



**FACULDADE DE TECNOLOGIA DE SÃO PAULO**

**CURSO SUPERIOR DE TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE  
SISTEMAS**

**LARISSA ALVES DE LIMA**

Visão Computacional no Monitoramento de Mal Súbito

SÃO PAULO

2024

**FACULDADE DE TECNOLOGIA DE SÃO PAULO**

**CURSO SUPERIOR DE TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE  
SISTEMAS**

**LARISSA ALVES DE LIMA**

Visão Computacional no Monitoramento de Mal Súbito

Trabalho submetido como exigência parcial  
para a obtenção do Grau de Tecnólogo em  
Análise e Desenvolvimento de Sistemas, sob  
a orientação do Prof. Me. Valter Yogui.

SÃO PAULO

2024

Larissa Alves de Lima

Título do trabalho: Visão Computacional no Monitoramento de Mal Súbito.

Trabalho submetido como exigência parcial para a obtenção do Grau de  
Tecnólogo em Análise e Desenvolvimento de Sistemas.

Parecer do Professor Orientador: \_\_\_\_\_

---

---

---

Conceito/Nota Final: \_\_\_\_\_

Orientador: Prof. Me. Valter  
Yogui

São Paulo, \_\_\_\_ de Junho de 2024

## **AGRADECIMENTOS**

Primeiramente gostaria de expressar meus sinceros agradecimentos ao Prof. Me. Valter Yogui por aceitar ser meu orientador pela paciência, dedicação e inspiração. Suas aulas e palestras despertaram a minha curiosidade e desejo de aprender e buscar sobre o tema dissertado nessa pesquisa.

Aos meus irmãos e amigos gostaria de deixar a minha gratidão por todo apoio moral e incentivo durante a minha jornada, eles foram extremamente importantes para que eu continuasse firme durante os estudos.

Aos meus colegas de classe nos momentos de troca e a todos professores do curso pela generosidade ao longo deste processo. Todos contribuíram compartilhando conhecimentos que, indiretamente, me auxiliou e expandiu os horizontes de possibilidades dentro da utilização da visão computacional.

E em especial, quero expressar a minha gratidão a minha mãe que esteve ao meu lado o tempo todo, quando se tornou difícil manter o foco e dedicação nos estudos e trabalho.

"Descobri que, depois de escalar uma grande colina, descobre-se que há muitas outras colinas para escalar."

Nelson Mandela

## RESUMO

A visão computacional tem sido uma crescente tecnologia que, com o avanço de outras áreas, têm evoluído em conjunto. Atualmente, com a implementações de IA generativa, Rede 5g e Deep Learning, é possível ampliar os horizontes da Visão Computacional e aplicá-la em diversos setores. Podemos notar sua utilização em larga escala em outros países, como por exemplo, na China onde é utilizada em segurança. Para viabilização desse recurso em países com um modelo político diferente, vamos voltar nossa atenção para a área de maior criticidade: Saúde e bem-estar, visto que esse é um tema que assume uma maior influência para um cidadão. A adoção de recursos que utilizem tecnologia torna o sistema de saúde mais eficiente, no caso da visão computacional nos possibilita a ação proativa, a fim de minimizar riscos que decorrem da demora na prestação de socorro a um indivíduo. O objetivo dessa pesquisa é avaliar a implementação da visão computacional e a sua viabilidade para monitoramento de situações emergenciais, que representam algum risco e assim, possibilitar a predição. Além disso, abordaremos os desafios envolvidos no tema retratado na literatura.

Palavras-chave: Visão Computacional, Saúde, Situações emergenciais, Tecnologia.

## **ABSTRACT**

Computer vision has been a growing technology that, with the advancement of other areas, has evolved together. Currently, with the implementations of generative AI, 5g Network and Deep Learning, it is possible to expand the horizons of Computer Vision and apply it in different sectors. We can see its large-scale use in other countries, for example, in China where it is used in security. To make this resource viable in countries with a different political model, we will turn our attention to the most critical area: Health and well-being, as this is a topic that has greater influence for a citizen. The adoption of resources that use technology makes the health system more efficient, in the case of computer vision, it allows us to take proactive action, in order to minimize risks that arise from delays in providing help to an individual. The objective of this research is to evaluate the implementation of computer vision and its viability for monitoring emergency situations, which represent some risk, and thus enable prediction. Furthermore, we will address the challenges involved in the theme portrayed in the literature.

