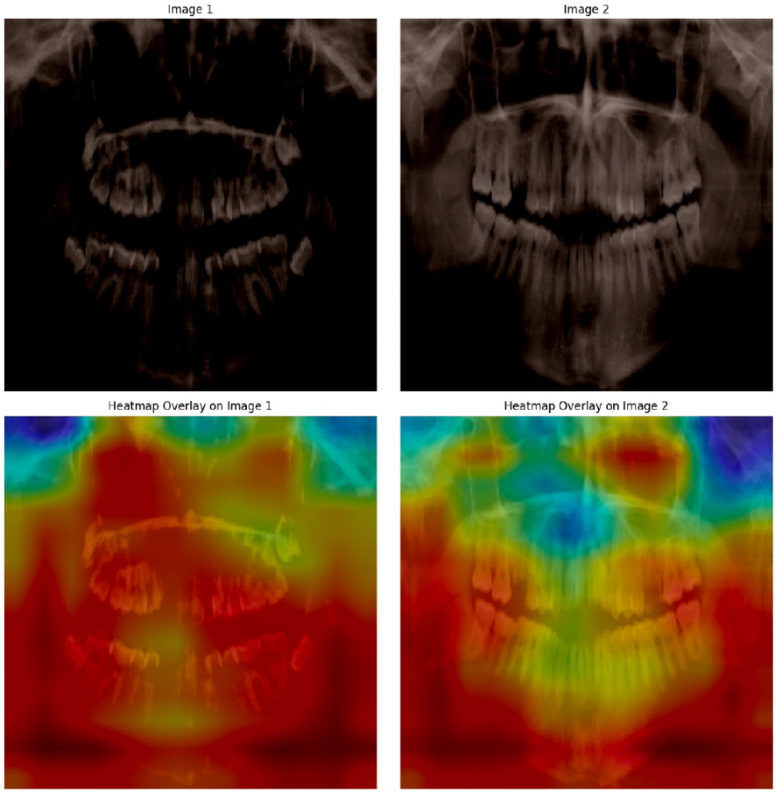

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 41ms/step
Model prediction: 0.2732
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 71
```



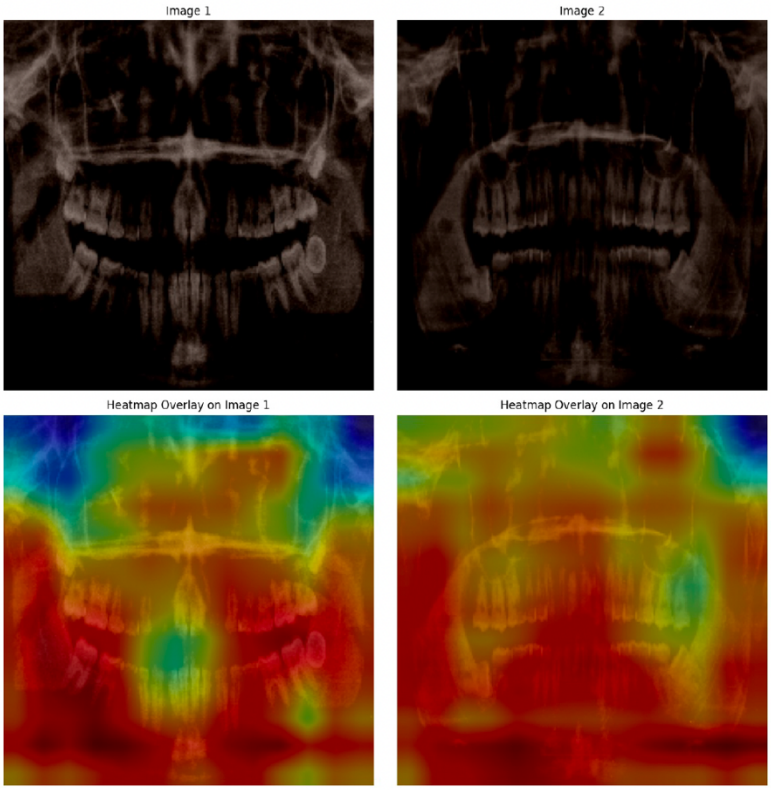

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 43ms/step
Model prediction: 0.0271
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 73
```



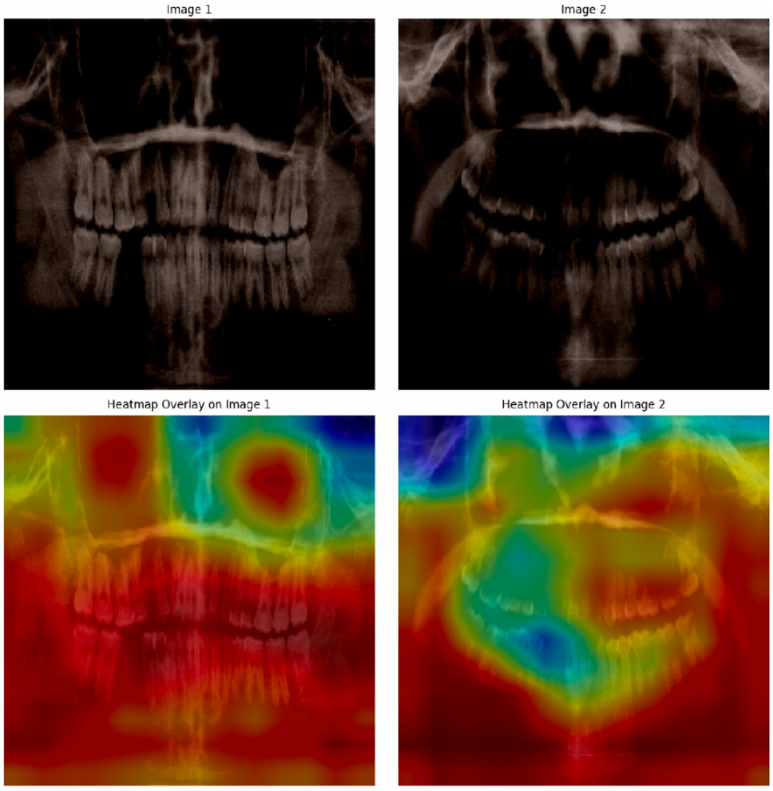

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.2789
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 74
```



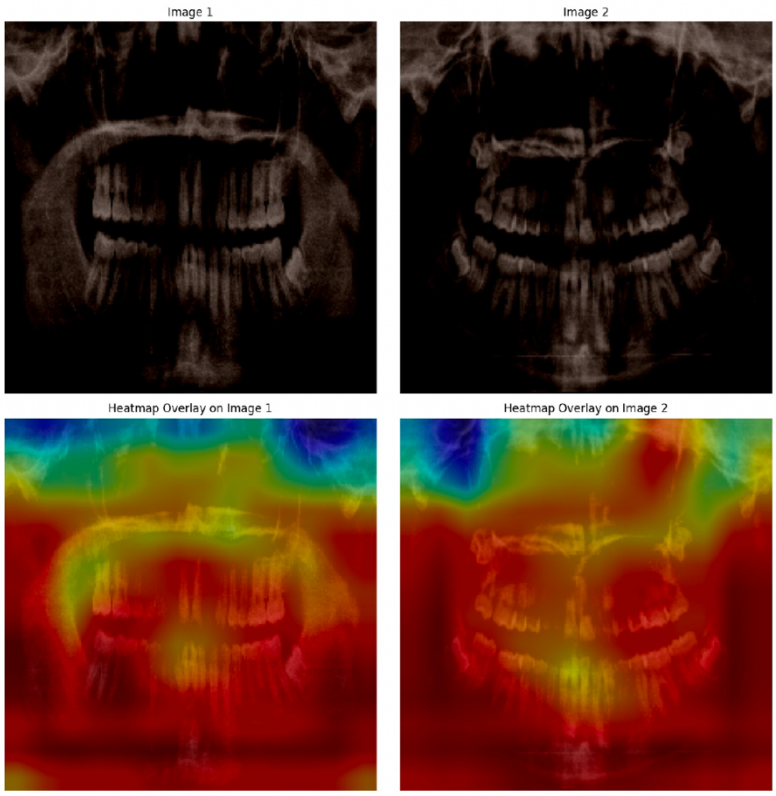

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.1515
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 77
```



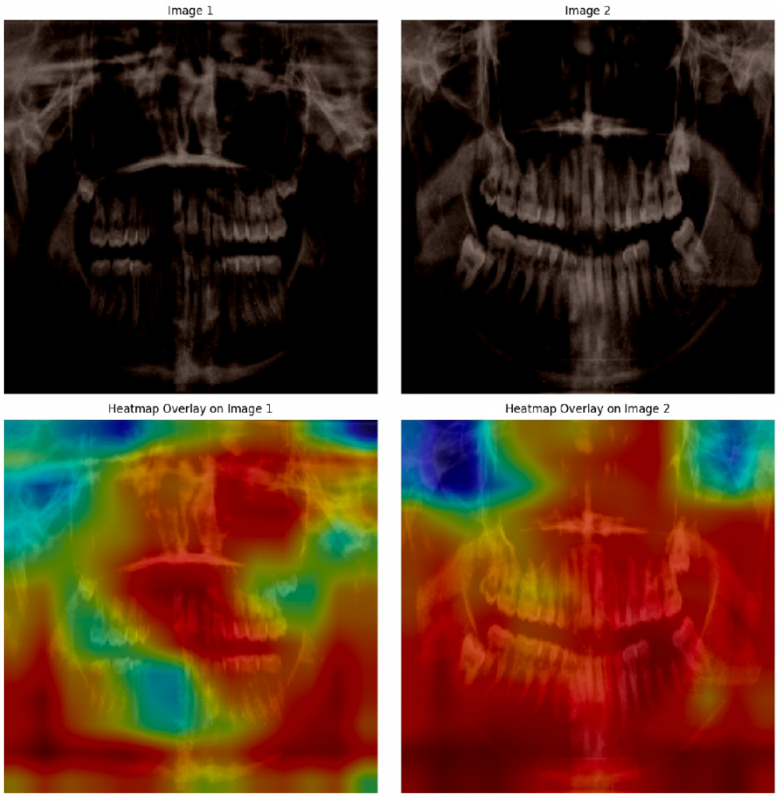

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 44ms/step
Model prediction: 0.0941
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 78
```



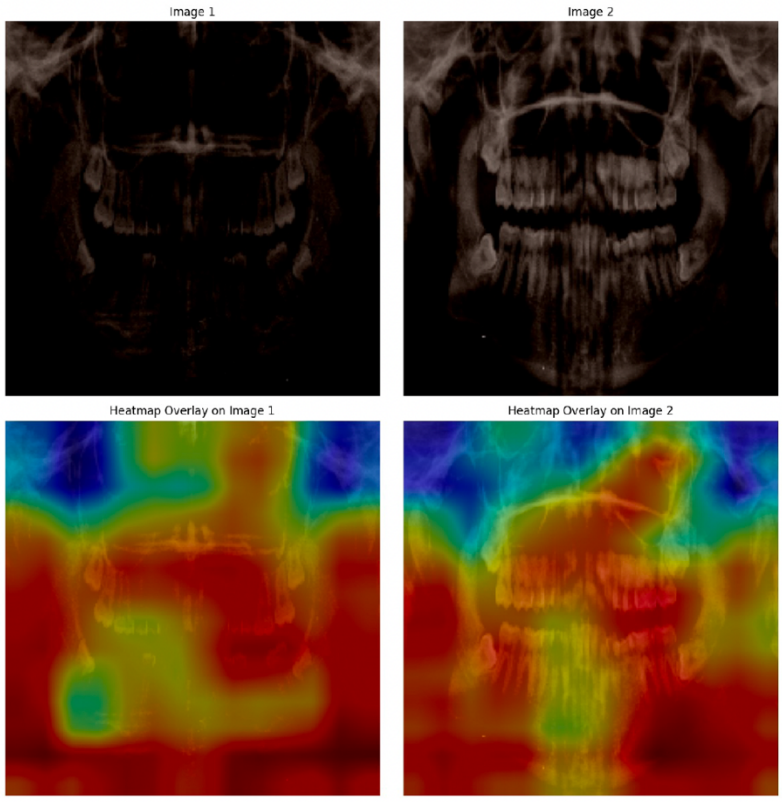

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 48ms/step
Model prediction: 0.0611
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 79
```



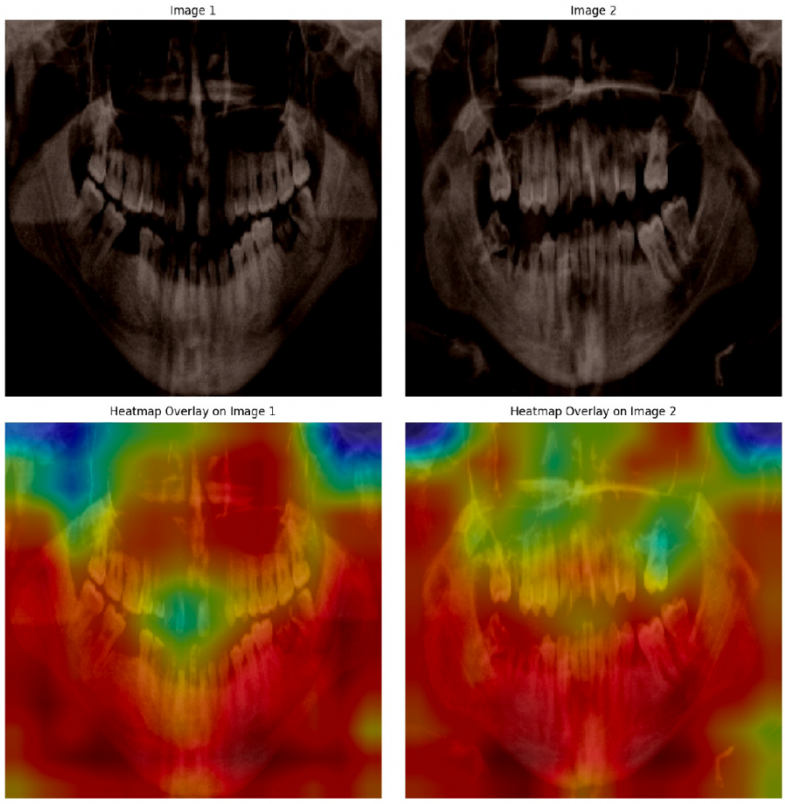

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 37ms/step
Model prediction: 0.3280
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 80
```



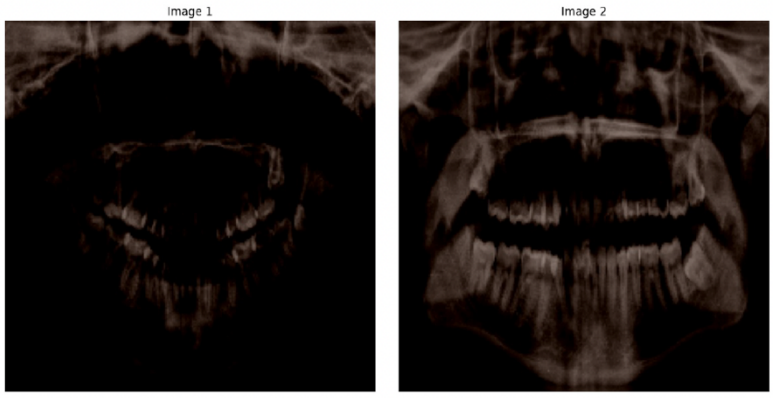

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.4257
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 82
```

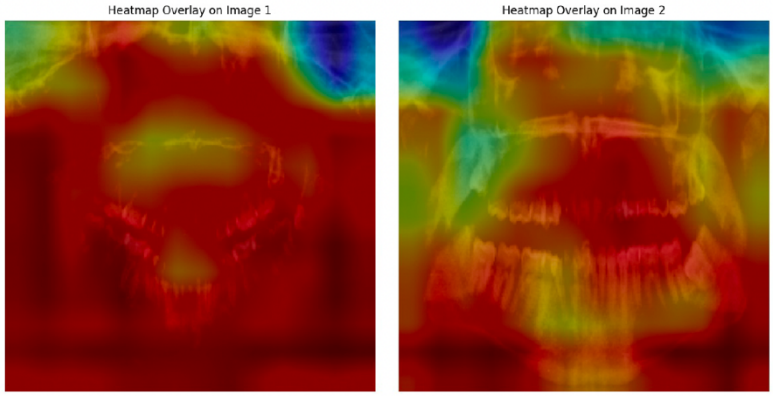



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 26ms/step
Model prediction: 0.3107
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 83
```

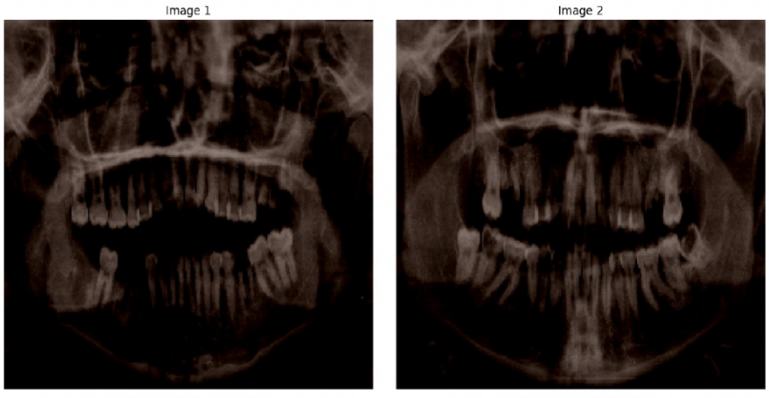


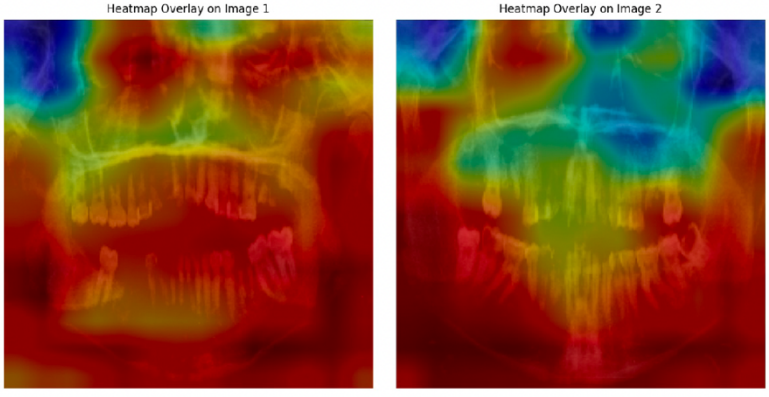

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.0616
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 84
```



