EUROPEAN SOCIETY OF RADIOLOGY

eBook for Undergraduate **Education in Radiology**

CAPÍTULO: Inteligência Artificial em Radiologia

Título original
The eBook for Undergraduate Education in Radiology
Chapter: AI in Radiology

Tradução
Precise Editing Tradução e Edição de Textos Ltda

Revisão da tradução
Dr. Augusto Braga Fernandes Antunes
Mestrado com Distinção em Advanced Neuroimaging pelo University College London (UCL); Diretor Médico da Axial Inteligência Diagnóstica – Grupo Alliança; Coordenador Médico do Núcleo de Ensino, Pesquisa e Inovação Alliança (NEPIA); Diretor de Comunicação do CBR.

Dr. Bruno Aragão
Doutor em Radiologia pela FMUSP; MBA de Gestão em Medicina Diagnóstica pela FIA/CBR; Coordenador Médico de Inovação do Grupo Fleury; Coordenador da Comissão de Inovação e Telerradiologia (CITe) do CBR.

Coordenação Geral
Dr. Ronaldo Hueb Baroni
Professor da Faculdade Israelita de Ciências da Saúde Albert Einstein; Gerente Médico do Departamento de Imagem do Hospital Israelita Albert Einstein; Diretor de Relações Internacionais do CBR

Realização
Colégio Brasileiro de Radiologia e Diagnóstico por Imagem

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Prefácio

O ensino de graduação em radiologia na Europa é ministrado de acordo com esquemas nacionais e pode variar consideravelmente de uma instituição acadêmica para outra. Às vezes, o campo da radiologia é considerado uma "disciplina transversal" ou ensinado no contexto de outras disciplinas clínicas, por exemplo, medicina interna ou cirurgia.

Este e-book foi criado para auxiliar estudantes de medicina e professores acadêmicos em toda a Europa, respectivamente, na compreensão e no ensino da radiologia como uma disciplina coerente por si só. O seu conteúdo baseia-se no Currículo Europeu da ESR de Formação em Radiologia em Nível de Graduação e resume os chamados elementos essenciais que podem ser considerados os princípios básicos com os quais todo estudante de medicina deve estar familiarizado. Embora as habilidades específicas do diagnóstico radiológico para interpretação de imagens não possam ser adquiridas por todos os estudantes e pertençam mais aos objetivos de aprendizagem dos Currículos de Formação da ESR em Níveis de Pós-Graduação, o presente e-book também contém alguns insights adicionais relacionados aos exames de imagem modernos na forma de exemplos das principais patologias, conforme sua visualização nas diferentes modalidades de imagem. O objetivo é dar ao estudante de graduação interessado uma compreensão da radiologia moderna, refletindo seu caráter multidisciplinar como especialidade baseada em órgãos.

Gostaríamos de estender nossos agradecimentos especiais aos autores e aos membros do Comitê de Educação da ESR que contribuíram para este e-book, a Carlo Catalano, Andrea Laghi e András Palkó, que iniciaram este projeto, e ao Escritório da ESR, em particular a Bettina Leimberger e Danijel Lepir, por todo o apoio na realização do mesmo.

Esperamos que este e-book possa cumprir seu propósito como uma ferramenta útil para o ensino acadêmico de radiologia na graduação.

Minerva Becker Vicky Goh

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Copyright e Termos de Uso

Este trabalho está licenciado sob Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License.

É permitido:

- **Compartilhar –** copiar e redistribuir o material em qualquer meio ou formato.

Nos seguintes termos:

- **Atribuição –** Você deve dar o devido crédito, fornecer um link para a licença e indicar se foram feitas alterações. Você pode fazê-lo de qualquer maneira razoável, mas não de forma que sugira que o licenciante endossa tais alterações ou seu uso.
- **Não Comercial –** Você não pode utilizar o material para fins comerciais.
- **Sem derivações –** Se você reescrever, transformar, ou recriar o material, você não poderá distribuir o material modificado

Como citar este trabalho:
European Society of Radiology, Tugba Akinci D' Antonoli, Marcio A. B. C. Rockenbach, Vera Cruz e Silva, Merel Huisman, Elmar Kotter, Emmanouil Koltsakis, Peter M. A. van Ooijen, Erik R. Ranschaert, Pinar Yilmaz (2023) eBook for Undergraduate Education in Radiology: Artificial Intelligence in Radiology. DOI 10.26044/esr-undergraduate-ebook-17

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Hyperlinks

Conhecimentos Essenciais

Conhecimentos Adicionais

Atenção

Compare

Perguntas

Referências

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

e-book—Educação em Radiologia na Graduação

Baseado no ESR Curriculum for Undergraduate Radiological Education

Capítulo: **Inteligência Artificial em Radiologia**

Autores

Editores

Merel Huisman
Elmar Kotter
Peter M. A. van Ooijen
Erik R. Ranschaert

Membros

Tugba Akinci D' Antonoli
Marcio Aloisio Bezzera Cavalcanti Rockenbach
Vera Cruz e Silva
Emmanouil Koltsakis
Pinar Yilmaz

Afiliações

European Society of Medical Imaging Informatics (EuSoMII) Education Committee

info@eusomii.org

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Conteúdo

- **Introdução**
  - Por que devemos aprender sobre IA?
  - Breve História da IA
  - Definições
- **Fundamentos da Inteligência Artificial**
  - Aprendizagem Supervisionada
  - Aprendizagem Não Supervisionada
  - Aprendizagem por Reforço
- **Tópicos Avançados em Inteligência Artificial**
  - Aprendizado profundo e suas aplicações em imagens médicas
  - Desenvolvimento, implantação e avaliação de algoritmos
  - Compartilhamento de dados
  - Possíveis benefícios, riscos e evidências disponíveis
- **Aspectos Futuros**
  - Futuro Brilhante da Radiologia com IA
  - Inteligência Artificial Geral
  - *Large Language Models* (Grandes Modelos de Linguagem)
- **Mensagens Finais**
- **Referências e Leituras Adicionais**
- **Teste Seu Conhecimento**

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Introdução | Por que devemos aprender sobre IA?

- A inteligência artificial (IA) é uma área em rápido crescimento, influenciando todos os aspectos de nossas vidas, incluindo a forma como praticamos a medicina. Os profissionais de saúde devem acompanhar o **ritmo do desenvolvimento digital** para avançar nessa área.
- Enquanto o volume e a complexidade dos exames de imagem disparam, há um aumento na escassez de mão de obra e na pressão sobre os radiologistas. Como resultado, a qualidade diminui e os atrasos nos relatórios estão aumentando. A IA pode **aumentar a velocidade e a qualidade** dos relatórios, ao mesmo tempo em que aumenta a satisfação profissional dos médicos.
- O uso de IA na área da saúde apresenta **riscos potenciais**, como grande número de erros ou custos adicionais desnecessários. Portanto, devemos aprender mais sobre esta tecnologia para podermos implementar ferramentas de IA com segurança e eficácia na medicina.
- Na seção a seguir, aprenderemos mais sobre as aplicações da IA em radiologia, mas primeiro, vamos analisar um breve histórico e conceitos fundamentais sobre IA.

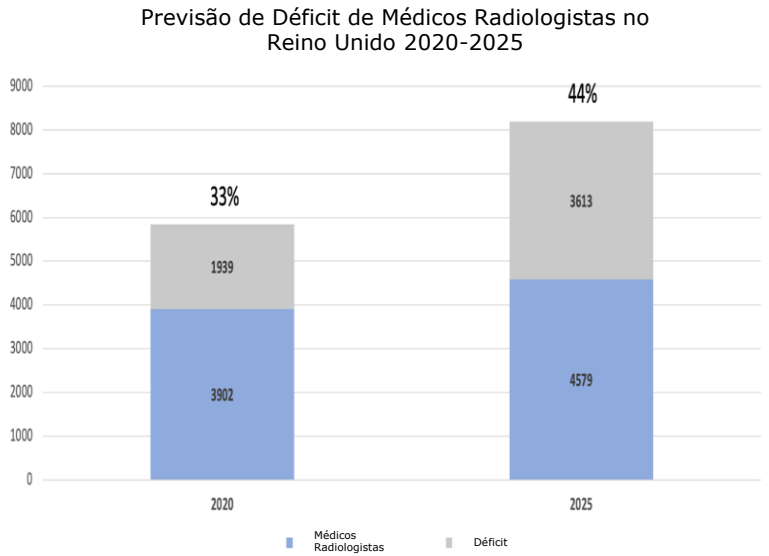

Adaptado de Clinical radiology UK workforce census 2020
report
https://www.rcr.ac.uk/publication/clinical-radiology-uk-workforce-census-2020-report

Conteúdo

- Introdução
  - Por que devemos aprender sobre IA
- Fundamentos de IA
- Tópicos Avançados sobre IA
- Aspectos Futuros
- Mensagens Finais
- Referências e Leituras Complementares
- Teste Seu Conhecimento

Introdução | Breve História da IA na Radiologia

- Ada Lovelace conceituou a primeira programação em 1842, marcando o nascimento da ciência da computação.
- Em 1895, William Conrad Roentgen descobriu o primeiro raio X, levando ao surgimento da radiologia como especialidade.
- Krizhevsky et al. venceram o desafio ImageNet em 2012 com o AlexNet, uma rede neural convolucional, e o campo do Deep Learning disparou.
- O primeiro algoritmo baseado em IA foi aprovado pela FDA em 2017 e oficialmente introduzido no ambiente clínico.