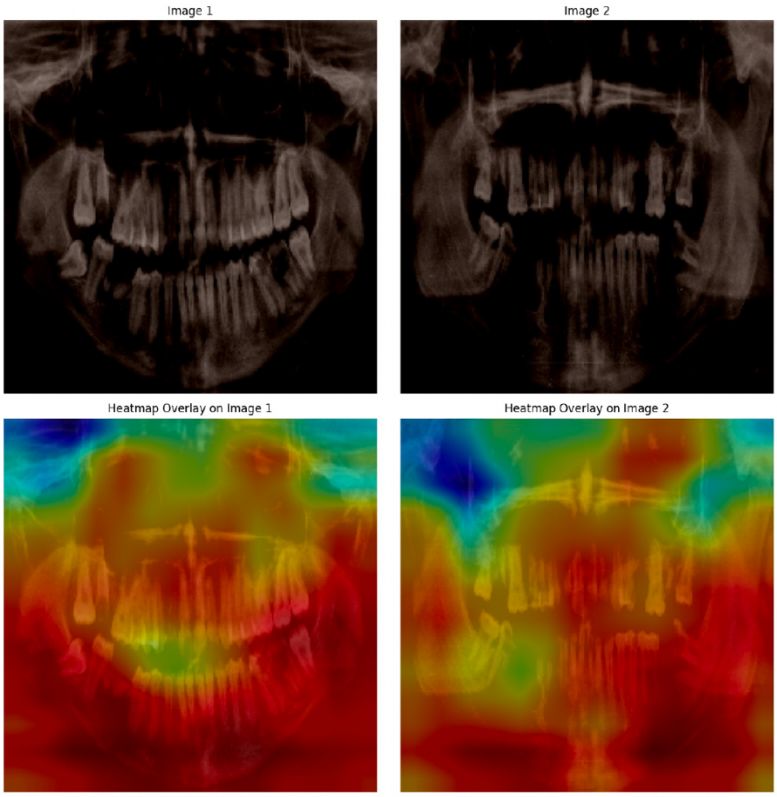



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 34ms/step
Model prediction: 0.1234
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 86
```

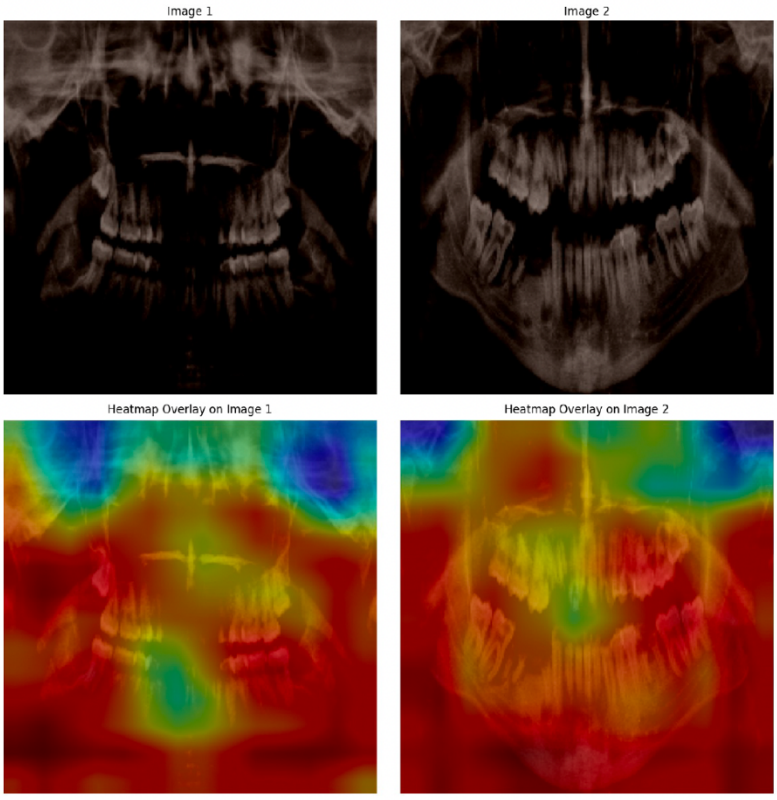




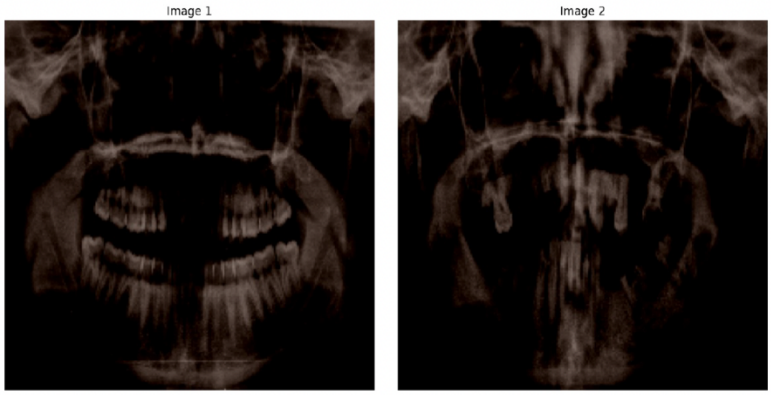

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.1821
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 87
```

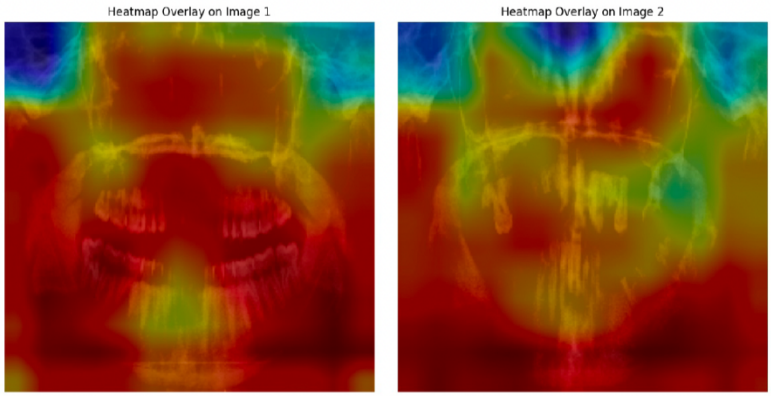



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 28ms/step
Model prediction: 0.1551
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 88
```

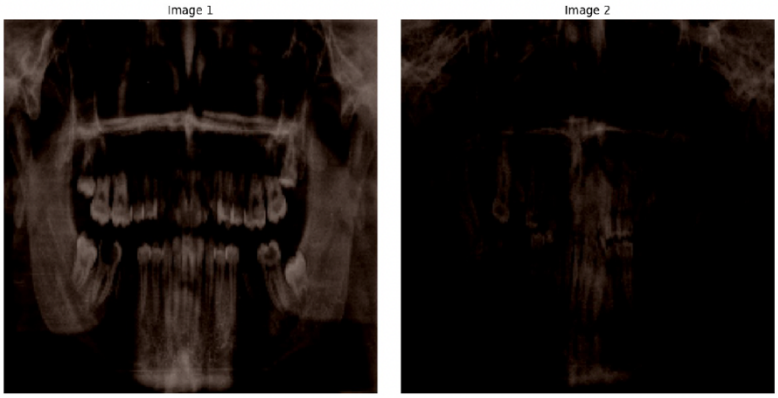


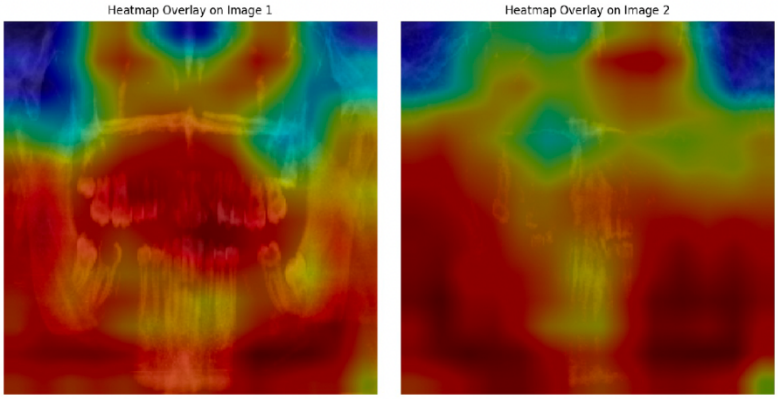

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 27ms/step
Model prediction: 0.4518
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 90
```



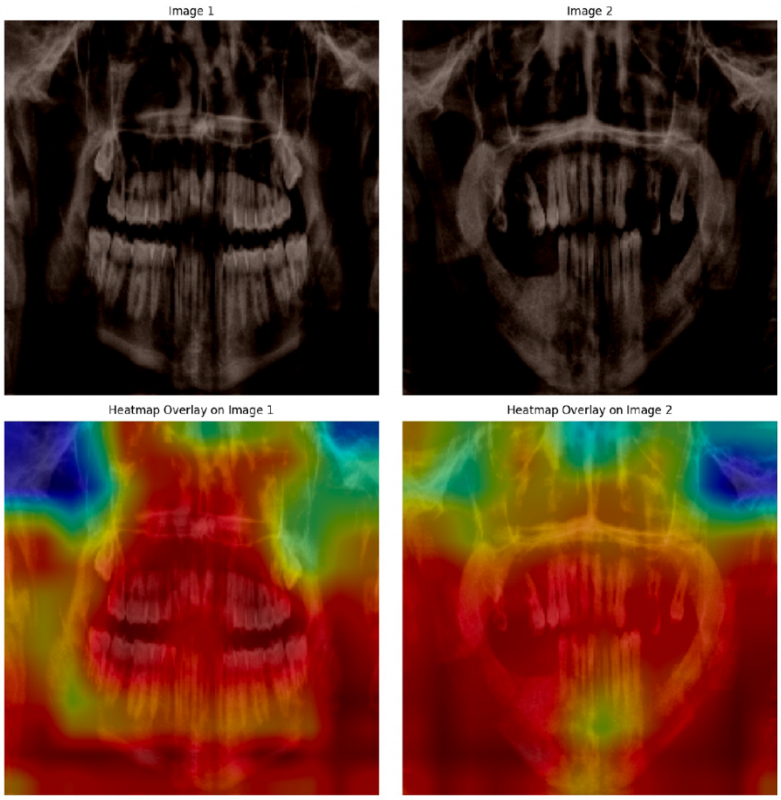



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.1998
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 91
```

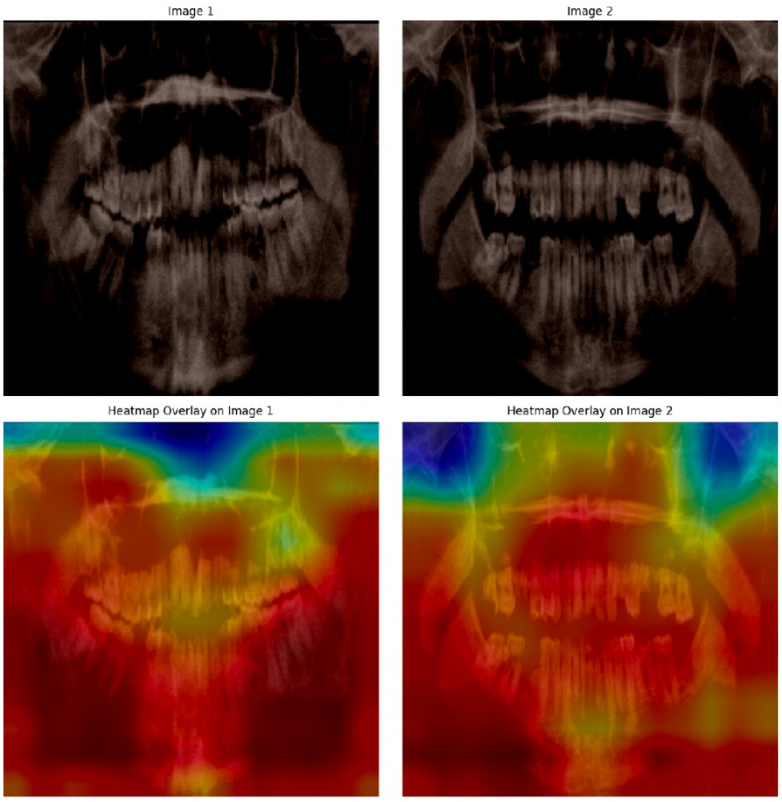




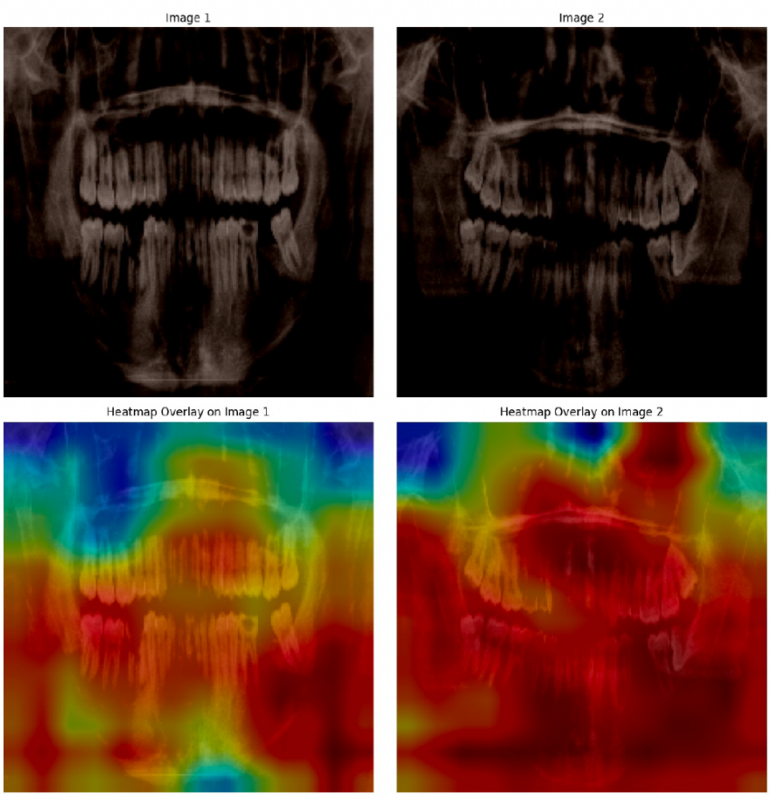

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.0770
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 93
```



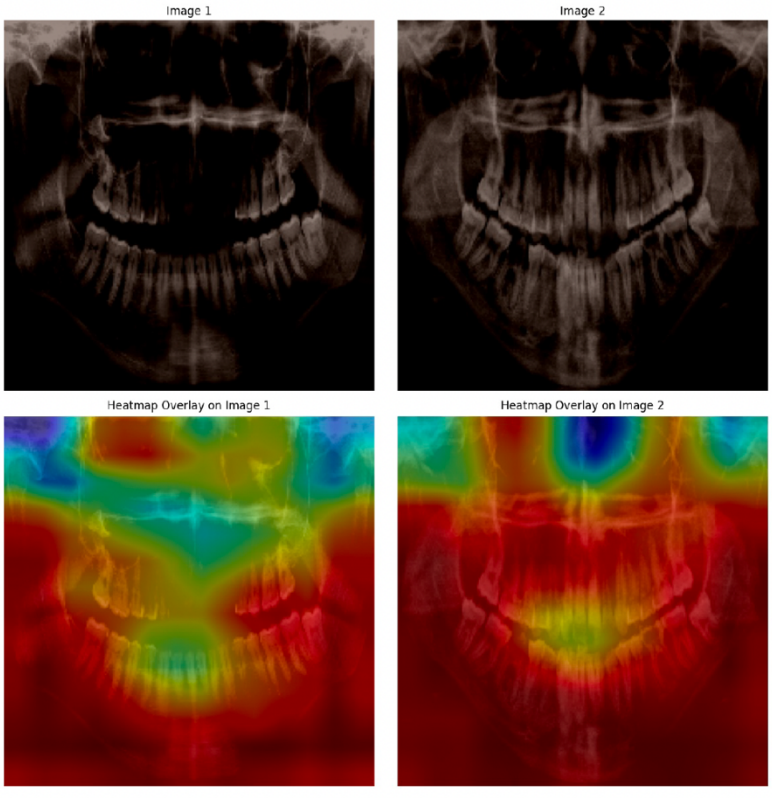

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.2280
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 95
```



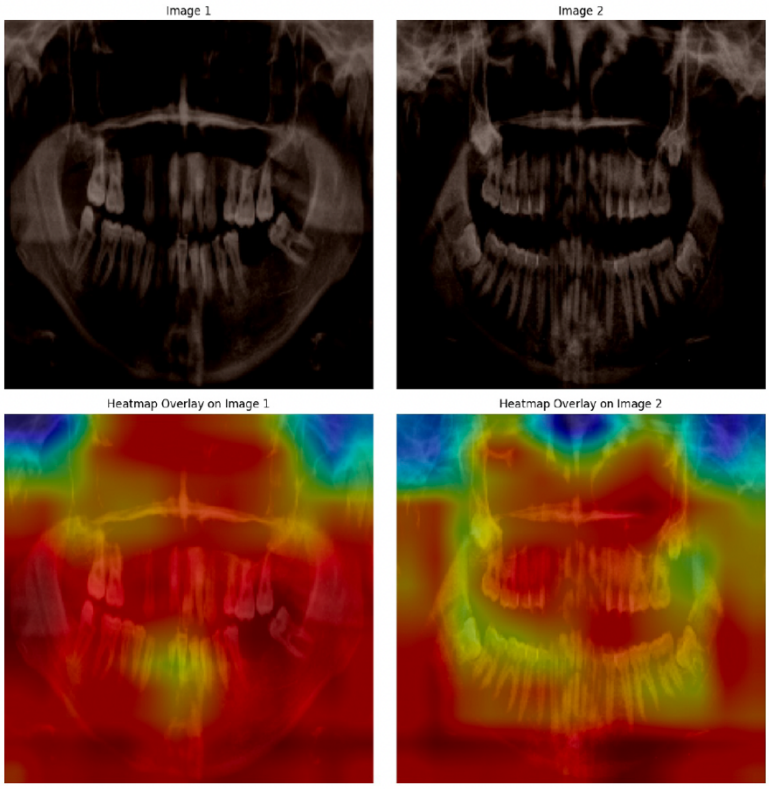

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.0685
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 98
```



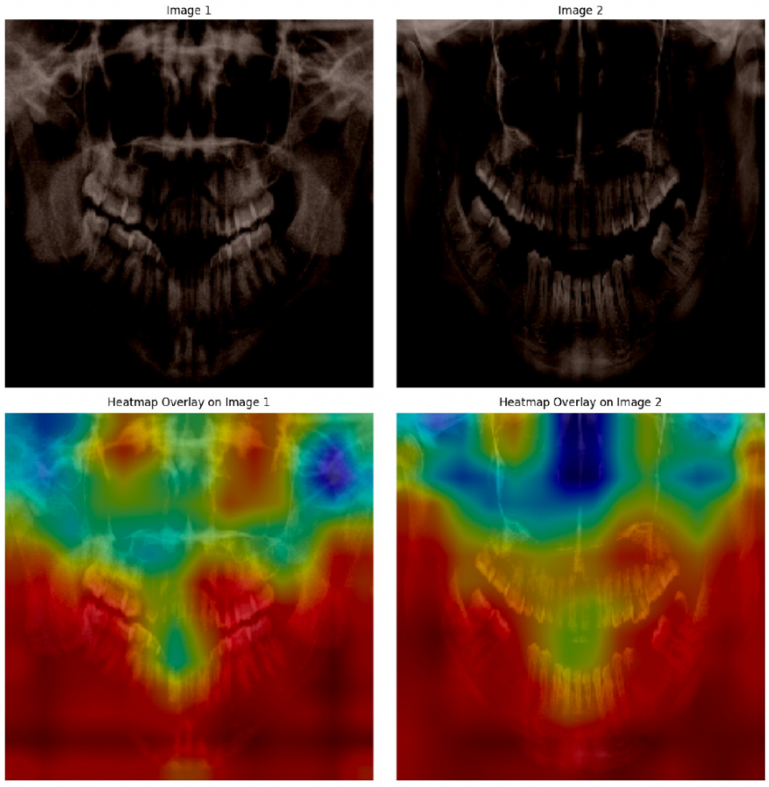

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.1508
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 99
```



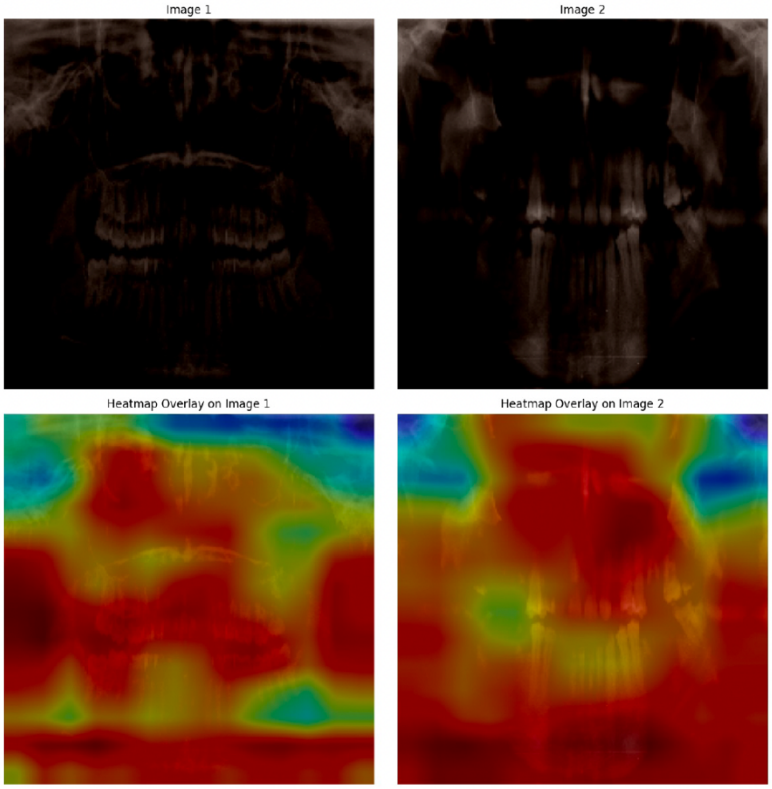

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.0593
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 101
```



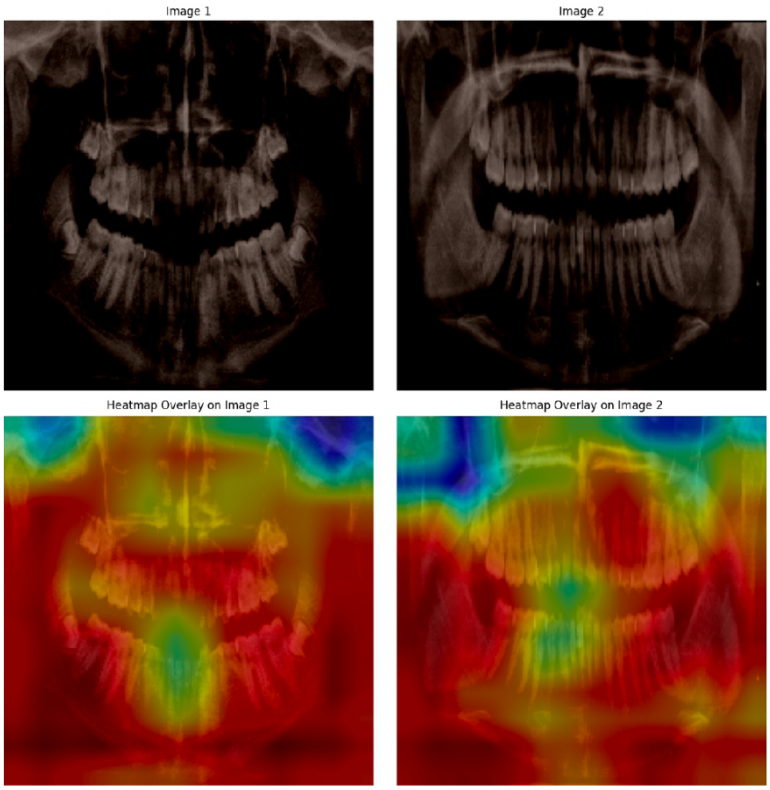

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.0857
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 103
```



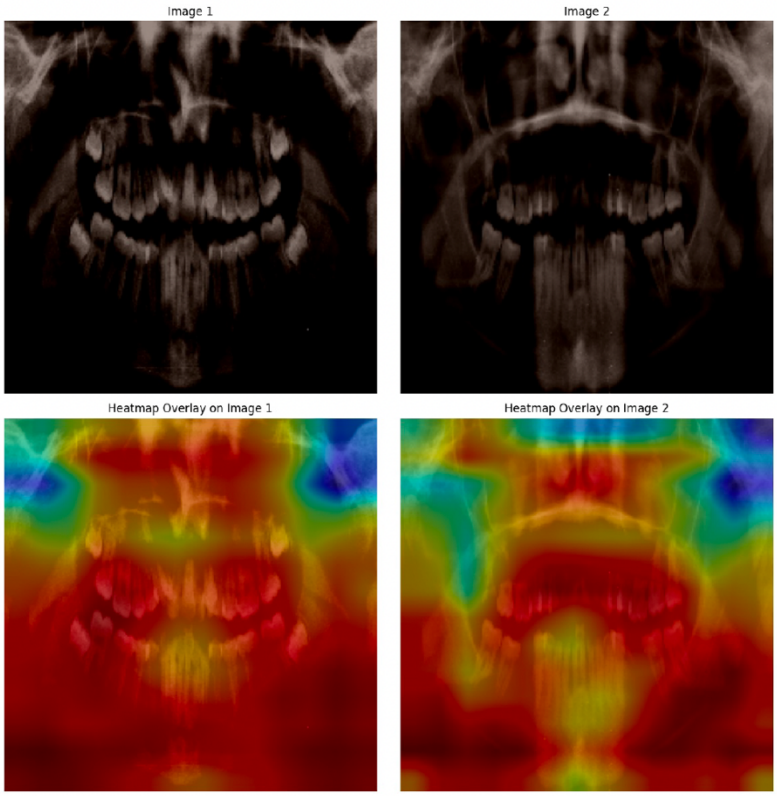

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.2082
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 104
```



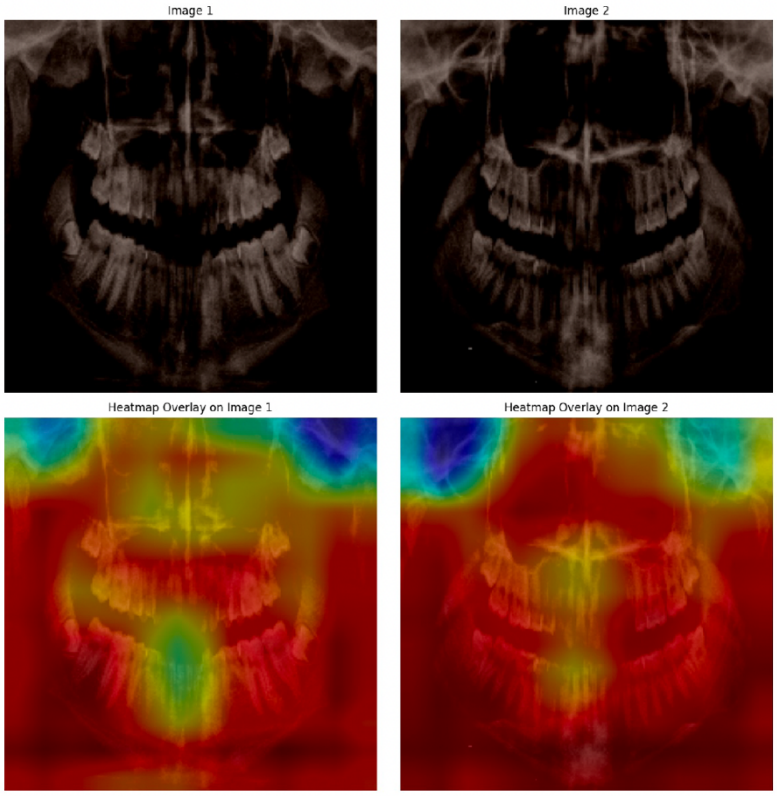

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.4154
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 105
```



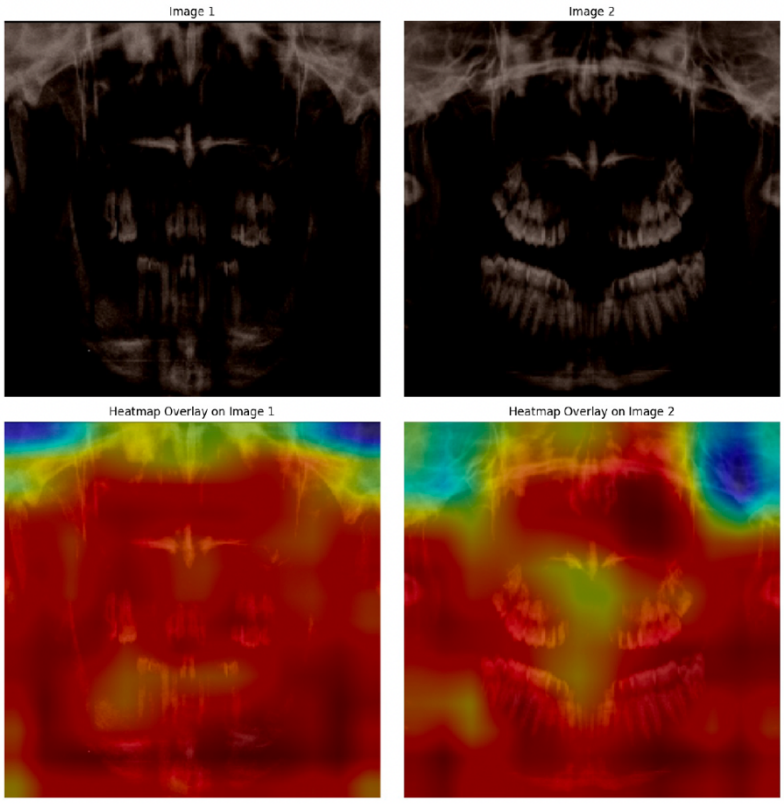

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 34ms/step
Model prediction: 0.3208
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 106
```



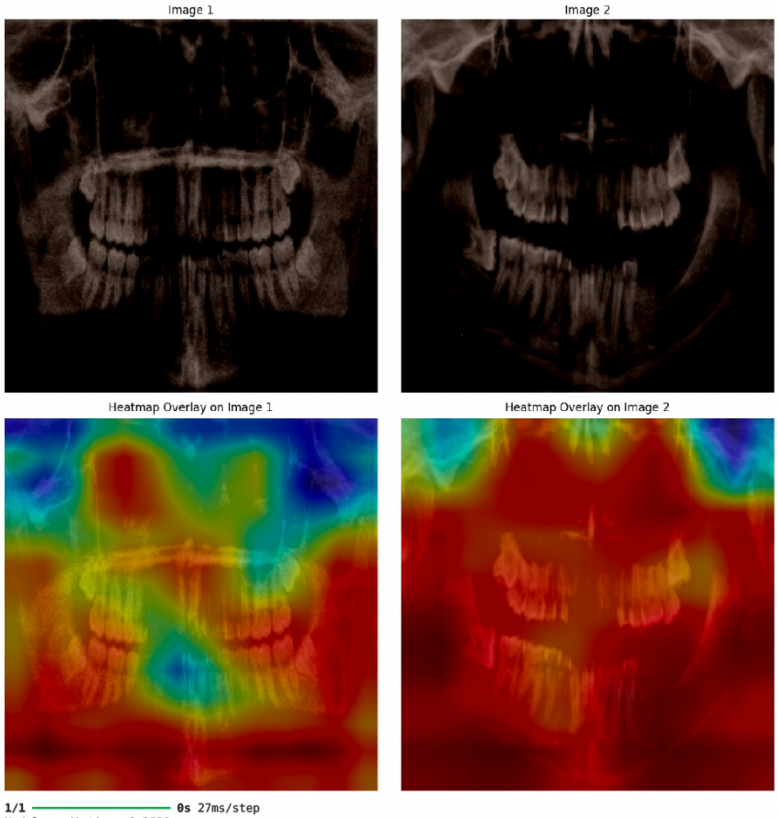

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 23ms/step
Model prediction: 0.2204
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 108
```



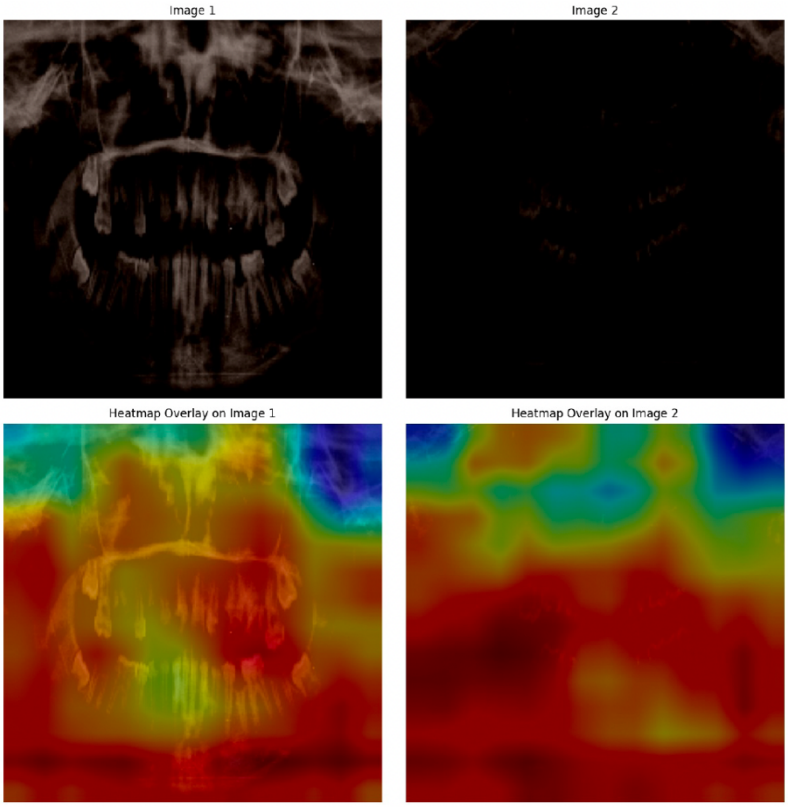

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 49ms/step
Model prediction: 0.1455
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 110
```



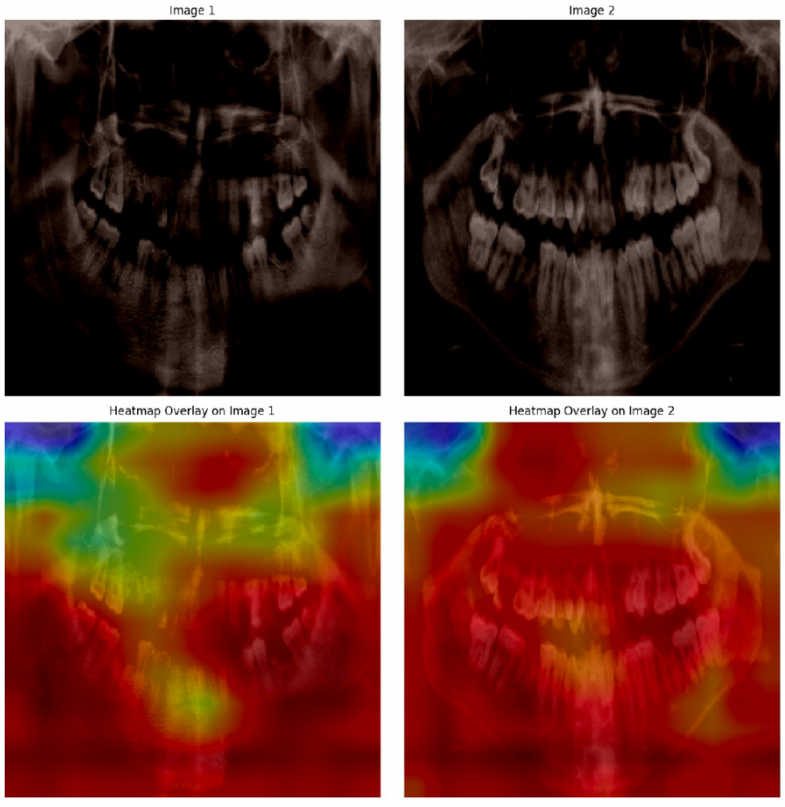

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 31ms/step
Model prediction: 0.4584
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 111
```



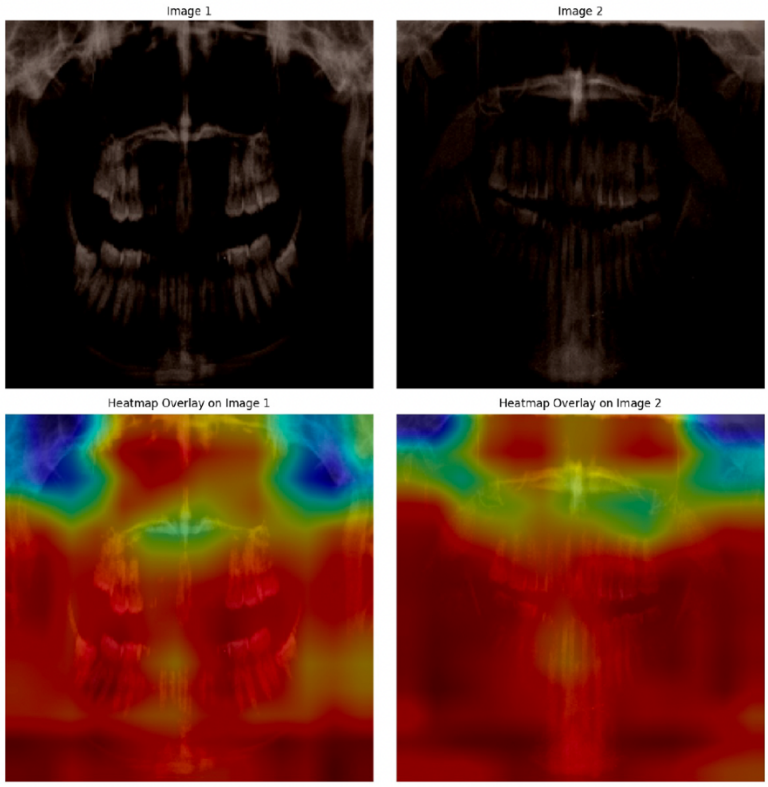

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 27ms/step
Model prediction: 0.2529
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 112
```