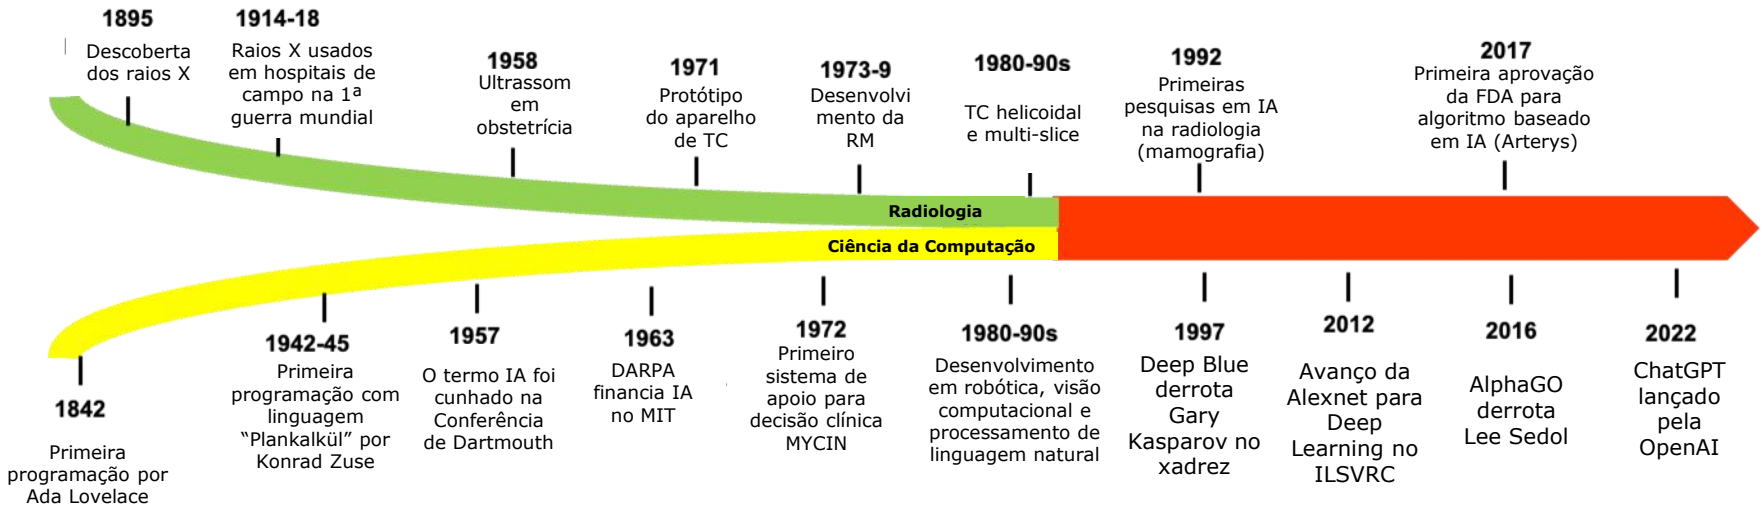

Adaptado de Clin Transl Sci (2020) 13, 216–218; doi:10.1111/cts.12704

Conteúdo

- Introdução
  - Breve história da IA em radiologia
- Fundamentos de IA
- Tópicos Avançados sobre IA
- Aspectos Futuros
- Mensagens Finais
- Referências e Leituras Complementares
- Teste Seu Conhecimento

Introdução | Definições

- **Inteligência Artificial (IA):** é um campo da ciência da computação focado na criação de soluções capazes de **executar tarefas tipicamente associadas à inteligência humana**. É um termo amplo que abrange uma ampla gama de tecnologias, e até mesmo um modelo básico baseado em regras pode ser considerado uma forma de IA.
- **Machine Learning (ML, Aprendizado de Máquina):** é uma sub-área da IA que gira em torno da criação de algoritmos capazes de aprender com dados e fazer predições. No entanto, esses algoritmos ainda dependem da **supervisão humana**. ML não é um conceito novo no campo da IA. Em visão computacional, os algoritmos tradicionais de ML frequentemente envolvem processamento de imagens e extração explícita de recursos.
- **Deep Learning (DL, Aprendizado Profundo):** é um subconjunto do ML que utiliza **redes neurais** para aprender padrões em dados. É considerado um campo relativamente novo dentro da IA e tem experimentado um aumento de popularidade nos últimos anos. Treinar um modelo de DL geralmente requer grandes quantidades de dados e recursos computacionais devido à complexidade das arquiteturas de redes neurais. Hoje em dia, isso é viável graças às placas gráficas especializadas em operações matriciais (Graphic Processing Units - GPU).

IA é um termo abrangente e pode ser aplicado a muitos domínios e de diversas formas.

Neste Capítulo focamos principalmente no *Deep Learning* **em reconhecimento de imagem**

Conteúdo

- Introdução
  - Definições
- Fundamentos de IA
- Tópicos Avançados sobre IA
- Aspectos Futuros
- Mensagens Finais
- Referências e Leituras Complementares
- Teste Seu Conhecimento

Introdução | Definições

Redes Neurais Artificiais (RNA): um tipo de algoritmo de aprendizado de máquina que imita a estrutura e a função do cérebro humano. Elas contêm múltiplos neurônios organizados em camadas hierárquicas. As camadas mais próximas da camada de entrada são responsáveis por processar e transformar os dados de entrada para extrair características relevantes, enquanto a camada de saída é responsável pela decisão final.

Rede neural profunda (RNP): um tipo específico de rede neural composta por múltiplas camadas intermediárias (camadas ocultas). Elas podem ser usadas para treinar modelos poderosos com base em grandes quantidades de dados.

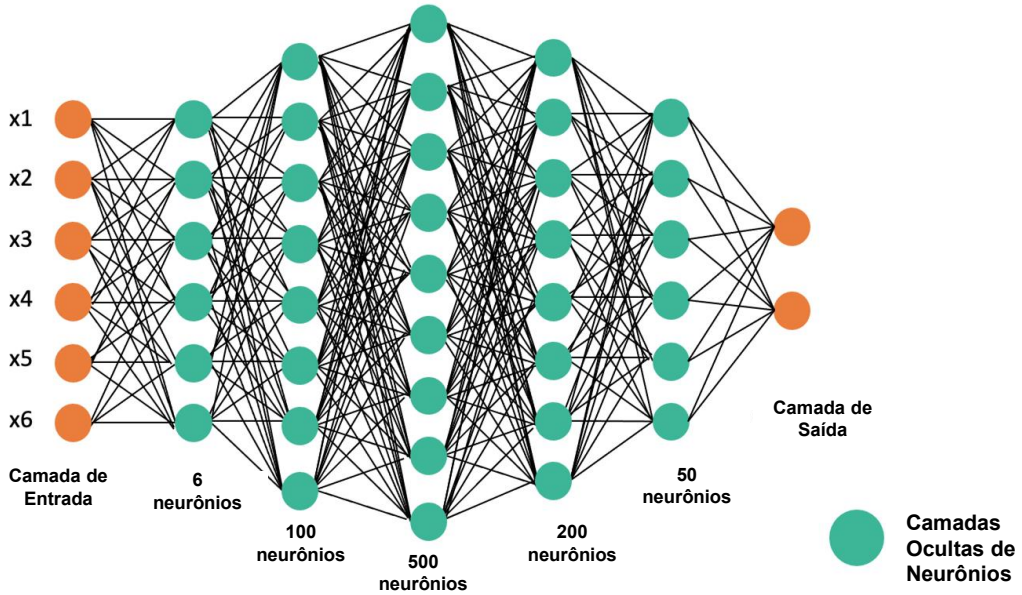

Adaptado de M. Bahi and M. Batouche, "Deep Learning for Ligand-Based Virtual Screening in Drug Discovery," doi: 10.1109/PAIS.2018.8598488

Conteúdo

- Introdução
  - Definições
- Fundamentos de IA
- Tópicos Avançados sobre IA
- Aspectos Futuros
- Mensagens Finais
- Referências e Leituras Complementares
- Teste Seu Conhecimento

Introdução | Definições

Radiômica: refere-se à **extração de características (*features*) quantificáveis e exploráveis** de imagens médicas. É um campo de pesquisa em rápido crescimento e aplicado principalmente na área de imagens oncológicas.