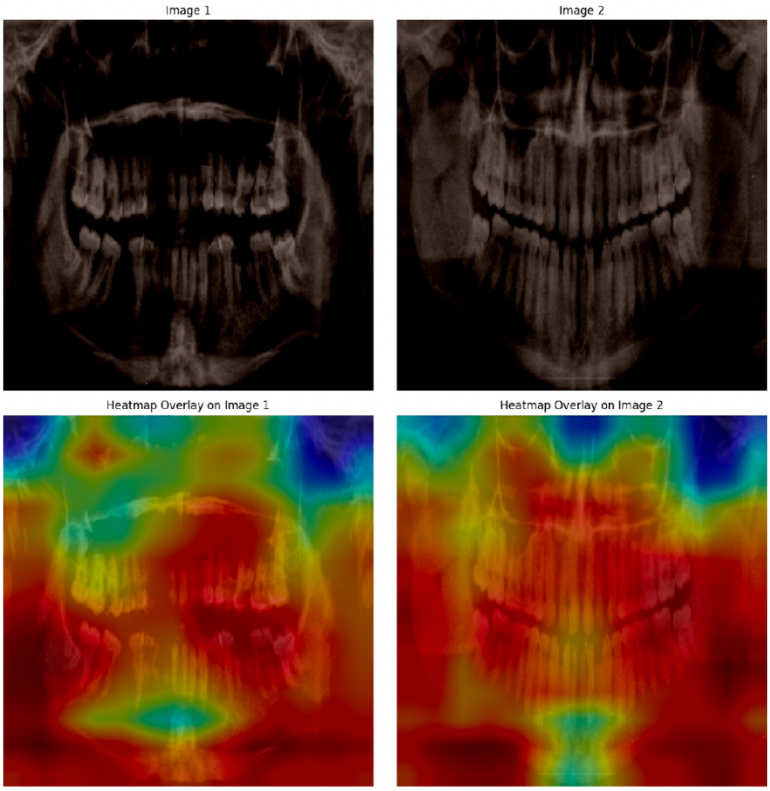

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.1869
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 113
```



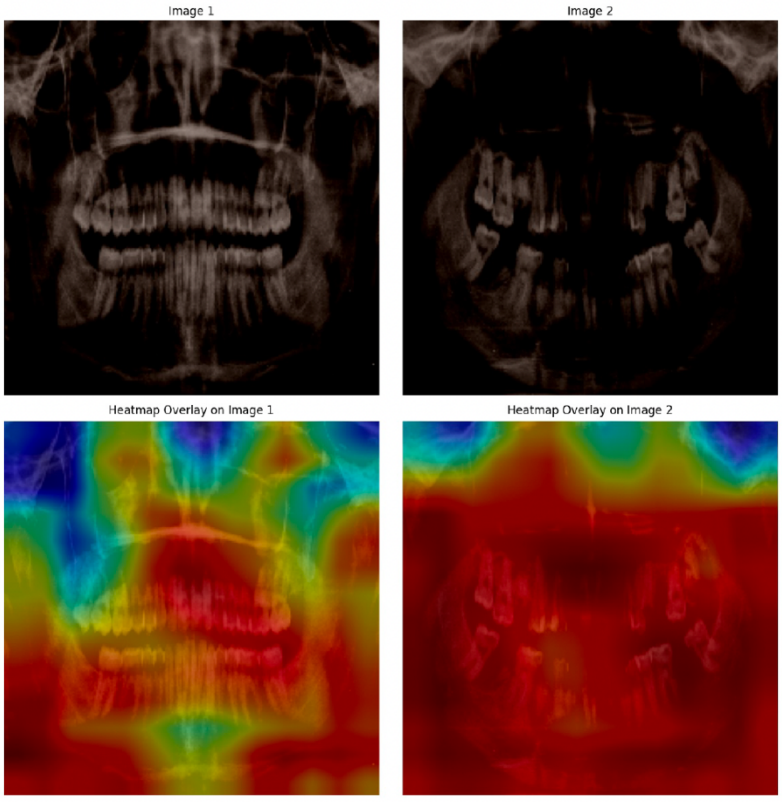

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 31ms/step
Model prediction: 0.1172
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 114
```



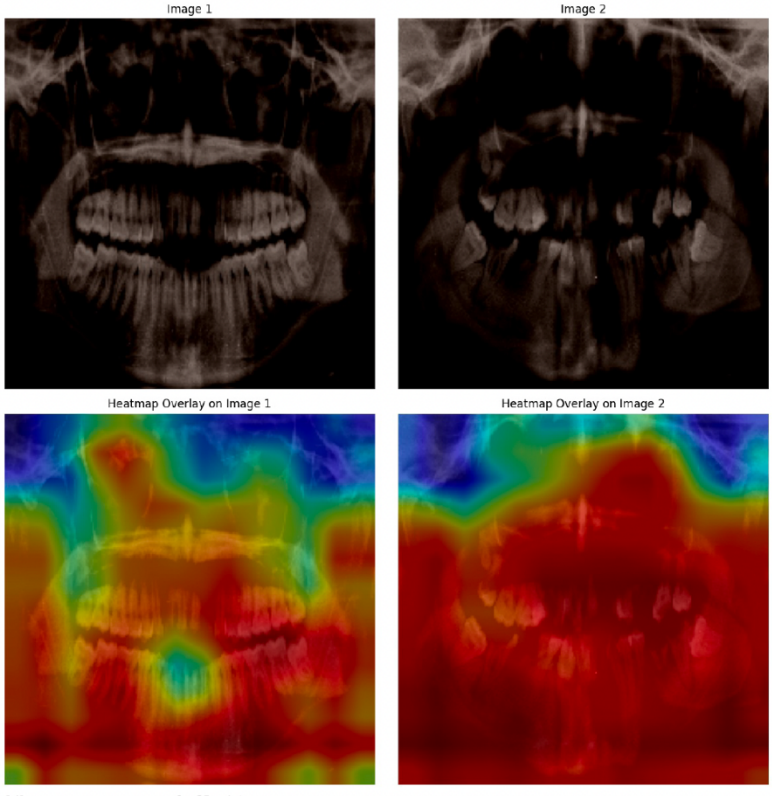

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 26ms/step
Model prediction: 0.0807
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 117
```



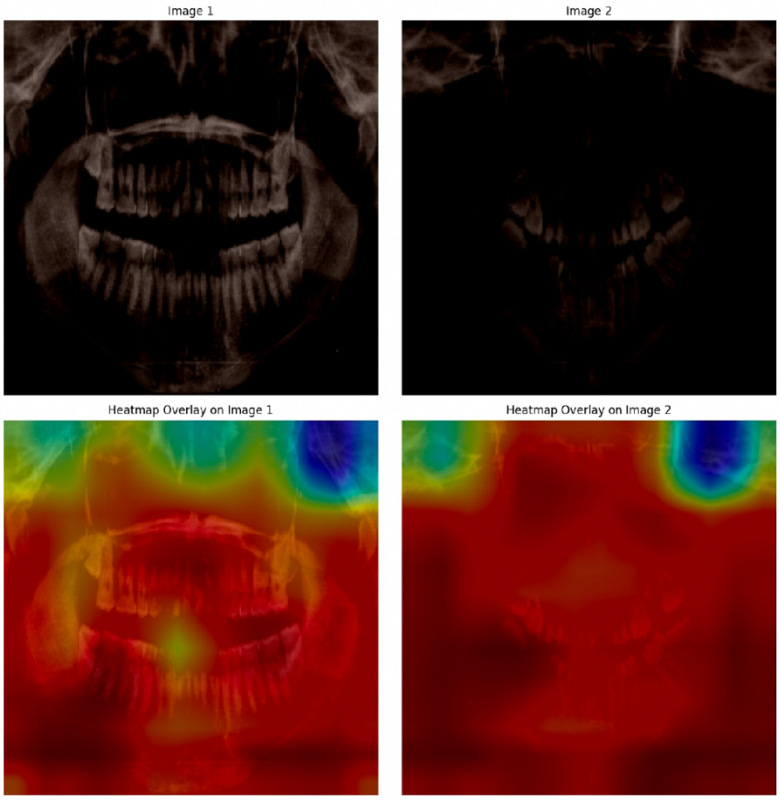

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 39ms/step
Model prediction: 0.2621
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 118
```



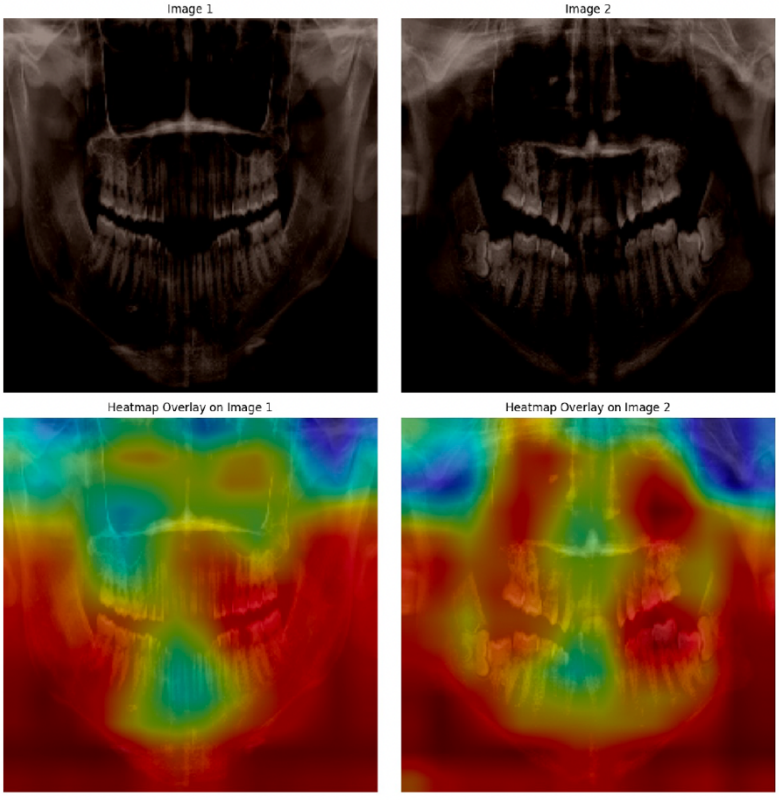

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 37ms/step
Model prediction: 0.2273
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 119
```



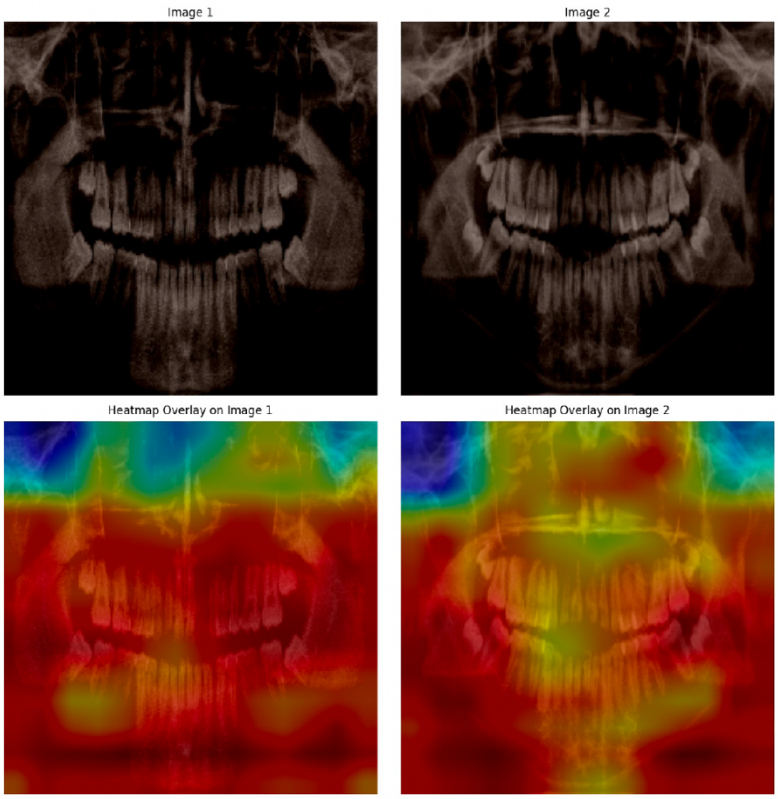

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 35ms/step
Model prediction: 0.2281
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 121
```



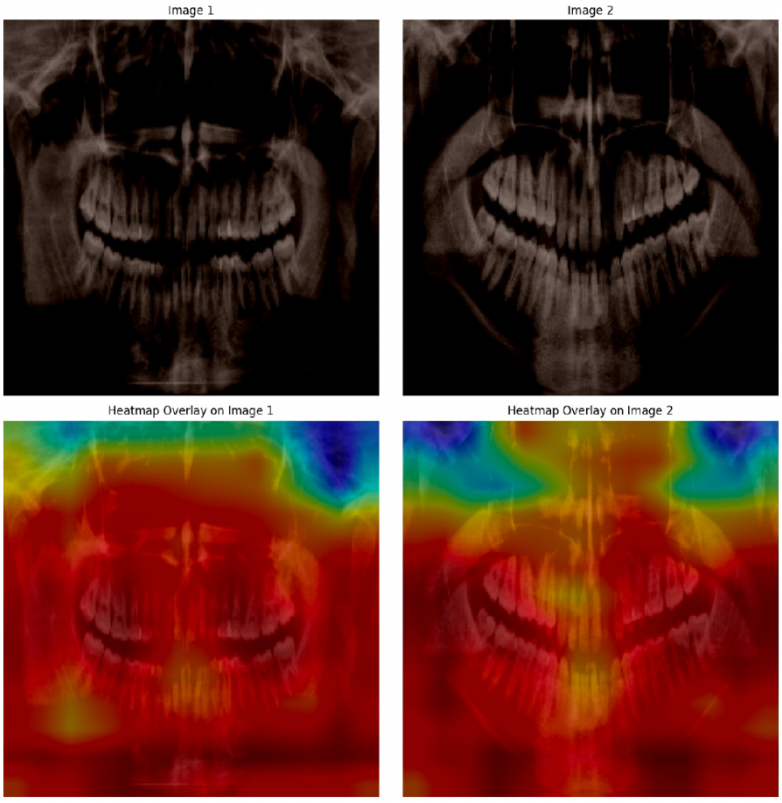

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 24ms/step
Model prediction: 0.1823
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 122
```



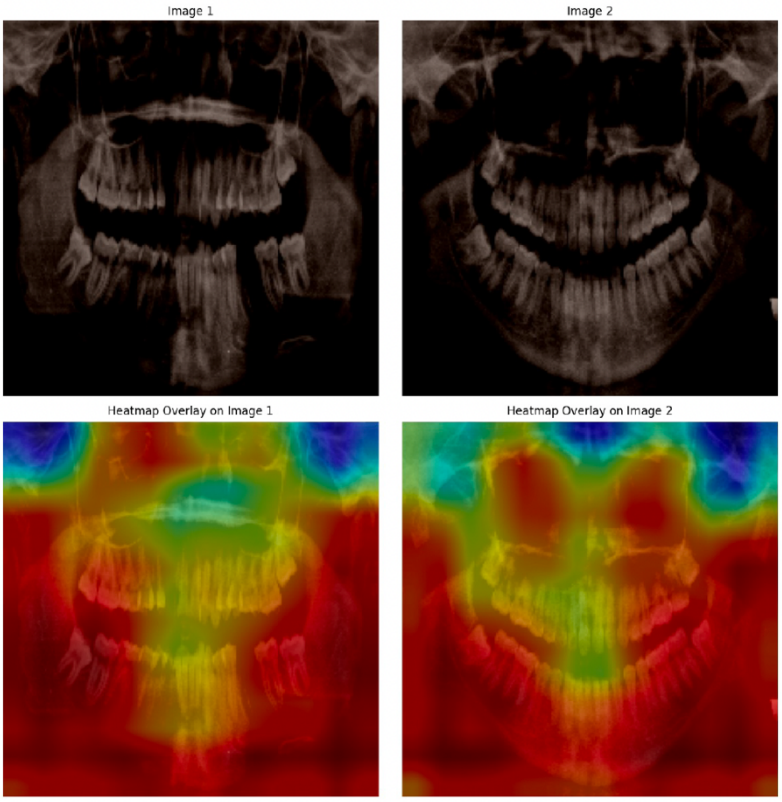

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 37ms/step
Model prediction: 0.1031
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 123
```