Atualmente, a radiômica ainda é fundamentalmente **uma área de pesquisa**, mas esforços estão sendo feitos para traduzir esses resultados para a prática clínica.

Dependendo do uso de **abordagens manuais ou de DL**, o fluxo de trabalho da radiômica pode incluir curadoria de dados clínicos e de imagem, pré-processamento de imagens, segmentação de imagens, extração de *features*, desenvolvimento e validação de modelos.

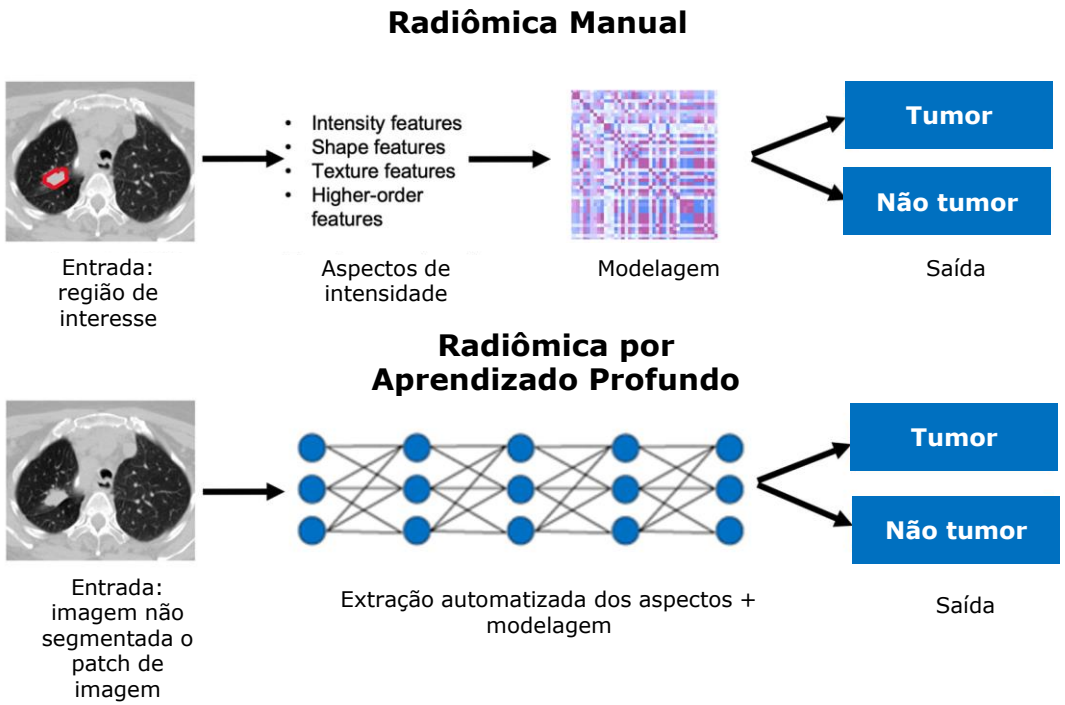

Courtesy of Tugba Akinci D'Antonoli

Conteúdo

- Introdução
  - Definições
- Fundamentos de IA
- Tópicos Avançados sobre IA
- Aspectos Futuros
- Mensagens Finais
- Referências e Leituras Complementares
- Teste Seu Conhecimento

Introdução | Aprendizado Supervisionado

Aprendizado supervisionado é um paradigma de ML que utiliza dados de treinamento **rotulados por humanos**. Em seguida, o modelo prediz (isso é chamado de "classificação") resultados em um novo conjunto de dados não rotulados. É a **técnica mais comumente utilizada**.

Os rótulos podem ser, por exemplo, uma **região de interesse (ROI)** que aponta para um tumor maligno de mama (veja a imagem abaixo), uma **caixa delimitadora** que indica uma lesão focal ou um **rótulo baseado em texto**, como "fratura".

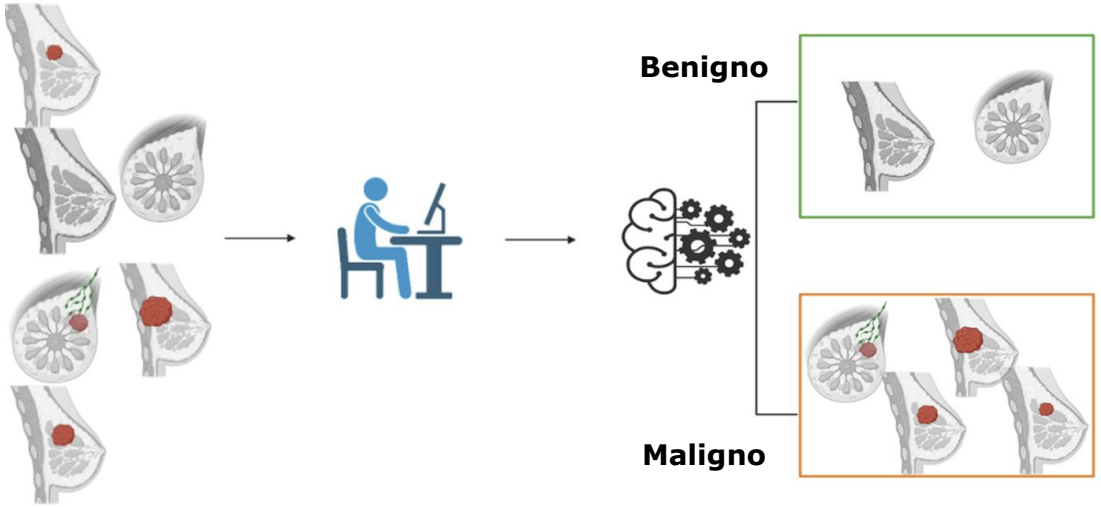

Created with BioRender.com

Métodos supervisionados comuns:

- **Regressão** => estima relações entre variáveis;
- **Algoritmos de Árvore de Decisão, por exemplo, *Random Forest)*** => são usados para tarefas de classificação e regressão; eles têm uma estrutura de árvore hierárquica com um nó raiz, ramos, nós internos e nós folha;
- ***Support Vector Machine* (SVM)** => são usados para tarefas de classificação e regressão; eles são especialmente úteis para classificar dados em dois grupos.

Conteúdo

Introdução

Fundamentos de IA
- Aprendizado Supervisionado

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Introdução | Aprendizado Não Supervisionado

- O **Aprendizado Não Supervisionado** ignora a rotulagem manual de dados por meio de técnicas de agrupamento, como *k-means*.
- O modelo é alimentado normalmente com uma grande quantidade de **dados não rotulados** e, em seguida, encontra padrões com base na estrutura dos dados.
- O aprendizado não supervisionado é normalmente usado para **grandes conjuntos de dados não estruturados,** por exemplo, na descoberta de novos biomarcadores.
- Em imagens médicas, um exemplo comum é a Rede Adversarial Generativa (GAN), usada para criar imagens sintéticas (=falsas).