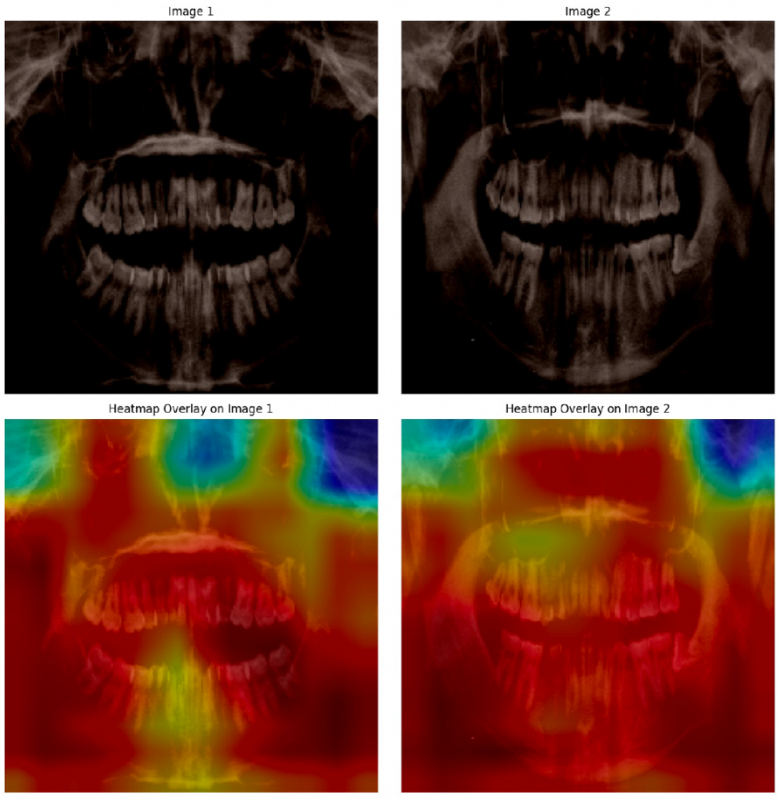

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 44ms/step
Model prediction: 0.2739
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 125
```



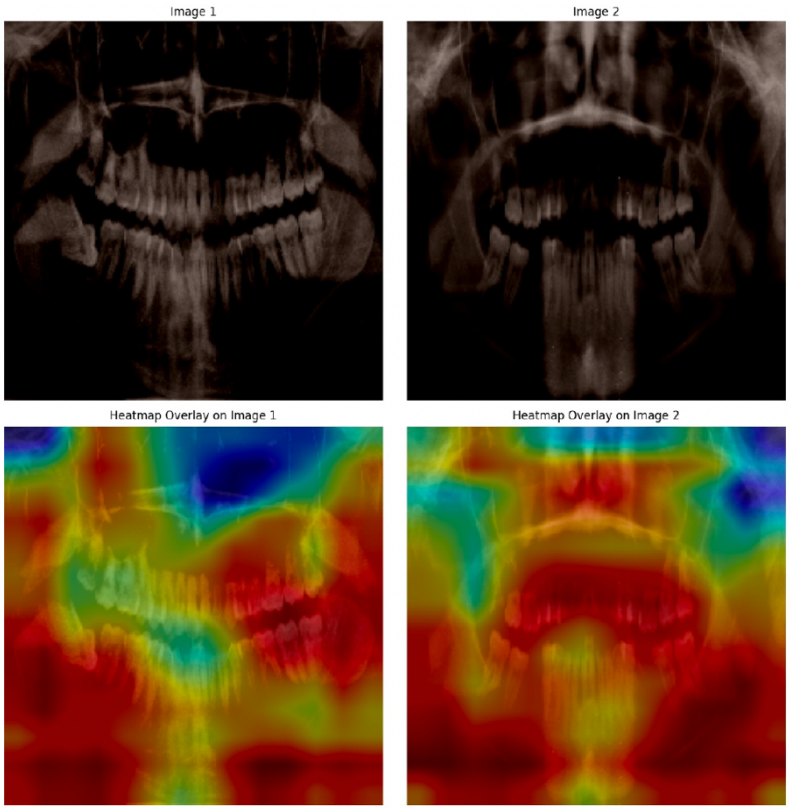

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 39ms/step
Model prediction: 0.1967
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 126
```



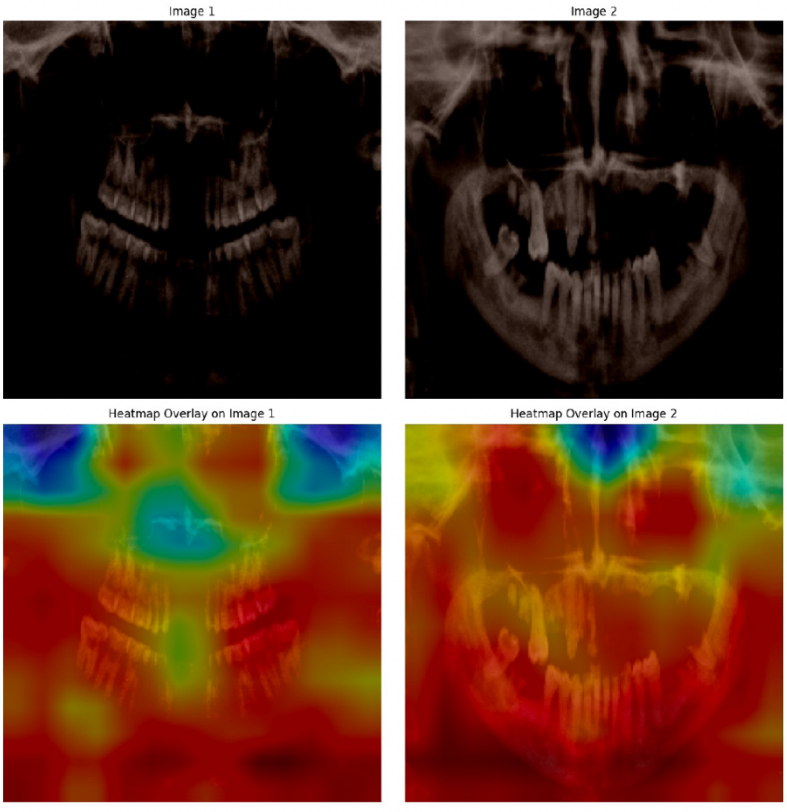

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 38ms/step
Model prediction: 0.1633
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 127
```



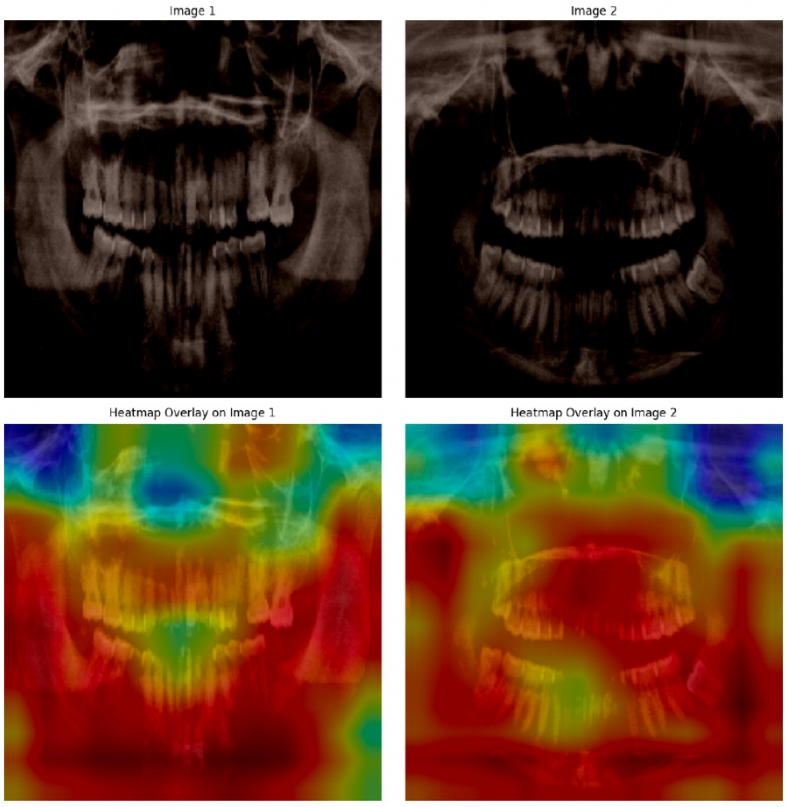

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 27ms/step
Model prediction: 0.2256
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 128
```



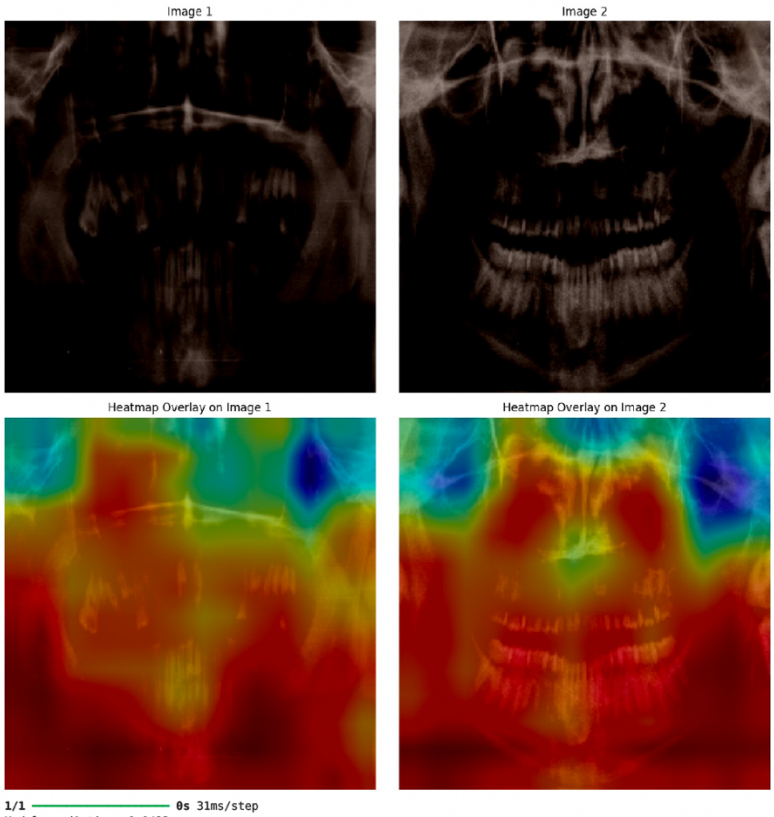

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 27ms/step
Model prediction: 0.2089
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 129
```



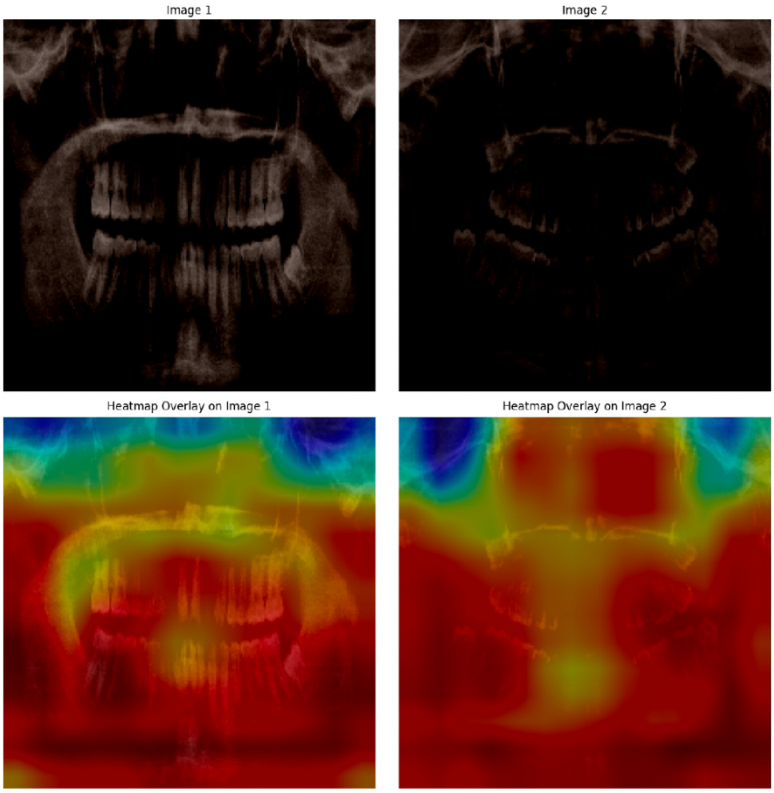

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.4130
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 130
```



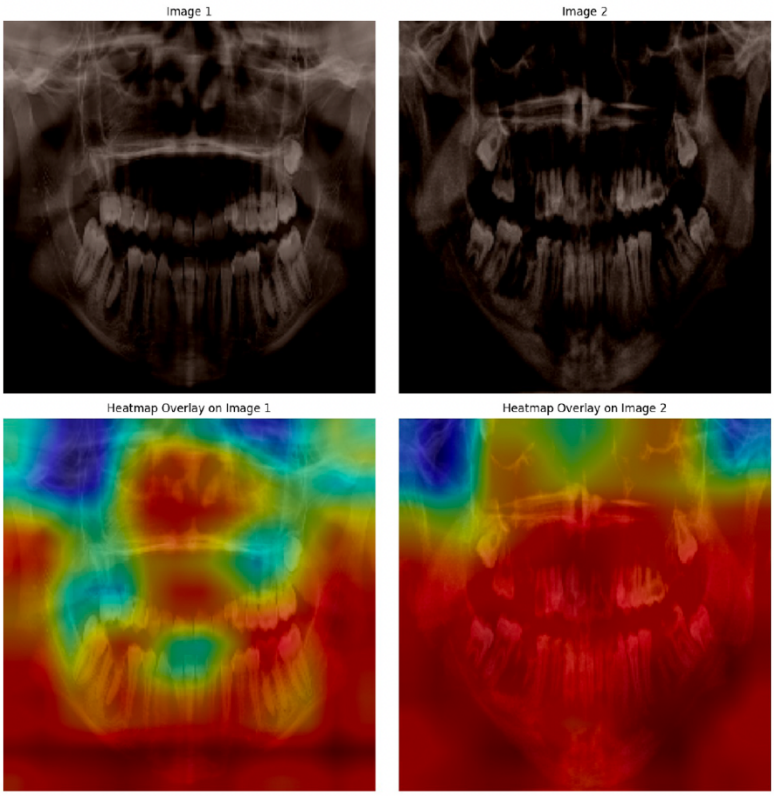

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 39ms/step
Model prediction: 0.1988
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 131
```



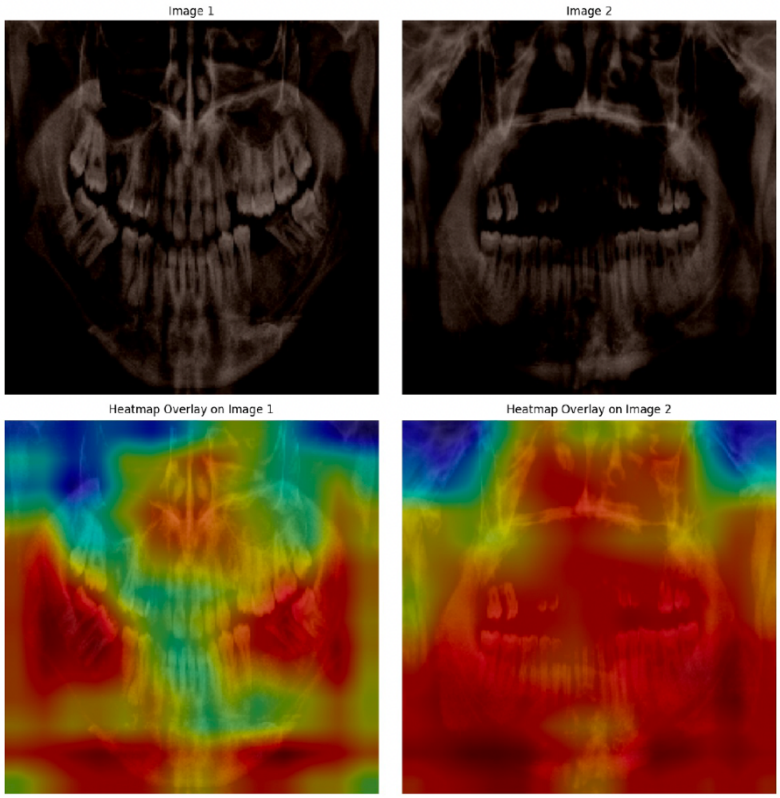

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 31ms/step
Model prediction: 0.0423
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 132
```



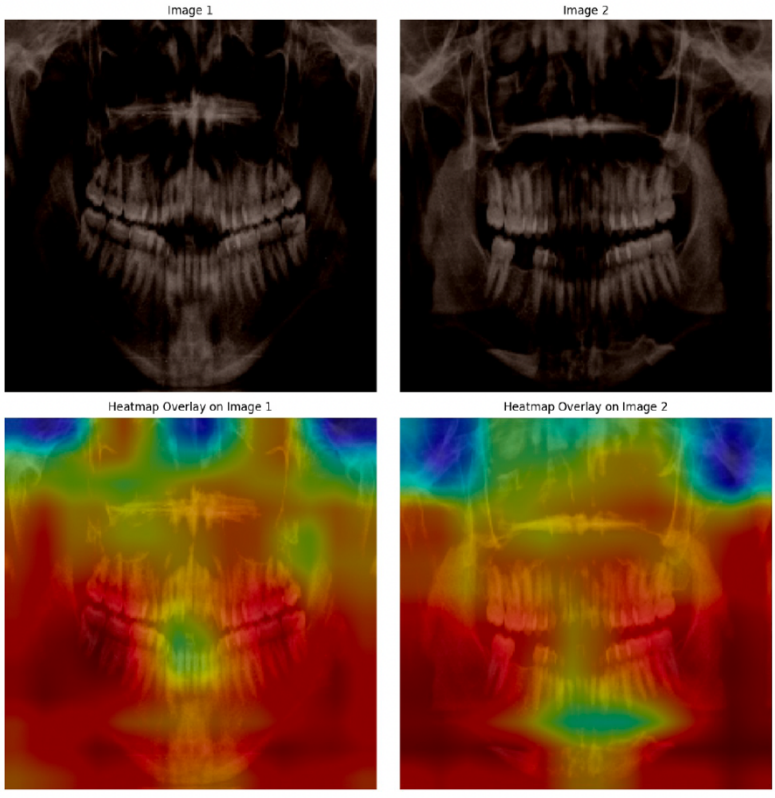

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 30ms/step
Model prediction: 0.4731
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 133
```



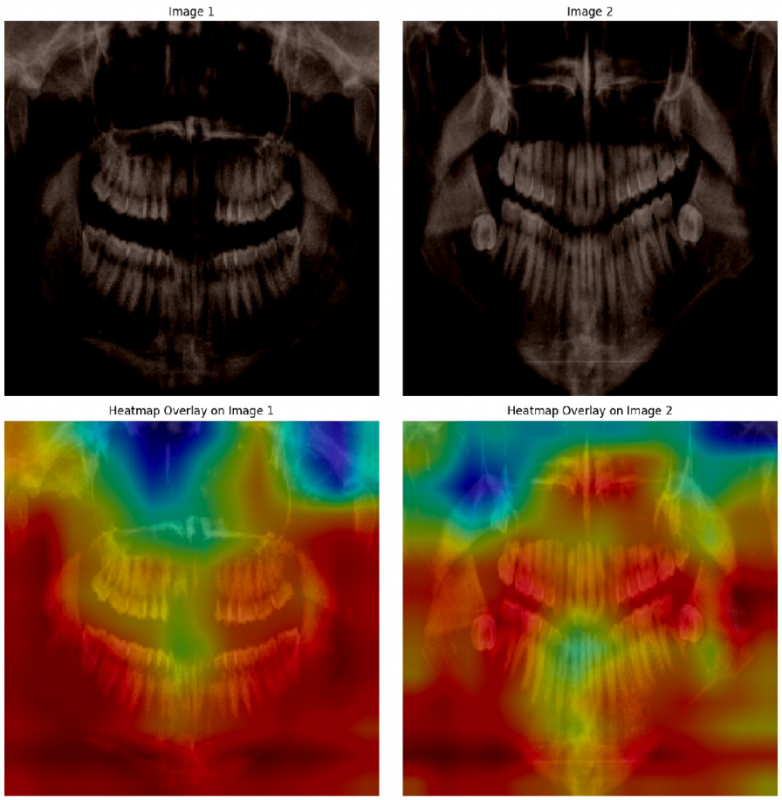

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 39ms/step
Model prediction: 0.1426
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 134
```