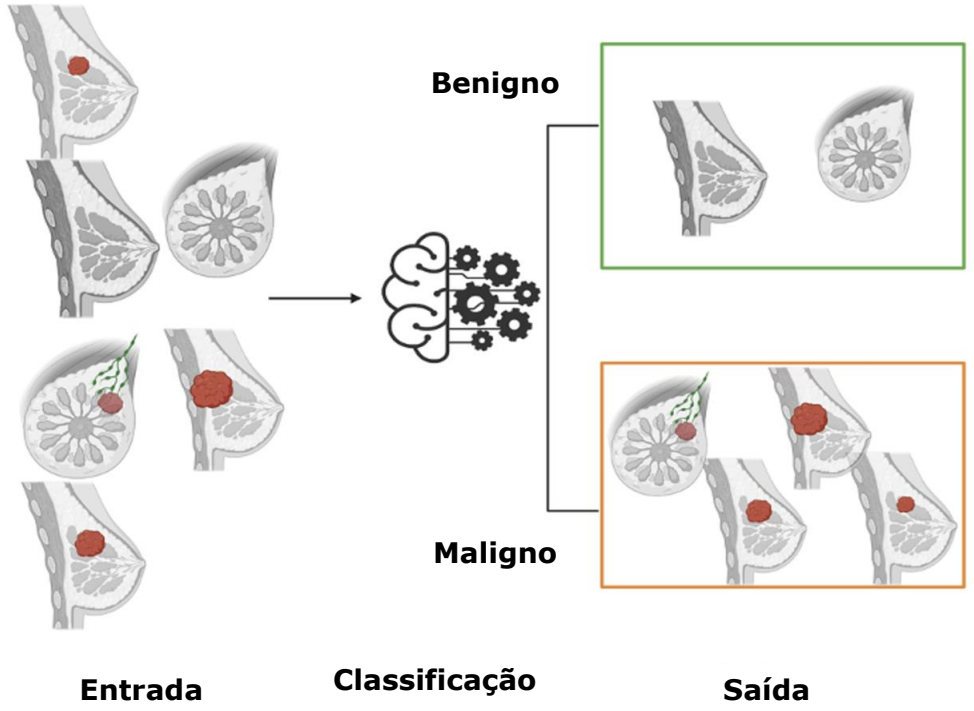

Criado com BioRender.com

Conteúdo

Introdução

Fundamentos de IA
- Aprendizado Não Supervisionado

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Introdução | Aprendizado Por Reforço

Aprendizado por reforço é uma abordagem de aprendizagem baseada em **recompensas e punições**. Um agente interage com o ambiente, percebendo seu estado e aprendendo a realizar ações que maximizem as recompensas no longo prazo.

Por meio dessa abordagem, o agente deve manter um equilíbrio entre recompensa e punição, através de um mecanismo de tentativa e erro, que favorece ações que gerem o maior benefício.

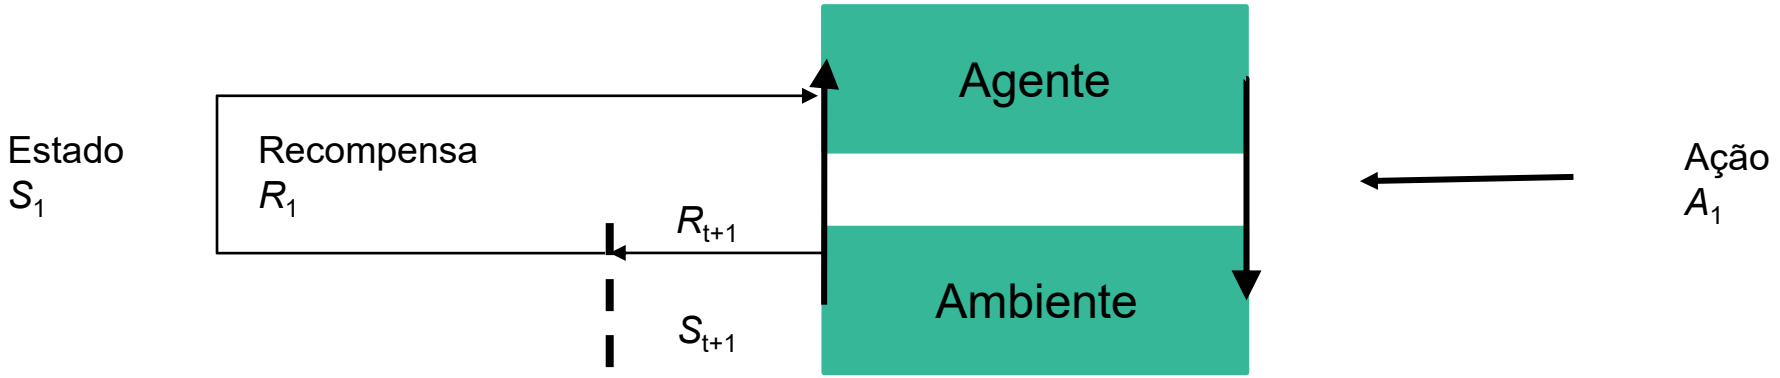

Adaptado de imagem por Shweta Bhatt.
https://towardsdatascience.com/reinforcement-learning-101-e24b50e1d292

Conteúdo

Introdução

Fundamentos de IA
- Aprendizado Por Reforço

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Aplicações de Deep Learning em Imagens Médicas

Imagens médicas têm sido uma das principais áreas de interesse no desenvolvimento de modelos de deep learning para aplicações clínicas. Muitos exemplos podem ser encontrados em algoritmos desenvolvidos para diferentes modalidades de imagem (RM, TC, raios-X, ultrassom). Nos próximos slides, você encontrará os tipos de tarefas em que o DL foi utilizado, juntamente com alguns exemplos de modelos:

Classificação: treine um modelo capaz de categorizar imagens.

Exemplos:

- Classificação binária: Radiografia de tórax normal vs. anormal sem especificação de uma patologia;
- Positiva para uma doença específica vs. negativa (por exemplo, classificação de ressonâncias magnéticas cerebrais como positiva ou negativa para Doença de Alzheimer);
- Classificação de planos anatômicos (multiclasse): axial vs. coronal vs. sagital;

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Aplicações de Deep Learning em Imagens Médicas

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Aplicações de Deep Learning em Imagens Médicas

Detecção: o objetivo desses algoritmos é identificar "objetos" anatômicos ou patológicos em uma imagem.

Frequentemente, o objeto detectado pode ser destacado com o **uso de caixas delimitadoras (veja a imagem).**

Exemplos incluem:

- Detecção de pontos de referência para planejamento de cirurgia da coluna em radiografias
- Detecção de nódulos pulmonares em TCs
- Detecção de cálculos renais em TCs
- Detecção de lesões hepáticas em TCs

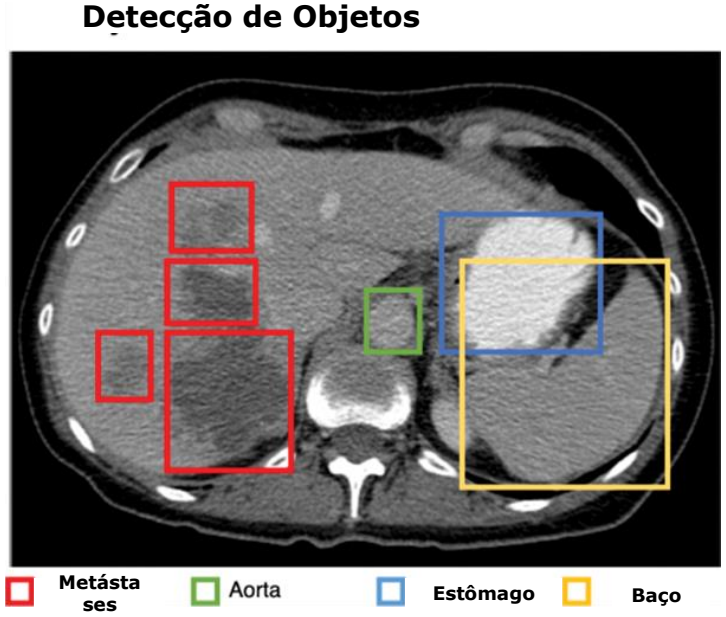

Cheng PM. Published Online: September 01, 2021
https://doi.org/10.1148/rg.2021200210
Shared under a CC BY 4.0 license

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Aplicações de Deep Learning em Imagens Médicas

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Aplicações de Deep Learning em Imagens Médicas

Segmentação: tarefa de dividir os pixels de uma imagem em **múltiplas regiões** ou segmentos, onde cada segmento corresponde a um objeto ou classe específica (por exemplo, um **órgão ou patologia**).

Em geral, esta é a primeira etapa, em tarefas de classificação ou quantificação (por exemplo, medição).

Este tipo de aplicação é um dos usos populares de DL em imagens médicas.

Examplos:

- Segmentação de próstata em RM
- Segmentação de fígado em TC
- Segmentação de tumor cerebral em RM
- Segmentação cardíaca em TC
- Segmentação de tumor pulmonar em angio-TC
- Segmentação de acidente vascular cerebral em TC/RM

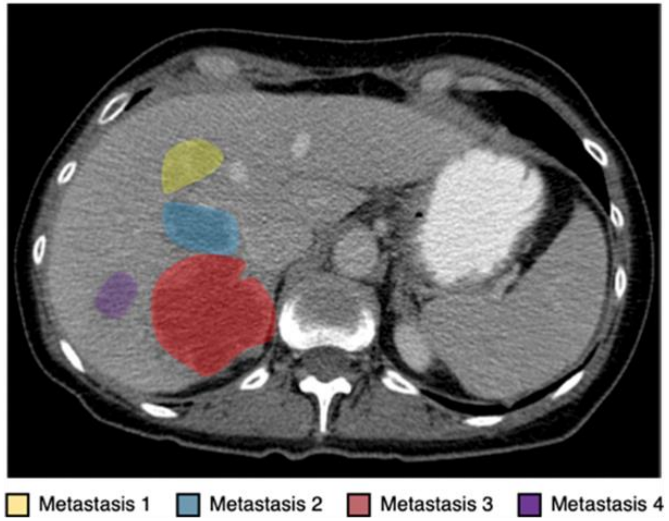

Segmentação de metastáses hepáticas em estudo de TC

Cheng PM. Published Online: September 01, 2021
https://doi.org/10.1148/rg.2021200210
Shared under a CC BY 4.0 license

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Aplicações de Deep Learning em Imagens Médicas

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Aplicações de Deep Learning em Imagens Médicas

Aprimoramento de imagem: modelos de DL podem ser treinados para executar tarefas que melhoram a **qualidade da imagem** ou que mantenham a qualidade da imagem com uma dose de radiação menor. As aplicações incluem:

- **Redução de ruído:** algoritmos de DL podem aprender a distinguir o ruído do sinal subjacente. O ruído pode então ser removido, preservando as características mais importantes da imagem.
- **Super-resolução:** modelos de DL podem aprender a aumentar a resolução espacial (ou seja, criar imagens de alta resolução a partir de imagens de baixa resolução)
- **Remoção de artefatos:** remoção de artefatos que afetam a qualidade da imagem (como artefatos de movimento, endurecimento do feixe).
- **Varreduras com realce de contraste virtual:** modelos de DL podem ser treinados para simular imagens com realce de contraste com base em um estudo sem contraste.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Aplicações de Deep Learning em Imagens Médicas

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Aplicações de Deep Learning em Imagens Médicas

Casos de uso não interpretativos:

Aplicações que não apresentam objetivo primário no diagnóstico ou prognóstico, mas que facilitam o fluxo de trabalho radiológico digital, desde o agendamento de pacientes até a comunicação dos resultados (veja o próximo slide para exemplos). Essas aplicações são relativamente novas e, em sua maioria, **ainda em desenvolvimento**, mas apresentam grande potencial.

Alguns exemplos comuns:

- **Suporte ao agendamento:** pode auxiliar na otimização do fluxo de trabalho, automatizando o processo de agendamento de exames e garantindo que a carga de trabalho seja adequada para o departamento.
- **Automação de protocolos de radiologia:** com base nas informações clínicas disponíveis, a IA pode ajudar a identificar o protocolo ideal de aquisição de imagens, por exemplo, se uma TC abdominal deve ser adquirida com ou sem contraste intravenoso.
- **Priorização da lista de trabalho:** alguns modelos de aprendizado de máquina são construídos para identificar exames urgentes que exigem interpretação imediata por um radiologista. Dessa forma, podemos garantir que os exames de alta prioridade sejam revisados primeiro.
- **Protocolos de exibição:** algumas ferramentas de IA podem ajudar a determinar o *layout* pelo qual as imagens radiológicas são exibidas na tela do computador, de acordo com o cenário clínico/protocolo de estudo específico.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Aplicações de Deep Learning em Imagens Médicas

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Aplicações de Deep Learning em Imagens Médicas

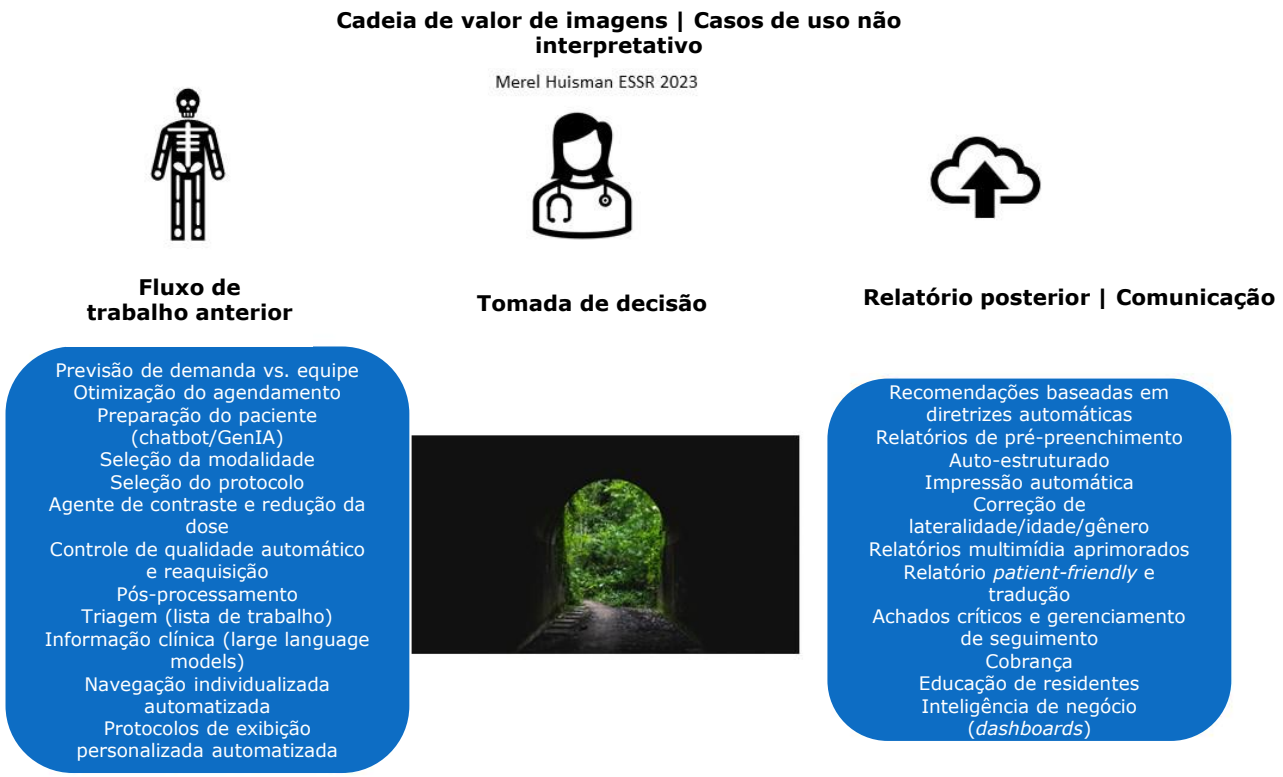

Fabricantes e médicos têm dado muito enfoque nos casos de uso interpretativos, embora haja uma variedade de outros casos de uso além do suporte à tomada de decisões (ou seja, além do diagnóstico).

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Aplicações de Deep Learning em Imagens Médicas

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Desenvolvimento, Implantação e Avaliação de Algoritmos

Definição de Caso de Uso

- Definir o objetivo do algoritmo (ou seja, a **condição clínica a ser abordada pela aplicação**)
- Definir os critérios de inclusão e exclusão associados à condição clínica
- Identificar os **elementos de dados** necessários para o desenvolvimento do modelo

Preparação do Conjunto de Dados

- Coletar **dados representativos** da condição clínica
- Rotular/anotar os dados coletados (esta é a **verdade fundamental** que será usada para treinar e testar o modelo)
- **Dividir** o conjunto de dados em conjuntos de treinamento, validação e teste

Treinamento do Modelo

- Avaliar que tipo de **pré-processamento** de dados será necessário
- Escolher a abordagem de arquitetura de modelo correta para a tarefa definida nas etapas anteriores
- Usar os conjuntos de **treinamento e validação** para avaliar o desempenho de modelos treinados com diferentes abordagens

Validação Interna

- **Selecionar** o modelo com o melhor desempenho no conjunto de validação
- Avaliar o **desempenho do modelo** no conjunto de **teste independente** (ou seja, de validação)
- Este desempenho será uma **aproximação da generalização** do modelo (ou seja, quão bem o modelo se comportaria em outro conjunto de dados)

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

- Desenvolvimento, Implantação e Avaliação de Algoritmos

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Desenvolvimento, Implantação e Avaliação de Algoritmos

Validação Externa

- Avaliar o **desempenho do modelo** em dados externos (por exemplo, dados de outras instituições de saúde).
- Avaliar a **generalização e a reprodutibilidade do modelo** (ou seja, a utilidade em diferentes contextos/populações).
- Ajudar a identificar **vieses** do modelo (por exemplo, baixo desempenho de subgrupos).