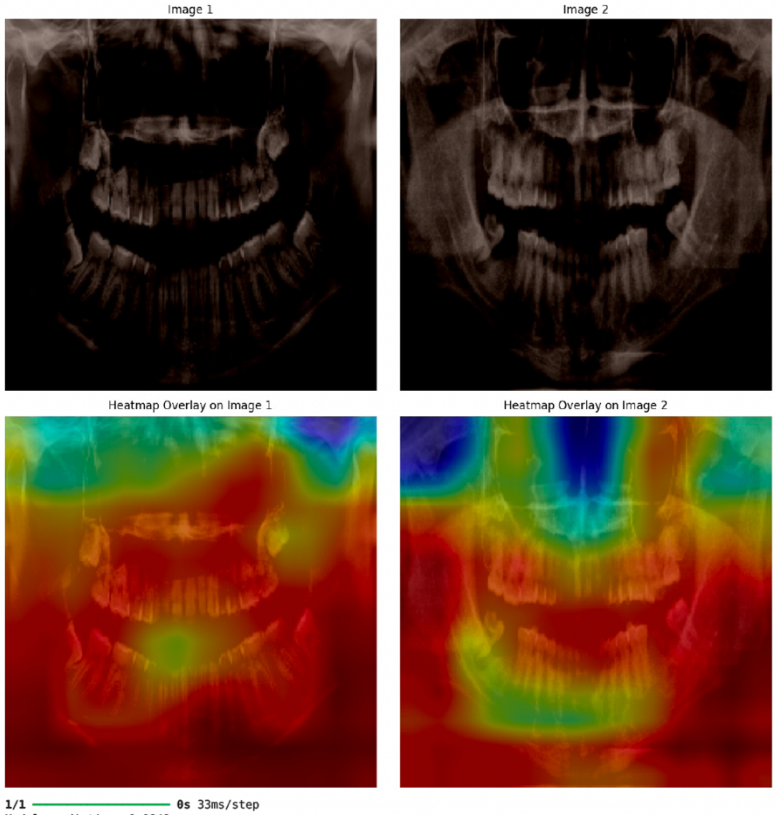

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 41ms/step
Model prediction: 0.2286
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 137
```



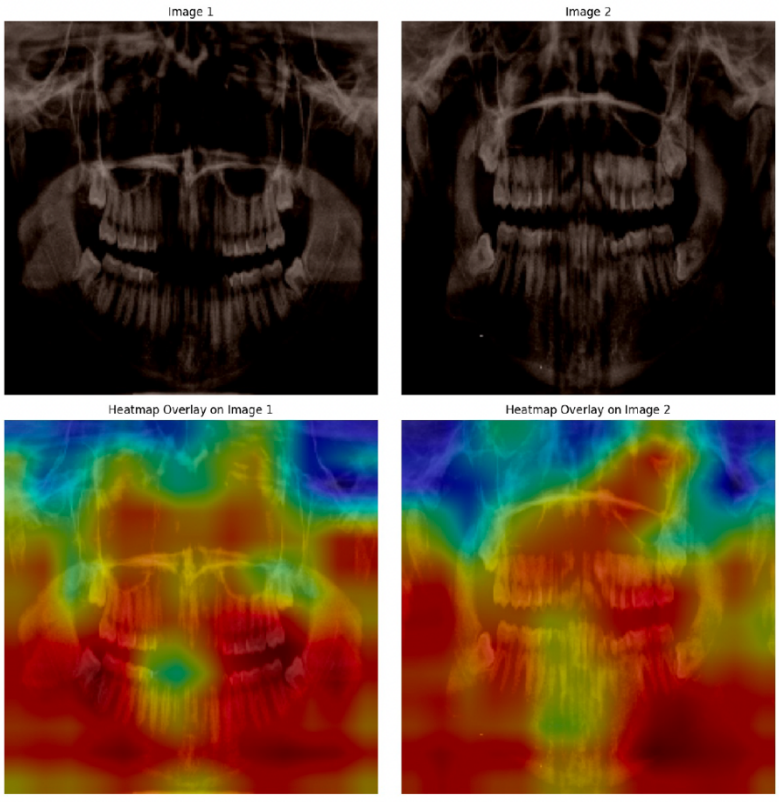

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 31ms/step
Model prediction: 0.3751
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 135
```



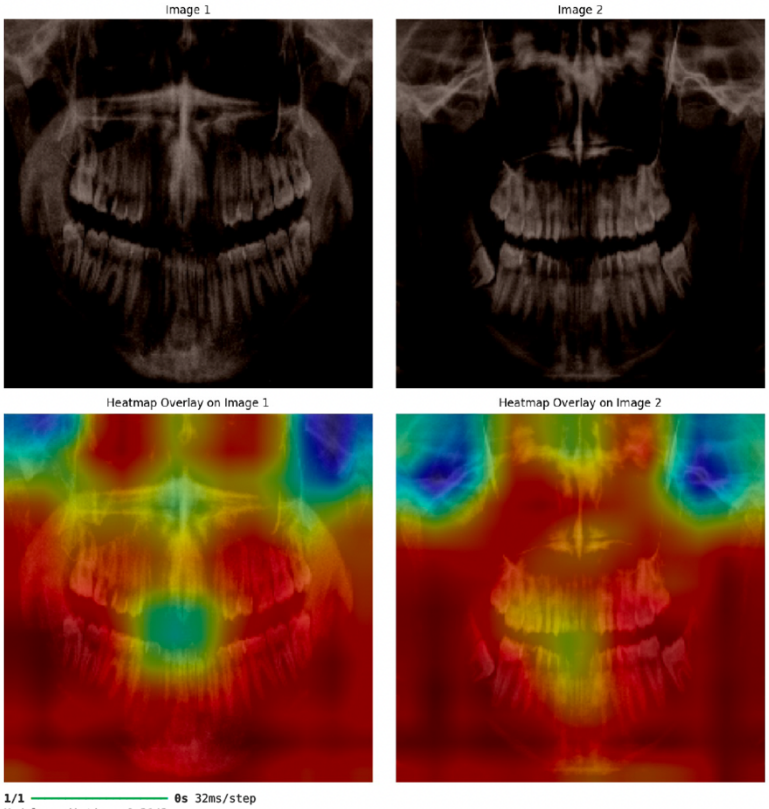

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 28ms/step
Model prediction: 0.0836
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 138
```



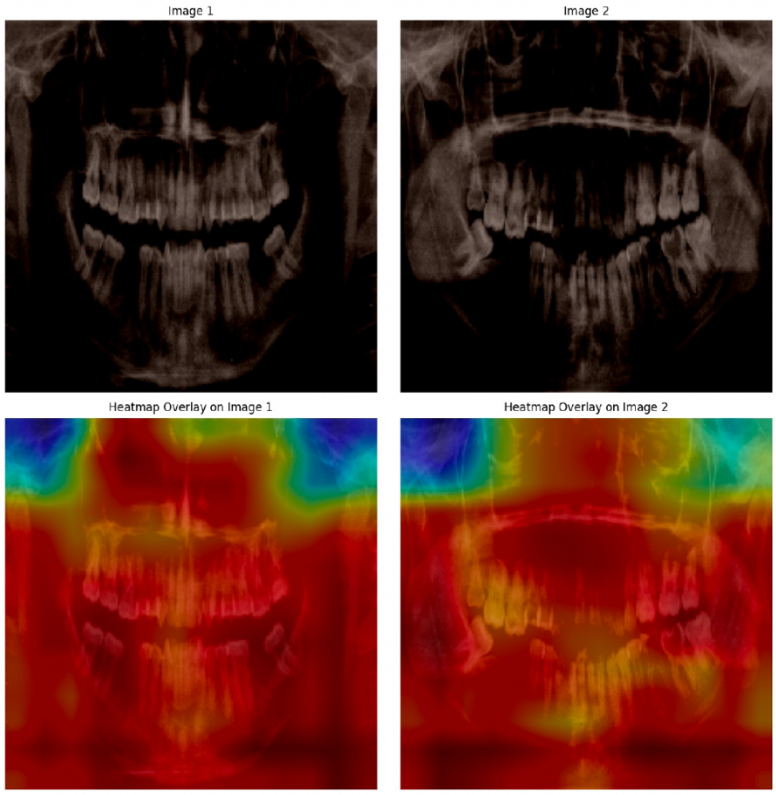

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 33ms/step
Model prediction: 0.0849
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 139
```



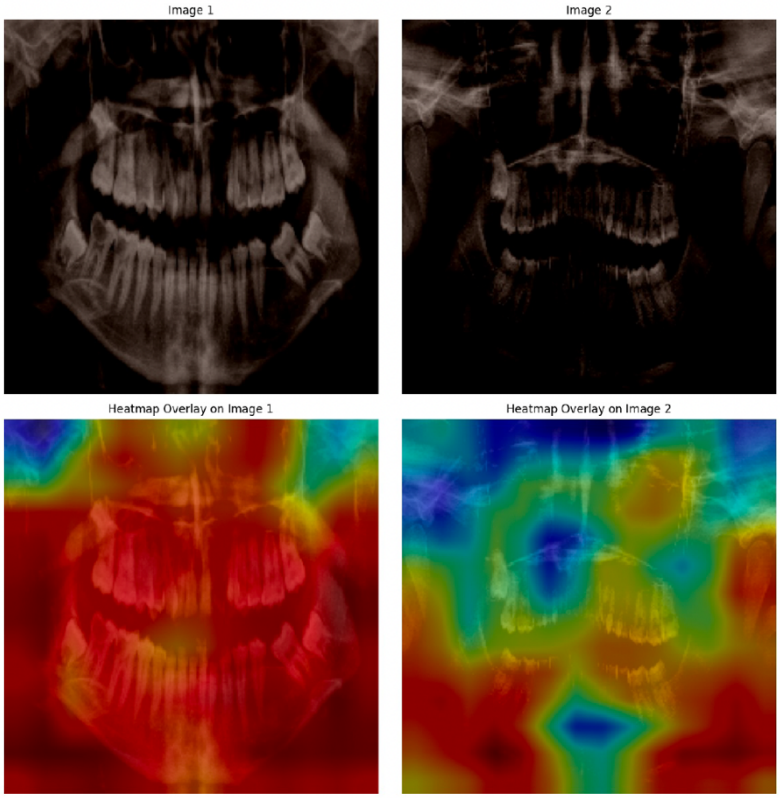

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 36ms/step
Model prediction: 0.2261
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 142
```



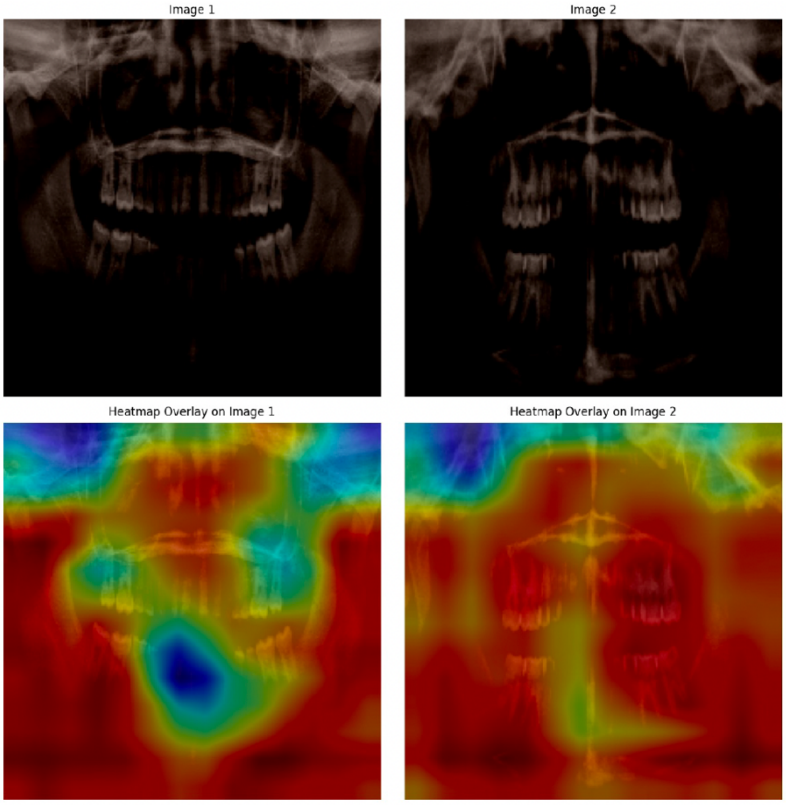

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 32ms/step
Model prediction: 0.3142
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 144
```



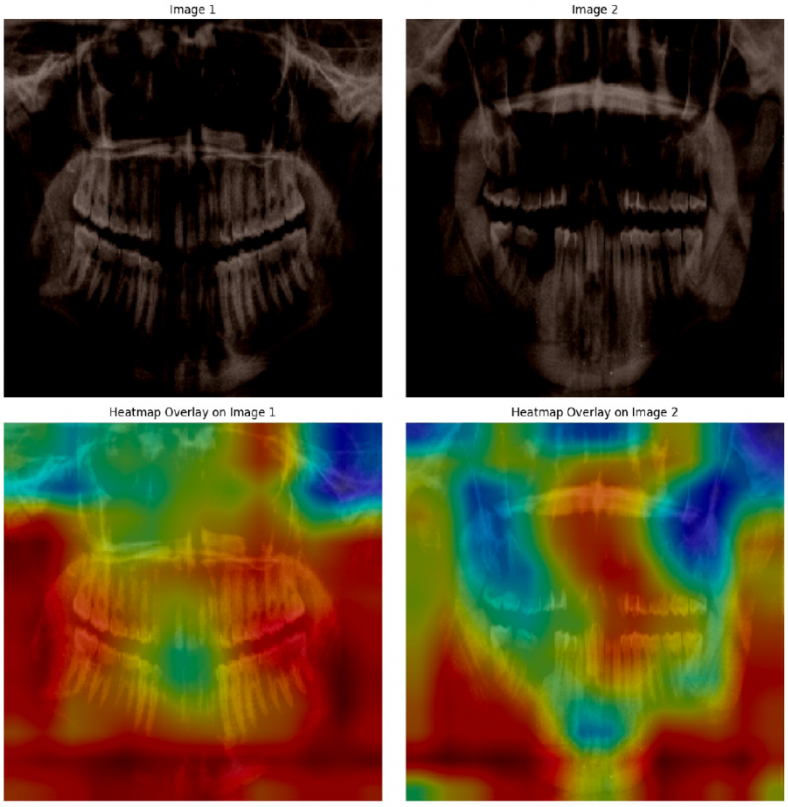

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 30ms/step
Model prediction: 0.1196
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 148
```



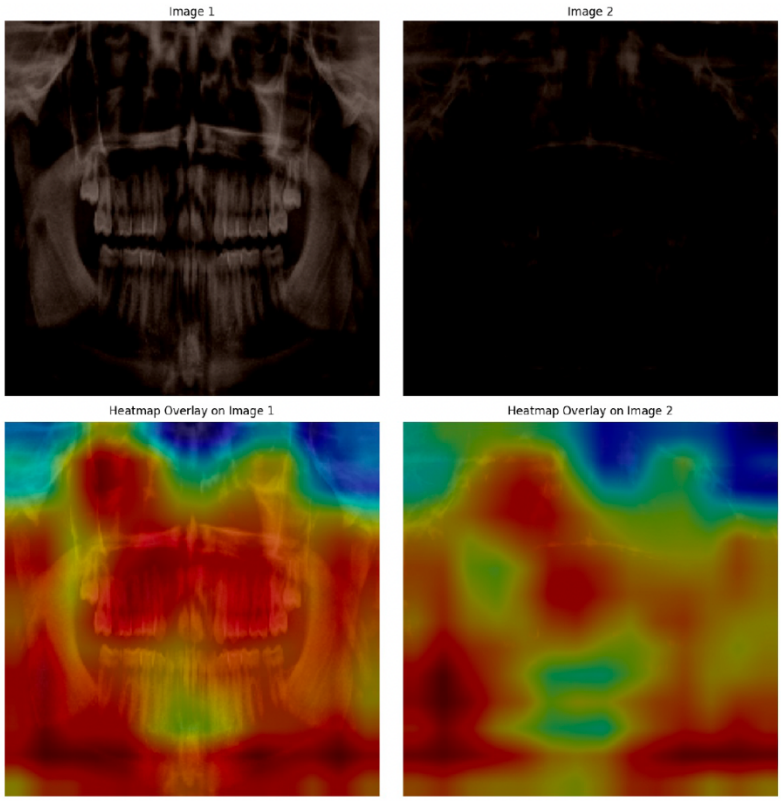

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 26ms/step
Model prediction: 0.0452
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 149
```



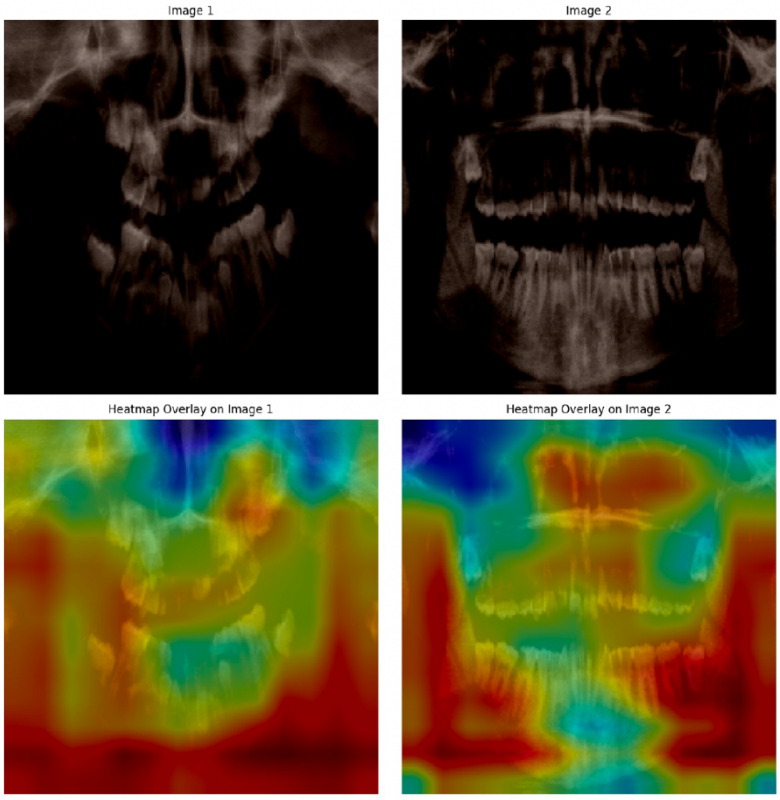

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 37ms/step
Model prediction: 0.2810
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 150
```



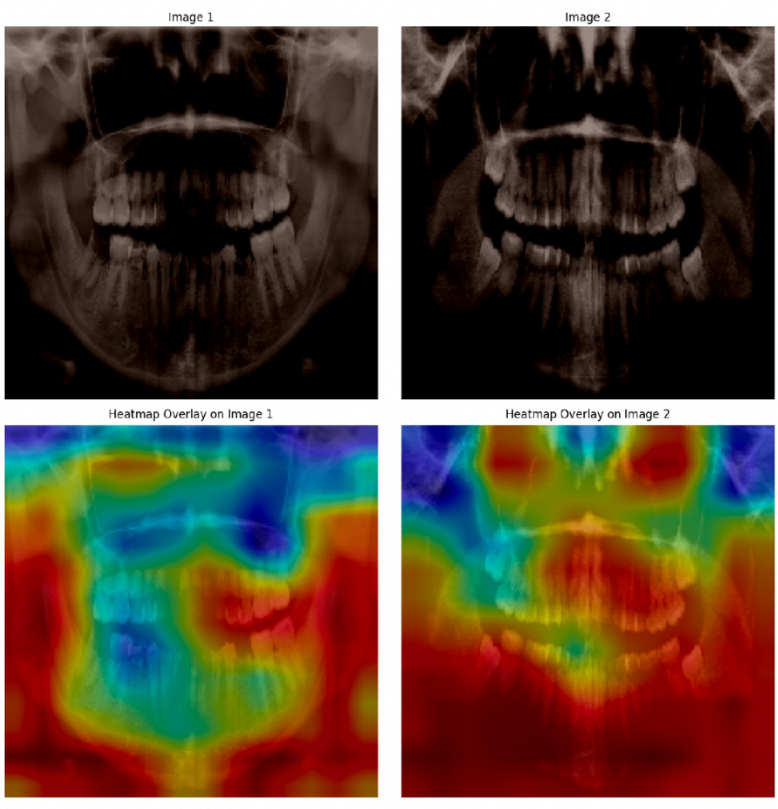

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 24ms/step
Model prediction: 0.0834
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 152
```



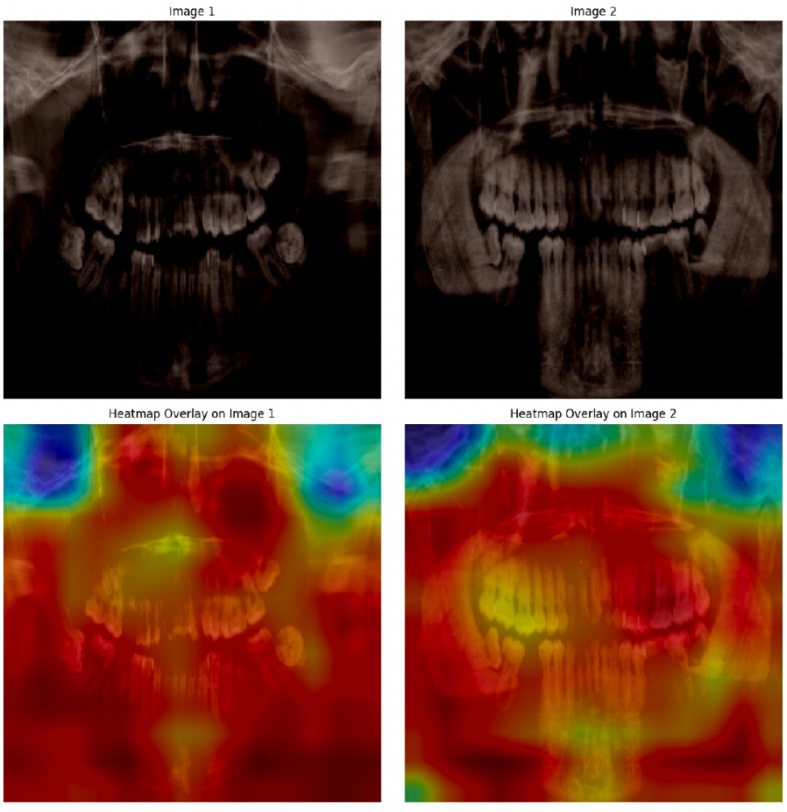

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.2381
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 155
```



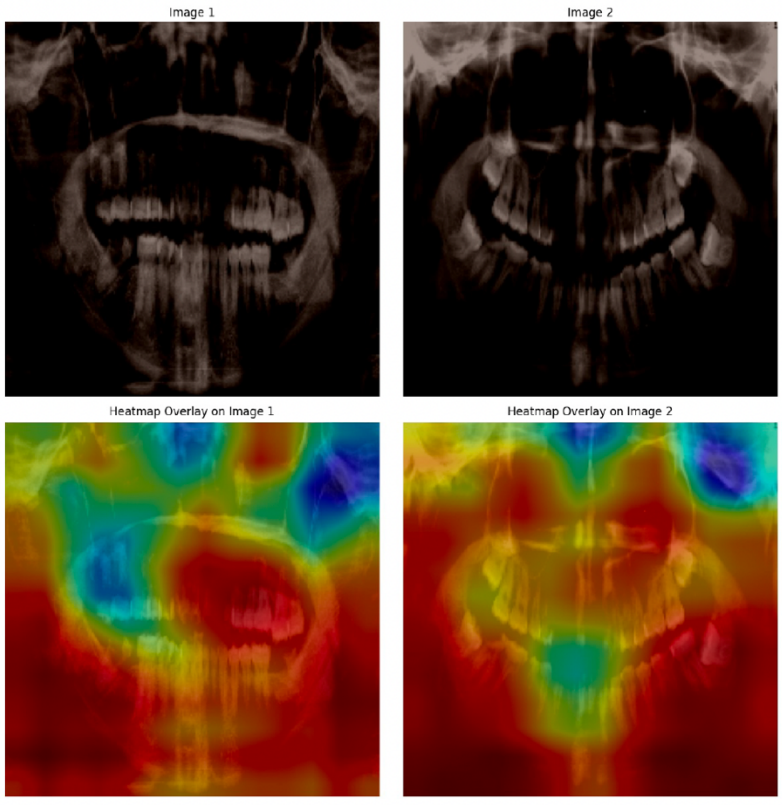

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 20ms/step
Model prediction: 0.0385
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 156
```



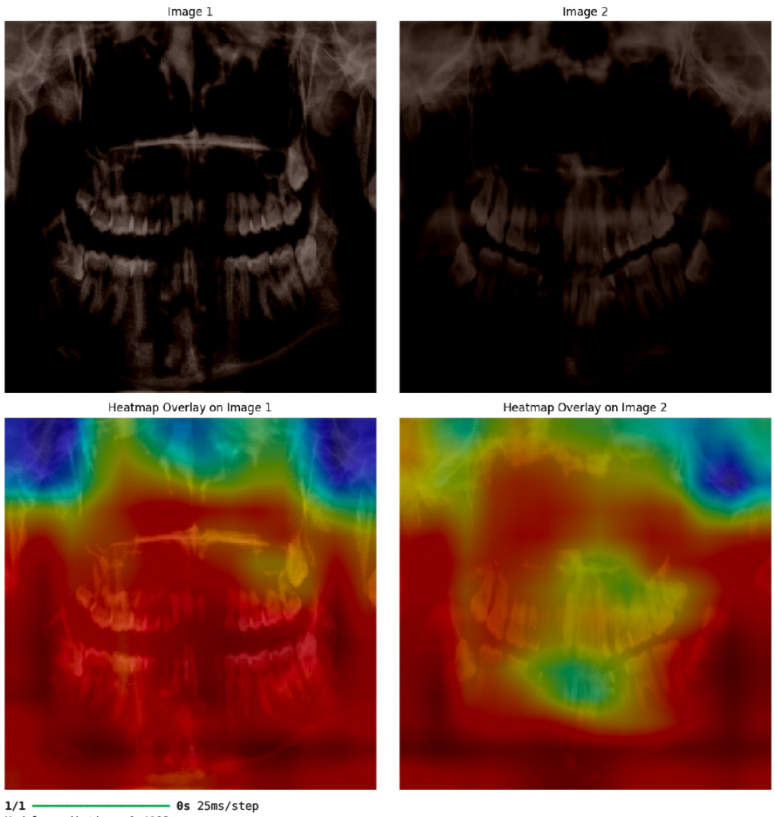

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 19ms/step
Model prediction: 0.0649
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 157
```



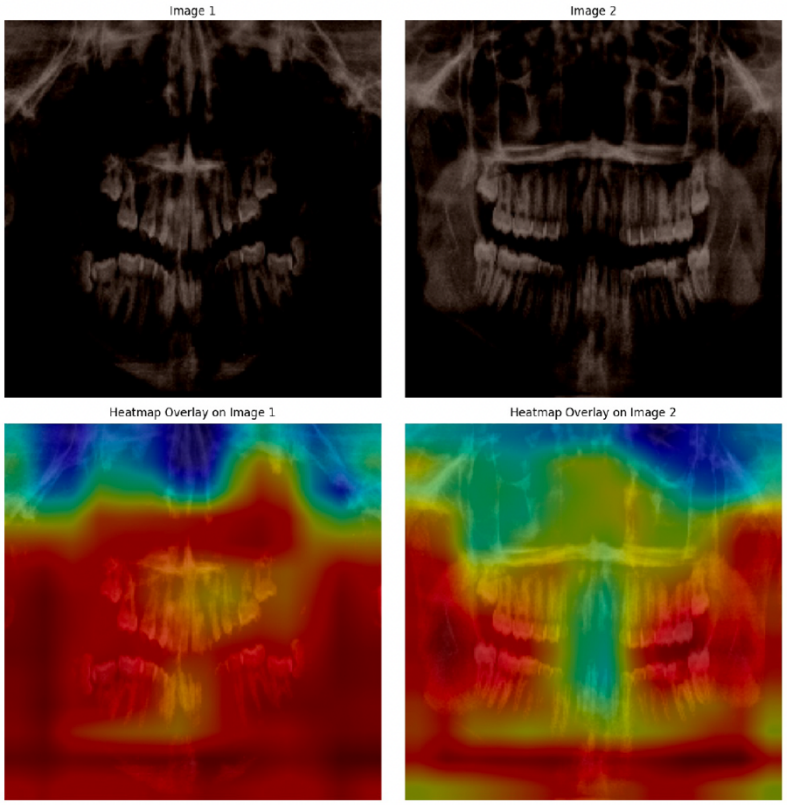

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.1436
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 158
```



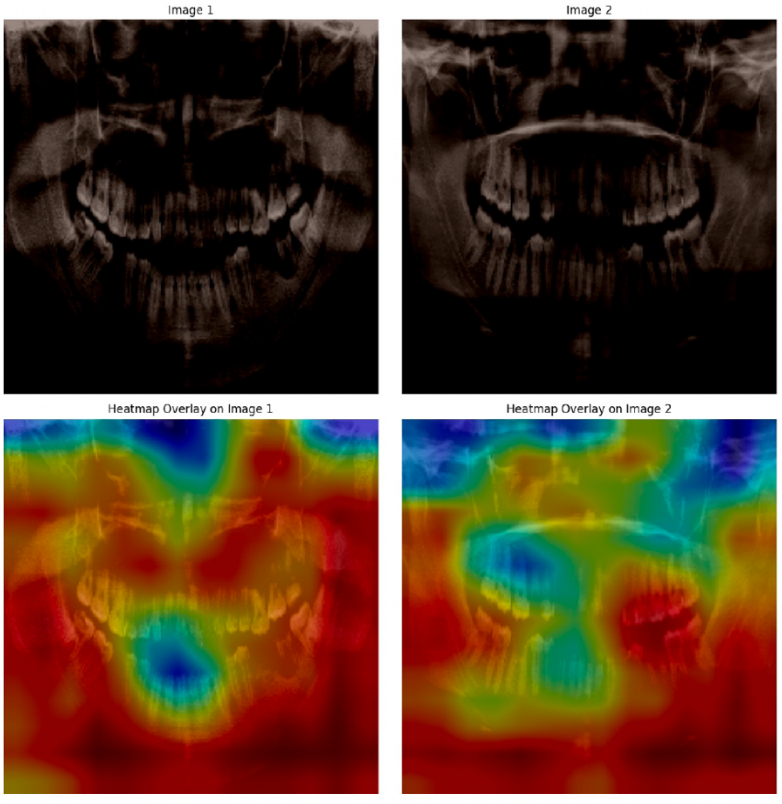

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 26ms/step
Model prediction: 0.2979
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 160
```



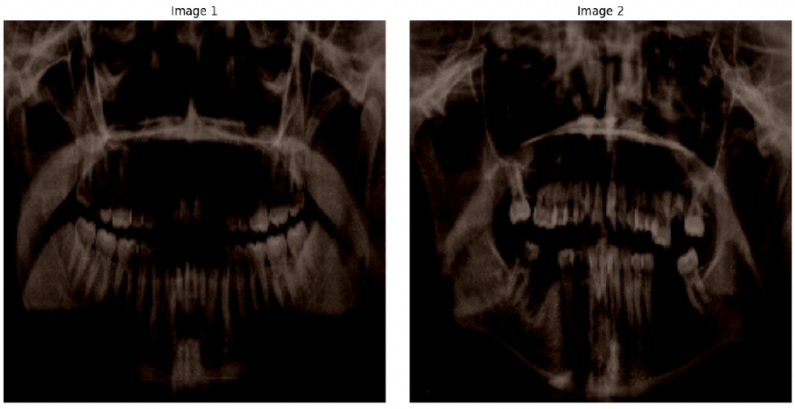

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 25ms/step
Model prediction: 0.4192
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 161
```

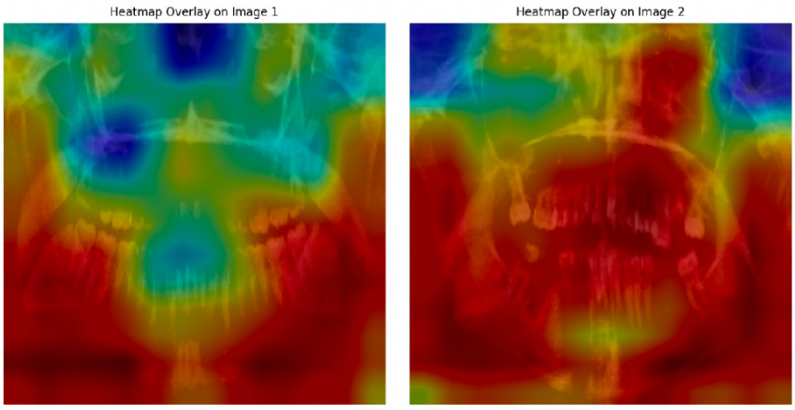



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 31ms/step
Model prediction: 0.0722
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 163
```



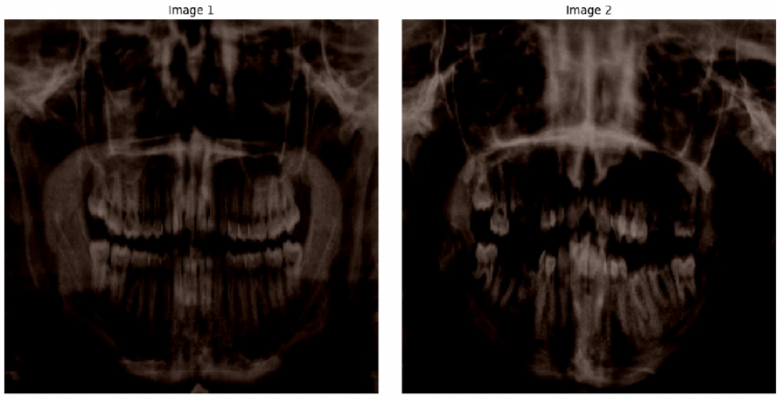

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 37ms/step
Model prediction: 0.0573
Actual label: Different people
Model classification: Different people
Correct classification: Yes
Pair 164
```



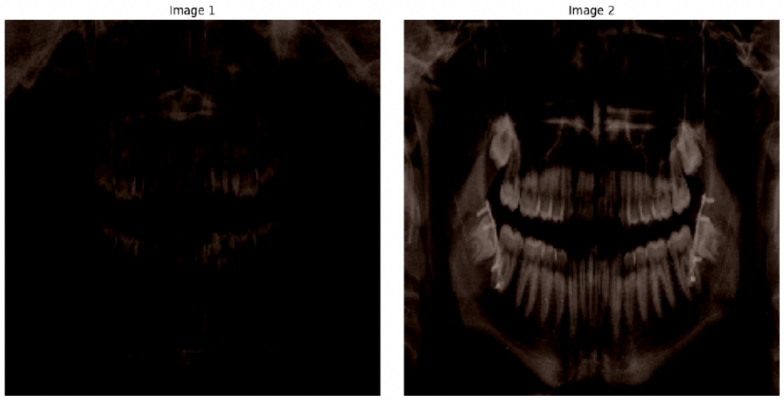



```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 32ms/step
Model prediction: 0.2691
Actual label: Different people
Model classification: Different people
Correct classification: Yes
```

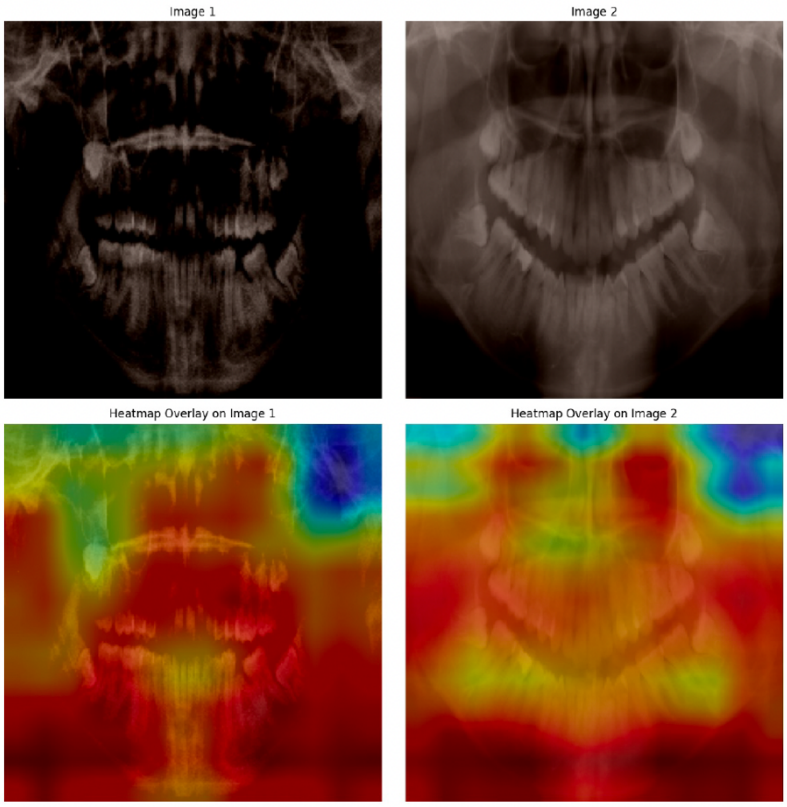
Anexo 5, IV – *Heatmaps* de OPG da classe "*Different*" classificadas como "*Same*"