Implantação Clínica

- Os modelos são implementados no **fluxo de trabalho clínico**, geralmente após um **piloto**.
- A **integração perfeita** não é trivial, mas crítica.
- É necessária autorização regulatória (por exemplo, **marca CE**).
- **Fatores de usabilidade** além do desempenho do modelo devem ser considerados (por exemplo, como e quando, velocidade, interação homem-máquina).

Vigilância Pós-Comercialização

- A saída do modelo deve ser **monitorada continuamente** para detectar quedas de desempenho em caso de alterações nos parâmetros clínicos (chamado de *dataset drift*).
- **Eventos adversos** relacionados ao uso do modelo devem ser relatados
- O **feedback do usuário** deve ser coletado.
- **Atualizações do modelo** podem ser implementadas para resolver quaisquer problemas que possam ser identificados.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

- Desenvolvimento, Implantação e Avaliação de Algoritmos

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Desenvolvimento, Implantação e Avaliação de Algoritmos

O desempenho algorítmico é constantemente avaliado durante todo o treinamento do modelo e, em seguida, o desempenho final é avaliado no conjunto de teste e, posteriormente, em dados externos durante a validação externa

O desempenho deve sempre ser avaliado usando múltiplas métricas para obter uma compreensão abrangente de seus pontos fortes e fracos. A escolha depende do tipo de problema, da prevalência da doença e do contexto clínico.

Métricas de desempenho comuns em ML:

- ***Dice similarity coefficient*:** uma medida de sobreposição baseada em pixels entre áreas previstas e reais em tarefas de segmentação, variando de 0 (sem sobreposição) a 1 (sobreposição perfeita)
- **Erro quadrático médio (EQM) / Erro absoluto médio (EAM)**: avalia a qualidade de um modelo de regressão
- **Precisão (= valor preditivo positivo)*:** proporção de verdadeiros positivos em relação a todas as previsões positivas, depende da prevalência
- **Recall (= sensibilidade)***: proporção de verdadeiros positivos em relação a todas as amostras positivas reais, independentemente da prevalência
- **Acurácia*:** proporção de previsões corretas em relação a todas as previsões (% corretas), intuitiva, mas pode superestimar o desempenho
- **Escore F1*:** métrica para predizer com confiança e não deixar de detectar doenças em um cenário de baixa prevalência, preferível à precisão em doenças raras
- **Área sob a curva ROC (AUC-ROC):** uma forma gráfica resumida de apresentar a capacidade de discriminação do modelo, plotada como a taxa de verdadeiros positivos em relação à taxa de falsos positivos em múltiplos limiares de classificação

*Derivado da matriz de confusão (veja o próximo slide)

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Desenvolvimento, Implantação e Avaliação de Algoritmos

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Desenvolvimento, Implantação e Avaliação de Algoritmos

A matriz de confusão é fundamental para a avaliação do desempenho do modelo em tarefas de classificação (por exemplo, lesão benigna vs. maligna). Ela fornece um resumo abrangente das previsões do modelo em comparação com os rótulos da classe real (padrão ouro):

		Predição	
		Positivo	*Negativo*
Classe Real (Verdade Básica)	*Positivo*	Verdadeiro Positivo (VP) Acerto	Falso Negativo (FN) Erro tipo II (perda)
	Negativo	Falso Positivo (FP) Erro tipo I (alarme falso)	Verdadeiro Negativo (VN) Rejeição Correta

Com base na matriz de confusão, diversas métricas de desempenho podem ser derivadas, incluindo:

- Sensibilidade: VP / (VP + FN). Mede a capacidade do modelo de identificar corretamente os casos positivos (anormalidades) de todos os casos positivos reais.
- Especificidade: VN / (VN + FP). Mede a capacidade do modelo de identificar corretamente os casos negativos (casos normais) de todos os casos negativos reais.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Desenvolvimento, Implantação e Avaliação de Algoritmos

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Desenvolvimento, Implantação e Avaliação de Algoritmos

IA em ensaios clínicos:

- Ferramentas de IA utilizadas em ambientes centralizados de leitura de imagens para ensaios clínicos também requerem validação técnica e clínica adequada. A consistência do padrão-ouro e a representação populacional adequada (incluindo fenótipos de doenças, variabilidade dos scanners e protocolos de aquisição) são igualmente essenciais neste cenário para o treinamento e teste dos algoritmos.
- A IA pode auxiliar/facilitar algumas tarefas relacionadas a ensaios e/ou análise de imagens, como: seleção de pacientes de acordo com critérios de inclusão, avaliação da qualidade da imagem a partir de exames enviados e avaliação de biomarcadores quantitativos de imagem, trazendo também uma redução significativa no tempo de anotação/leitura de imagens e na variabilidade entre leitores.

Para maiores informações: https://www.eusomii.org/w60-validation-of-automated-image-analysis-tools-in-the-absence-of-a-ground-truth-by-marco-during/

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Desenvolvimento, Implantação e Avaliação de Algoritmos

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Compartilhamento de Dados

O desenvolvimento e o aprimoramento da IA baseiam-se amplamente na experiência de aprendizado do algoritmo. Uma vez que os algoritmos aprendem com os dados, um acesso mais abrangente aos mesmos é crucial para maior precisão e implementação e, em última análise, para um melhor serviço prestado à saúde.

GDPR - *General Data Protection Regulation*

Em 25 de maio de 2018, a GDPR entrou em vigor. Ele se aplica a todos os **estados-membros da União Europeia** e diz respeito ao processamento de **dados pessoais**, incluindo (embora não especificamente concebido para) dados relativos à saúde

A GDPR é uma **lei vinculativa** e substitui as leis preexistentes..

Dados pessoais: qualquer informação relativa a uma pessoa física identificada ou identificável

Processamento: qualquer operação ou conjunto de operações realizadas com dados pessoais

Dados relativos à saúde: qualquer informação relativa a uma pessoa física identificada ou identificável

Pessoa física identificada ou identificável é um conceito-chave em matéria de proteção de dados

Dê uma olhada: https://gdpr-info.eu/

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Compartilhamento de Dados

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Compartilhamento de Dados

Um cenário específico em que a GDPR é de extrema importância é o desenvolvimento e a comercialização de Dispositivos Médicos (DM), especificamente aqueles que implementam software de IA, onde o acesso a conjuntos de dados apropriados determina seu desempenho e conformidade com o **uso pretendido.**

O Medical Device Regulations (MDR, Regulamento de Dispositivos Médicos) da UE substituiu a Diretiva de Dispositivos Médicos (MDD) da UE em 26 de maio de 2021. Ele impõe requisitos regulatórios rigorosos que precisam ser atendidos antes que os dispositivos médicos possam ser usados na prática clínica. **O MDR da UE exige a conformidade com a GDPR.**

O **MDR** se aplica a instrumentos, aparelhos, dispositivos, softwares, implantes, reagentes, materiais ou outros artigos para qualquer um dos seguintes fins:

- diagnóstico, prevenção, monitoramento, tratamento ou alívio de uma doença;
- investigação, substituição ou modificação de um processo anatômico, fisiológico ou patológico;
- fornecimento de dados por meio de exame in vitro de amostras derivadas de um corpo humano.

O **uso pretendido** compreende:

(1) a finalidade médica real;

(2) o uso autorizado, entendido como a definição dos usuários a serem selecionados e do ambiente de uso, da população-alvo de pacientes ou das partes do corpo.

Ferramentas de software baseadas em IA são vistas como dispositivos médicos e são regulamentadas como tal

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

- Compartilhamento de Dados

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Compartilhamento de Dados

Técnicas para mitigar os riscos à proteção de dados de acordo com a GDPR

- **Pseudonimização** – significa o tratamento de dados sensíveis pessoais de tal forma que os dados pessoais não possam mais ser atribuídos a um sujeito específico sem o uso de informações adicionais para a obtenção de dados, desde que essas informações adicionais sejam mantidas separadamente. Dados pseudonimizados são considerados dados pessoais de acordo com a GDPR.

- **Anonimização – dados anônimos** são dados dos quais nenhuma conexão com uma pessoa identificável específica pode ser estabelecida e estão fora da aplicabilidade da GDPR.

No caso específico do setor da saúde, onde é crucial manter a rastreabilidade, a pseudonimização é um exemplo de uma salvaguarda adequada para a proteção de dados.

Para mais informações: https://www.eusomii.org/protection-of-patient-data-in-eu-vs-us-by-erik-ranschaert-md-phd-2/
https://www.linkedin.com/pulse/anonymisation-now-house-cards-magali-feys

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Compartilhamento de Dados

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Compartilhamento de Dados

Dados de saúde podem ser processados:

- Quando o paciente dá **consentimento explícito e inequívoco** para o uso de seus dados;
- Quando for do interesse **vital do paciente;**
- Para fins de **assistência à saúde;**
- Para **interesse público** na área da saúde pública
- Para **fins de arquivamento** de interesse público, **fins de pesquisa científica** ou **histórica** ou **fins estatísticos;**
- No campo do **direito trabalhista, previdenciário e de proteção social.**

European Society of Radiology (ESR). The new EU General Data Protection Regulation: what the radiologist should know. Insights Imaging. 2017 Jun;8(3):295-299. doi: 10.1007/s13244-017-0552-7. Epub 2017 Apr 24. PMID: 28439718; PMCID: PMC5438318.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA
- Compartilhamento de Dados

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Possíveis Benefícios, Riscos e Evidências Disponíveis

Aplicações de IA no ambiente clínico, especificamente no fluxo de trabalho da Radiologia, abrangem não apenas o reconhecimento de imagens e o suporte à tomada de decisões (centrado no radiologista), mas também procedimentos prévios e posteriores. Para um fluxo de trabalho eficiente, os algoritmos de IA devem ser totalmente integrados às estações de trabalho PACS (Picture Archiving and Communication System).

Alguns possíveis **benefícios** incluem a automação de tarefas demoradas, principalmente em:

- Otimização da lista de trabalho (por exemplo, facilitando a análise de exames de emergência) e agendamento
- Seleção de modalidade e protocolo
- Tempo de aquisição de imagens e redução da dose de radiação
- Processamento de imagens
- Detecção, medição e classificação de lesões
- Relatórios e comunicação para médicos e pacientes
- Faturamento

Artificial Intelligence in Medical Imaging: Opportunities, Applications and Risks | SpringerLink

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

- Possíveis Benefícios, Riscos e Evidências Disponíveis

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Possíveis Benefícios, Riscos e Evidências Disponíveis

Outras aplicações atuais disponíveis incluem processos automatizados relacionados a exames, como:

- Posicionamento do paciente no isocentro (TC e RM)
- Identificação da região de interesse (RM)
- Manutenção de equipamentos (TC)

Vale ressaltar que a economia simultânea de tempo e custos, aliada à redução da carga de trabalho radiológico e ao aumento da produtividade e eficiência, beneficiará principalmente o paciente, mas também o radiologista, os médicos solicitantes e o sistema de saúde em geral.

Em última análise, as soluções de IA também podem auxiliar na extensão da cobertura dos serviços de saúde em locais com escassez de profissionais.

Potočnik, J., Foley, S. & Thomas, E. Current and potential applications of artificial intelligence in medical imaging practice: A narrative review. J Medical Imaging Radiat Sci (2023) doi:10.1016/j.jmir.2023.03.033.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

- Possíveis Benefícios, Riscos e Evidências Disponíveis

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Tópicos Avançados | Possíveis Benefícios, Riscos e Evidências Disponíveis

Alguns **riscos** inerentes precisam ser considerados em aplicações de IA, tais como:

- **Viés não intencional** que pode causar disparidades na saúde (por exemplo, gênero, raça, status sócio-econômico);
- **Queda de desempenho** no ambiente clínico ou em certos subgrupos de pacientes;
- **Desempenho inconsistente** do algoritmo ao longo do tempo;
- **Complicação excessiva** da assistência médica e **aumento de custos** sem ganhos de eficiência nem de qualidade;
- Falta de reembolso (específico de cada país);
- **Falha na vigilância pós-comercialização** (obrigatória de acordo com o MDR);
- **Questões de responsabilidade** (em relação a erro médico) sobre o resultado final do paciente - quem é o responsável? O desenvolvedor da IA? A empresa que comercializa o algoritmo? Ou o radiologista?
- **Ataques cibernéticos e vazamento de dados**;
- **Viés de automação** (ou seja, humanos seguindo a IA cegamente, mesmo que ela esteja dando conselhos errados);
- **Impulsionamento técnico > atração clínica** (ou seja, desenvolver ferramentas porque é possível, não porque é necessário)

É essencial estar ciente dos **problemas clínicos reais** e da **adequação** das soluções baseadas em IA em um ambiente clínico específico; veja a IA como um meio, não como um objetivo final.

Artificial Intelligence in Medical Imaging: Opportunities, Applications and Risks | SpringerLink

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

- Possíveis Benefícios, Riscos e Evidências Disponíveis

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Aspectos Futuros

- Atualmente, os algoritmos de IA em radiologia têm um foco restrito, visando um recurso ou tarefa específica de imagem (**chamada de solução pontual**).
- No futuro, isso pode mudar com a inteligência artificial geral (IAG) e, eventualmente, a IA poderá executar muitas tarefas com capacidade no nível humano e supervisão humana limitada.
- Nesse caso, as tarefas diárias de um radiologista podem mudar drasticamente; teríamos mais tempo para o contato com pacientes, casos complexos e reuniões de equipes multidisciplinares.

IA restrita (solução pontual)	IA geral
Específica para aplicação/tarefa limitada	Executa tarefas gerais de inteligência (humana)
Modelos de domínio fixo fornecidos por programadores	Auto-aprendizado e raciocínio com seu ambiente operacional
Aprende a partir de milhares de exemplos rotulados	Aprende a partir de poucos exemplos e/ou com dados não estruturados
Reflexão nas tarefas mas sem compreensão	Gama completa de habilidades cognitivas humanas
O conhecimento não é transferido para tarefas de outros domínios	Alavanca a transferência de conhecimento para novos domínios e tarefas
A IA atual em radiologia	A IA do futuro em radiologia?

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Aspectos Futuros

Large language models (LLM, Modelos de Grandes Linguagens)

- LLMs são redes neurais profundas treinadas para gerar textos em nível humano.
- A família GPT (generative pretrained transformer) de LLMs está em ascensão e já está sendo utilizada em diversas áreas da medicina e radiologia.
- Até o momento, diversos artigos foram publicados utilizando GPT-3.5 e GPT-4, demonstrando que os LLMs podem auxiliar na tomada de decisões em mamografia, na escrita de artigos médicos ou na aprovação em exames de conselhos de radiologia.
- Pode haver mais novidades em breve, e os LLMs podem facilitar nosso caminho para a IAG.

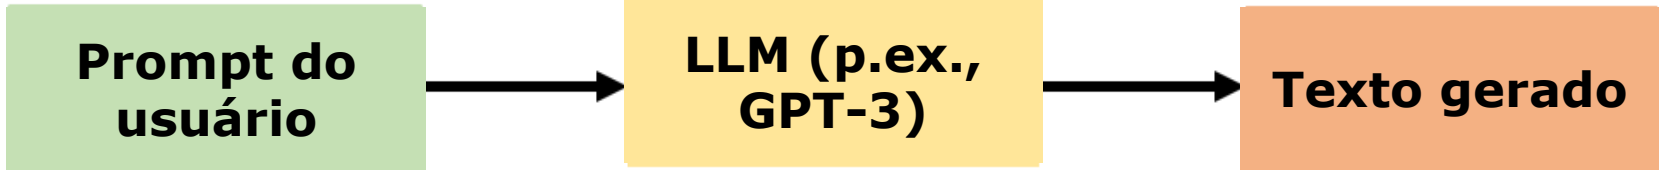

Conteúdo

Introdução
Fundamentos de IA
Tópicos Avançados sobre IA
Aspectos Futuros
Mensagens Finais
Referências e Leituras Complementares
Teste Seu Conhecimento