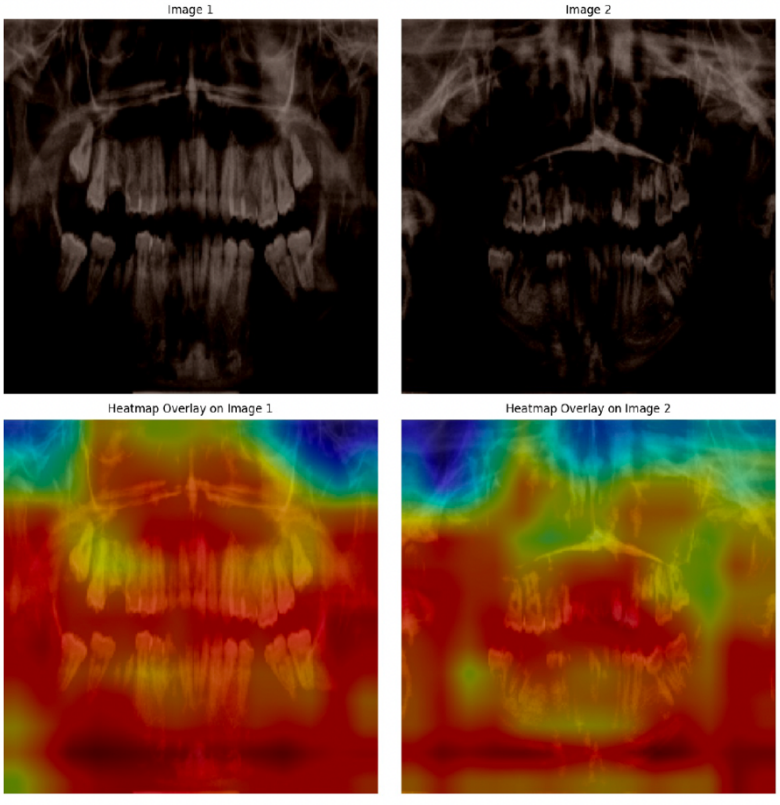

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 35ms/step
Model prediction: 0.5256
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 34
```



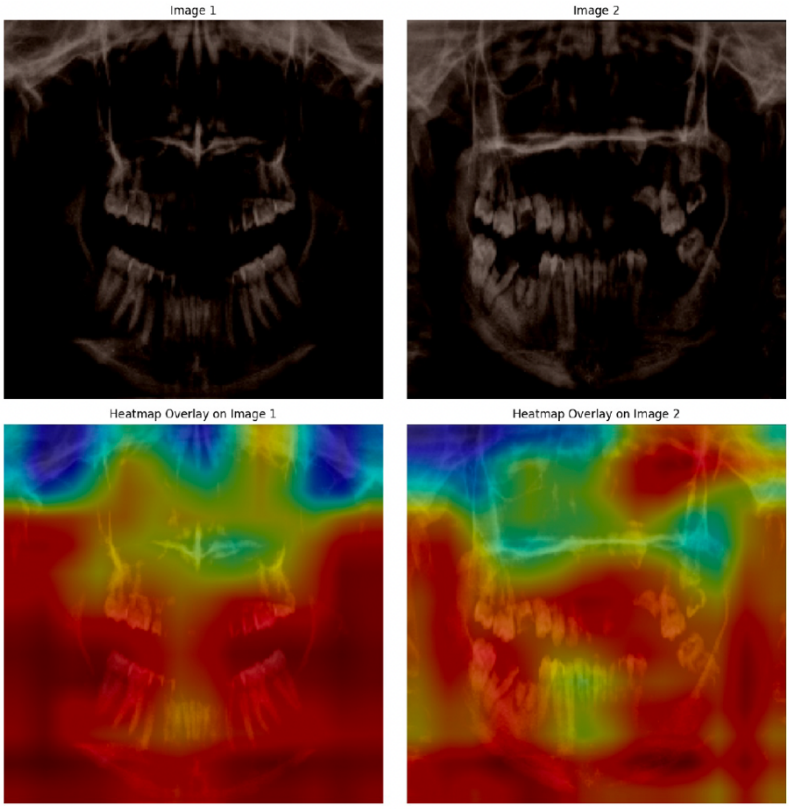

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 47ms/step
Model prediction: 0.7869
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 63
```



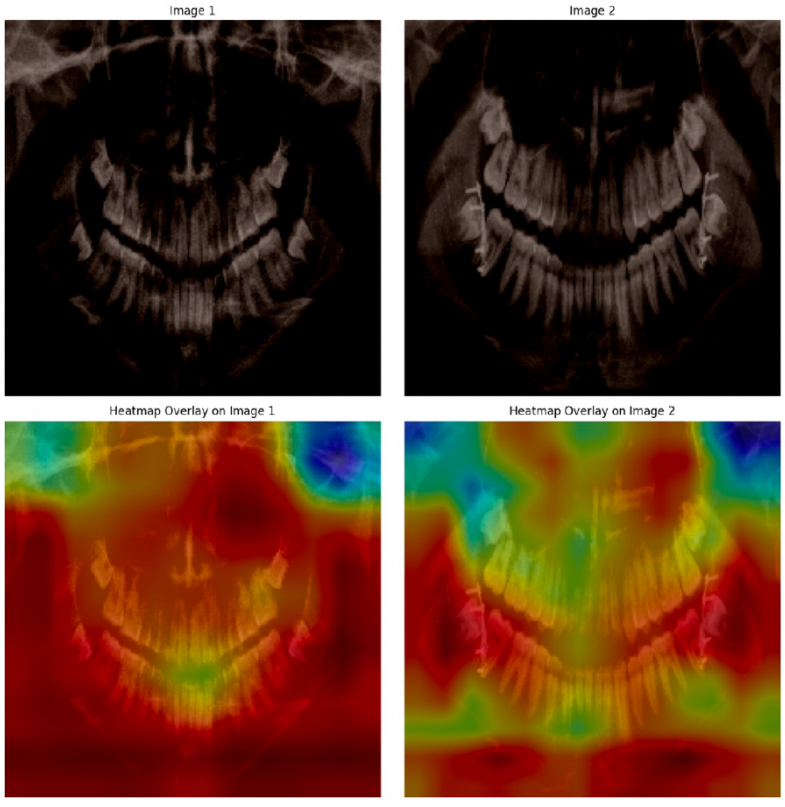

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 47ms/step
Model prediction: 0.8499
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 64
```



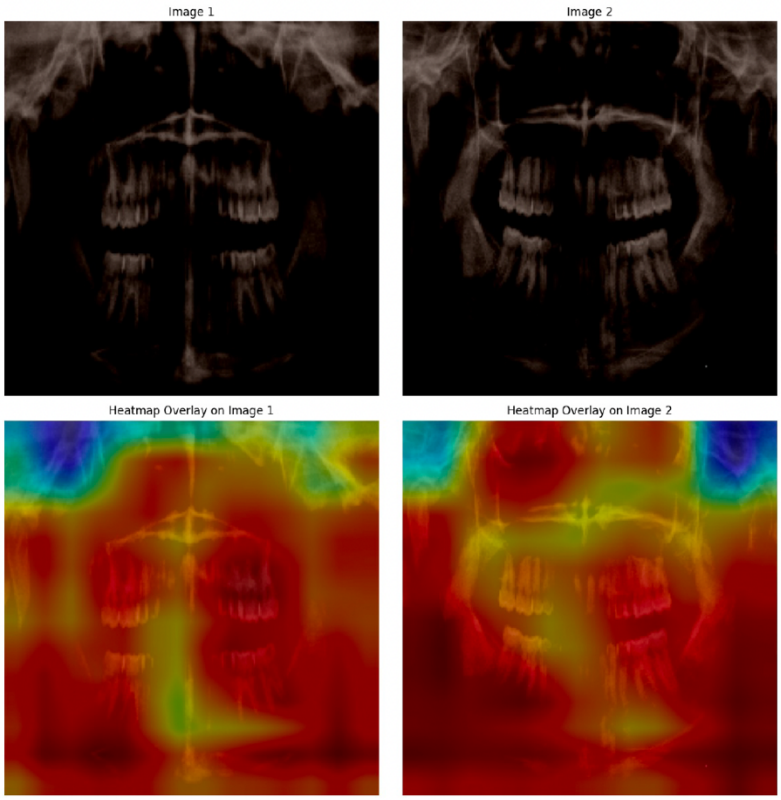

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 46ms/step
Model prediction: 0.6131
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 65
```



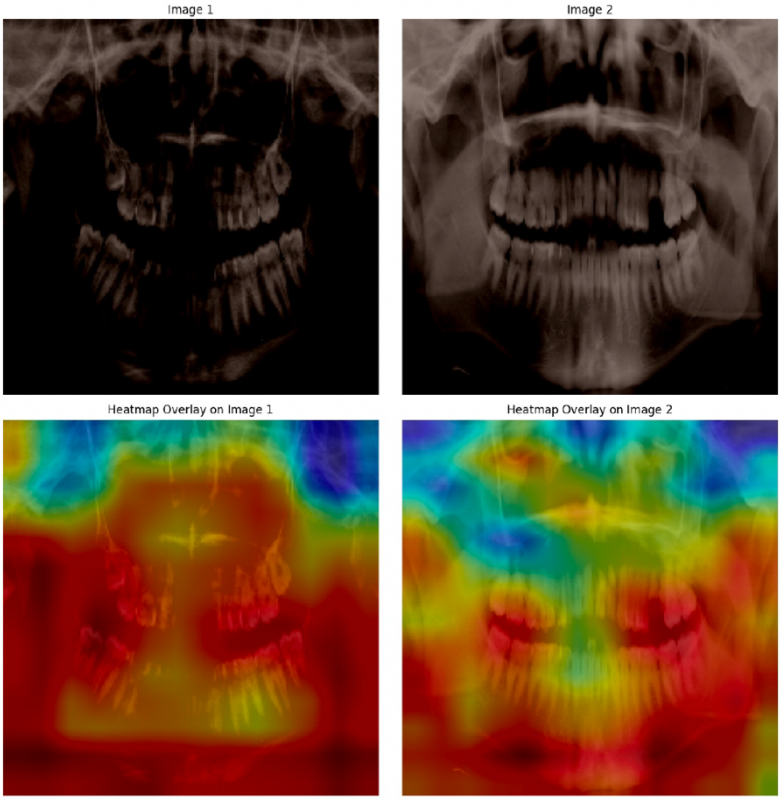

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 21ms/step
Model prediction: 0.7405
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 75
```



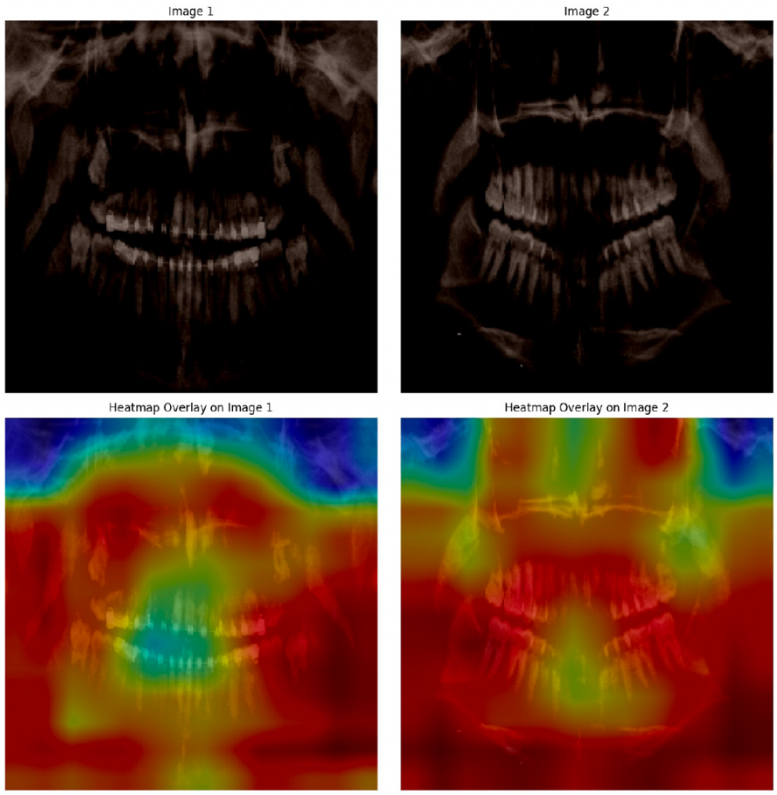

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 18ms/step
Model prediction: 0.6188
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 94
```



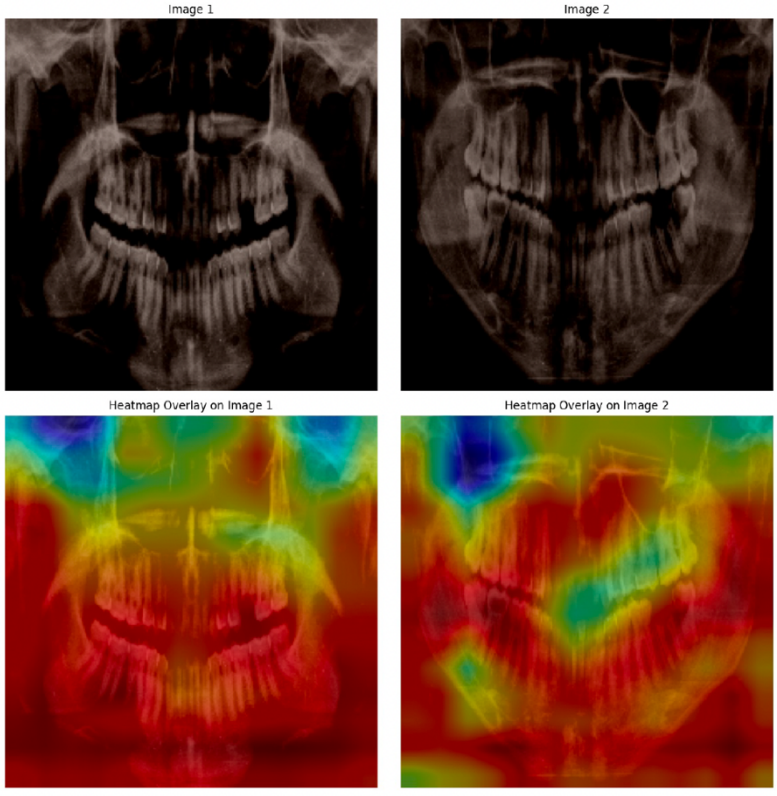

```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 40ms/step
Model prediction: 0.5269
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 97
```




```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 36ms/step
Model prediction: 0.5619
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 116
```




```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 30ms/step
Model prediction: 0.6643
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 136
```




```
1/1 ━━━━━━━━━━━━━━━━━━━━ 0s 36ms/step
Model prediction: 0.5374
Actual label: Different people
Model classification: Same person
Correct classification: No
Pair 145
```

Anexo 6 – Trabalhos Científicos desenvolvidos na FMDUL entre 2020 e 2024

I – Publicações Científicas

II – Apresentações Científicas

Anexo 6, I – Publicações Científicas

1. **"Analysis of Human skeletal remains in 1755 Lisbon earthquake commingled and disarticulated population: estimating stature from long limb bones except femur"**

Autores: Raquel Carvalho, Maria Vitória Lameiro, Mariana Correia, Patrícia Antunes, Tatiana Major, Valon Nushi, Rui Santos e Cristiana Palmela Pereira

Bulletin of the International Association for Paleodontology (Quartil 4)

[Publicado a 30 de junho de 2023]

Carvalho R, Lameiro MV, Correia M, Antunes P, Major T, Nushi V, Pereira CP. Analysis of human skeletal remains in 1755 Lisbon earthquake commingled and disarticulated population: estimating stature from long limb bones except femur. Bull Int Assoc Paleodontol. 2023;17(1):13-20.

2. **"Dental age assessment: scoring systems and models from the past until the present – how is it presented in the court?"**

Autores: Cristiana Palmela Pereira, Rui Santos, Valon Nushi, Maria Vitória Lameiro, Patrícia Antunes, Raquel Carvalho, Tatiana Major e Sakher J. AlQahtani

International Journal of Legal Medicine (Quartil 1)

[Publicado a 8 de maio de 2023]

Pereira CP, Santos R, Nushi V, Lameiro M, Antunes P, Carvalho R, Major T, Alqahtani S. Dental age assessment: scoring systems and models from the past until the present—how is it presented in the court? Int J Legal Med. 2023 May;137:1-8. doi: 10.1007/s00414-023-03011-3.

3. **"Odontometrics analysis from a commingled archaeological human population related to 1755 Lisbon's earthquake"**

Autores: Maria Vitória Lameiro, Mariana Correia, Patrícia Antunes, Raquel Carvalho, Tatiana Major, Rui Santos e Cristiana Palmela Pereira

Bulletin of the International Association for Paleodontology (Quartil 4)

[Publicado a 1 de dezembro de 2022]

Lameiro MV, Correia M, Antunes P, Carvalho R, Santos R, Palmela Pereira C. Odontometrics analysis from a commingled archaeological human population related to 1755 Lisbon's earthquake. Bull Int Assoc Paleodont [Internet]. 2022 Dec 23;16(2).

Anexo 6, II – Apresentações Científicas

1. Apresentação do projeto **"Modelos de Inteligência Artificial para Aplicação Médico--Legal em Identificação Humana"**

Autores: Mariana Correia e Raquel Carvalho

No âmbito dos Estágios de Verão do CEAUL (Centro de Estatística Aplicada da Universidade de Lisboa) – Sê Investigador 2024

[19 de julho de 2024, via Zoom]

2. Apresentação do póster científico **"Outpatient oral surgery. Which NSAIDs/Analgesics to prescribe? A systematic review and meta-analysis"**

Autores: Ana Rodrigues, Cristiana Palmela Pereira, Madalena M. Tropa, Diana Augusto, Francisco A. Coutinho, Francisco Salvado e Rui Santos

No âmbito do VI Congresso Internacional de Estatística em Decisão Médica

[4 de julho de 2024, via Zoom]

3. Apresentação do póster científico **"Retrospective analysis of a case series of patients with traumatic injuries to the temporomandibular joint in Hospital Santa Maria: A Medico-legal Framework for Impairment Assessment"**

Autores: Ana Rodrigues, Cristiana Palmela Pereira, Sofia Matos, Francisco Salvado, Francisco Coutinho e Rui Santos

No âmbito do VI Congresso Internacional de Estatística em Decisão Médica

[4 de julho de 2024, via Zoom]

4. Apresentação do projeto **"Coleção Osteológica da Academia das Ciências de Lisboa relacionada com o Terramoto de 1755"**

Autores: Patrícia Antunes e Raquel Carvalho

No âmbito dos Estágios de Verão do CEAUL (Centro de Estatística Aplicada da Universidade de Lisboa) – Sê Investigador 2024

[26 de julho de 2022, via Zoom]