Mensagens Finais

- A IA é um esforço multidisciplinar em que cientistas da computação, médicos e especialistas clínicos colaboram em todas as etapas do processo para alcançar soluções clinicamente aplicáveis.
- Machine Learning (ML) utiliza algoritmos capazes de aprender com dados e fazer previsões, enquanto o Deep Learning (DL) é um subconjunto do ML e utiliza Redes Neurais Profundas para aprender padrões em dados.
- Há uma ampla gama de áreas onde o DL pode ser aplicado em radiologia, incluindo o uso ou não de imagens médicas.
- A conformidade com a GDPR é fundamental: a coleta de dados deve ser minimizada e usada de forma justa, com uma finalidade clara e legítima. Os dados não devem ser armazenados por mais tempo do que o necessário e devem ser protegidos com medidas de segurança cibernética adequadas.
- Os benefícios da implementação da IA incluem a redução do tempo de interpretação e processamento de imagens, a otimização de listas de trabalho e a redução da dose de radiação.
- Os riscos e limitações da IA incluem queda de desempenho, problemas de responsabilidade, ataques cibernéticos e vazamento de dados.
- Os radiologistas devem se familiarizar com esses fatores e aproveitar esse enorme potencial para o melhor atendimento possível ao paciente.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Referências

1. Hosny, A., Parmar, C., Quackenbush, J. et al. Artificial intelligence in radiology. Nat Rev Cancer 18, 500–510 (2018). https://doi.org/10.1038/s41568-018-0016-5
2. Gabriel Chartrand, Phillip M. Cheng, Eugene Vorontsov, Michal Drozdzal, Simon Turcotte, Christopher J. Pal, Samuel Kadoury, and An Tang. Deep Learning: A Primer for Radiologists. RadioGraphics 2017 37:7, 2113-2131.https://doi.org/10.1148/rg.2017170077
3. Phillip M. Cheng, Emmanuel Montagnon, Rikiya Yamashita, Ian Pan, Alexandre Cadrin-Chênevert, Francisco PerdigónRomero, Gabriel Chartrand, Samuel Kadoury, and An Tang. Deep Learning: An Update for Radiologists. RadioGraphics 2021 41:5, 1427-1445. https://doi.org/10.1148/rg.2021200210
4. Bradley J. Erickson, Panagiotis Korfiatis, Zeynettin Akkus, and Timothy L. Kline. Machine Learning for Medical Imaging.RadioGraphics 2017 37:2, 505-515. https://doi.org/10.1148/rg.2017160130
5. https://gdpr-info.eu/
6. European Society of Radiology (ESR). The new EU General Data Protection Regulation: what the radiologist should know. Insights Imaging. 2017 Jun;8(3):295-299. doi: 10.1007/s13244-017-0552-7. Epub 2017 Apr 24. PMID: 28439718; PMCID: PMC5438318
7. Regulation 2017/745 Recital 47, arts. 62(4)(h), 72(3), 92(4), 110(1)–(2) (EU)
8. The Future of Medical Device Regulation: Innovation and Protection (pp. 77-90). Cambridge: Cambridge University Press. doi:10.1017/9781108975452.007
9. Artificial Intelligence in Medical Imaging: Opportunities, Applications and Risks | SpringerLink
10. https://www.linkedin.com/pulse/anonymisation-now-house-cards-magali-feys
11. https://www.monash.edu/researchinfrastructure/mbi/research/imaging-analysis/motion-artefact-removal-in-mri
12. https://discourse.slicer.org/t/new-extension-fully-automatic-whole-body-ct-segmentation-in-2-minutes-using-totalsegmentator/26710
13. A. Krizhevsky, I. Sutskever, and G. Hinton. Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems 25, 2012.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Leituras Adicionais

1. Artificial Intelligence in Medical Imaging: Opportunities, Applications and Risks 1st ed. 2019 Edition by Erik R. Ranschaert (Editor), Sergey Morozov (Editor), Paul R. Algra (Editor), Springer

1. Pesapane, F., Codari, M. & Sardanelli, F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. Eur Radiol Exp 2, 35 (2018). https://doi.org/10.1186/s41747-018-0061-6

1. Mazurowski MA, Buda M, Saha A, Bashir MR. Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. J Magn Reson Imaging. 2019 Apr;49(4):939-954. doi: 10.1002/jmri.26534. Epub 2018 Dec 21. PMID: 30575178; PMCID: PMC6483404.

1. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. Nat Rev Cancer. 2018 Aug;18(8):500-510. doi: 10.1038/s41568-018-0016-5. PMID: 29777175; PMCID: PMC6268174.

1. Kelly BS, Judge C, Bollard SM, Clifford SM, Healy GM, Aziz A, Mathur P, Islam S, Yeom KW, Lawlor A, Killeen RP. Radiology artificial intelligence: a systematic review and evaluation of methods (RAISE). Eur Radiol. 2022 Nov;32(11):7998-8007. doi: 10.1007/s00330-022-08784-6. Epub 2022 Apr 14. Erratum in: Eur Radiol. 2022 May 20;: PMID: 35420305; PMCID: PMC9668941.

1. Kulkarni S, Seneviratne N, Baig MS, Khan AHA. Artificial Intelligence in Medicine: Where Are We Now? Acad Radiol. 2020 Jan;27(1):62-70. doi: 10.1016/j.acra.2019.10.001. Epub 2019 Oct 19. PMID: 31636002.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

1 – O que é VERDADE sobre Redes Neurais Profundas

- Seu sucesso se deve a hardwares melhores (placas gráficas) especializados em operações matriciais
- Necessitam de neurônios biológicos artificiais altamente interconectados para operar
- São a única forma de aprendizado de máquina
- Necessitam da extração e codificação manual de conhecimento

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

1 – O que é VERDADE sobre Redes Neurais Profundas

- ✓ Seu sucesso se deve a hardwares melhores (placas gráficas) especializados em operações matriciais
- Necessitam de neurônios biológicos artificiais altamente interconectados para operar
- São a única forma de aprendizado de máquina
- Necessitam da extração e codificação manual de conhecimento

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

2 – Os diferentes métodos de Machine Learning são:

- Aprendizado pré-codificado e pós-codificado
- Aprendizado ascendente e descendente
- Aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço
- Aprendizado por tentativa única e aprendizado por múltiplas tentativas

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

2 – Os diferentes métodos de Machine Learning são:

- Aprendizado pré-codificado e pós-codificado
- Aprendizado ascendente e descendente
- ✓ Aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço
- Aprendizado por tentativa única e aprendizado por múltiplas tentativas

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

3 – O que é VERDADE sobre o Compartilhamento de Dados:

- A anonimização permite o compartilhamento seguro de dados e o retraçamento os dados originais do paciente.
- Dados pseudo-anonimizados são considerados dados pessoais de acordo com a GDPR.
- Para fins de saúde, os dados do paciente podem ser processados sem consentimento.
- Softwares nem sempre se enquadram no MDR.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

3 – O que é VERDADE sobre o Compartilhamento de Dados:

- A anonimização permite o compartilhamento seguro de dados e o retraçamento os dados originais do paciente.
- ✓ Dados pseudo-anonimizados são considerados dados pessoais de acordo com a GDPR.
- Para fins de saúde, os dados do paciente podem ser processados sem consentimento.
- Softwares nem sempre se enquadram no MDR.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

4 – Em relação à Algorithm Evaluation, qual das seguintes é uma métrica adequada para avaliar uma tarefa de segmentação?

- Erro quadrático médio
- Precisão
- Escore F1
- Dice similarity coefficient

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

4 – Em relação à Avaliação de Algoritmos, qual das seguintes é uma métrica adequada para avaliar uma tarefa de segmentação?

- Erro quadrático médio
- Precisão
- Escore F1
- ✓ Coeficiente de similaridade de DICE

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

5 – Em relação às aplicações de Deep Learning em imagens médicas, dividir uma imagem em várias regiões, onde cada região corresponde a um objeto ou classe específica, é um exemplo de:

- Classificação
- Aprimoramento de imagem
- Detecção
- Segmentação

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Teste Seu Conhecimento

5 – Em relação às aplicações de Deep Learning em imagens médicas, dividir uma imagem em várias regiões, onde cada região corresponde a um objeto ou classe específica, é um exemplo de:

- Classificação
- Aprimoramento de imagem
- Detecção
- ✓ Segmentação

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento

Todo o material usado (incluindo propriedade intelectual e elementos de ilustração) é originário dos autores, os autores tinham o direito de usar o material pela lei aplicável ou obtiveram uma licença transferível do detentor dos direitos autorais.

Conteúdo

Introdução

Fundamentos de IA

Tópicos Avançados sobre IA

Aspectos Futuros

Mensagens Finais

Referências e Leituras Complementares

Teste Seu Conhecimento