**Keywords:** Computer Vision, Health, Emergency situations, Technology.

## LISTA DE FIGURAS

Figura 1 - Exemplo de aparelhos para aquisição de imagens.....	17
Figura 2 - Exemplo de pré-processamento de imagem (redução de ruído) .....	18
Figura 3 - Exemplo de um processo de segmentação de imagem.....	19
Figura 4 - Exemplo do Aprendizado Supervisionado para classificação de imagens	22
Figura 5 - Esquema de uma rede neural, onde temos o Input (entrada de dados), as camadas ocultas e o Output (saída de informações). .....	25
Figura 6 – Software SwimEye .....	27
Figura 7 – Exemplo do SMPL-X .....	29
Figura 8 – Exemplo de artefato de saída do OpenPose.....	30

## LISTA DE ABREVIATURAS E SIGLAS

AVC .....	Acidente Vascular Cerebral
CNNs.....	Redes Neurais Convolucionais
IA.....	Inteligência Artificial
ML .....	Machine Learning
RNNs .....	Redes Neurais Recorrentes
VC .....	Visão Computacional

## Sumário

1. Introdução.....	13
2. Visão computacional.....	14
2.1. Características .....	16
2.1.1. Aquisição de imagens.....	17
2.1.2. - Pré-processamento .....	17
2.1.3. Segmentação.....	18
2.1.4. Extração de característica .....	19
2.1.5. Classificação e interpretação.....	19
3. Machine Learning .....	21
3.1. Aprendizado Supervisionado .....	22
3.2. Aprendizado não-supervisionado.....	22
3.3. Aprendizado semi-supervisionado .....	23
3.4. Aprendizado por reforço.....	23
4. Aprendizado Profundo .....	24
5. Mal Súbito.....	26
6. Soluções existentes.....	27
7. Conclusão.....	31
Referencial .....	32

## 1. Introdução

Atualmente, estamos passando pela 4ª revolução industrial e é possível notar a ascensão de tecnologias que antes eram tidas como impossíveis. O campo da Inteligência Artificial (IA), em especial, tem estado no foco das grandes empresas do mundo, até mesmo organizações de menor porte tem participado dessa corrida pela modernização com o intuito de não ficar para trás.

Com a chegada de novas tecnologias, coisas que antes fazíamos de forma manual ou que se faz necessário pessoas para execução de tarefas, acabarão ficando para trás, e conseqüentemente, teremos que nos adaptar a uma nova realidade.

A Visão Computacional (VC), é um campo que avança em conjunto com outras soluções de IA e tem ganhado cada vez mais espaço. Muito utilizada para reconhecimento facial, carros autônomos e até na agricultura, tem um campo de aplicação amplo que podem incluir segurança e saúde. Os ganhos em visão computacional têm sido potencializados com o *machine learning (ML)* e *deep learning*, que buscam ensinar máquinas de maneira similar ao aprendizado humano.

Os recursos de IA que hoje são viáveis, nos permitem não somente sermos mais produtivos, mas também proporciona qualidade de vida. Através da visão computacional, é possível criar aplicações que ajudem pessoas com deficiência visual na identificação de objetos e identificação de linguagem de sinais.

A tecnologia possui grande potencial no que diz respeito a saúde e bem-estar, e nessa pesquisa o objetivo é explorar a possibilidade da utilização da visão de máquina para otimizar a identificação de eventos médicos emergenciais que são visualmente detectáveis, como o mal súbito.

O mal súbito pode estar associado a diversas causas, como o acidente vascular cerebral por exemplo e em muitos casos, quando não é realizado o atendimento com urgência pode ocasionar o óbito. O mal súbito causado pelo acidente vascular cerebral (AVC), possui uma série de sinais que podem ser percebidos de forma visual, partindo disso, exploraremos a possibilidade dessa percepção ser realizada por máquinas, através da Visão Computacional, *Machine Learning* e *Deep Learning*.

## 2. Visão computacional

A VC, é um campo da tecnologia que teve seus primórdios no final dos anos 50, no entanto, somente a partir dos anos 70 ela começou a ser explorada de maneira aprofundada. Embora ainda não seja amplamente conhecida pelo público em geral, sua presença em nossa vida cotidiana tem se tornado cada vez mais notável.

De acordo com Ballard e Brown (1982), a visão computacional se dedica à criação de descrições explícitas e significativas de objetos físicos a partir de imagens, tudo isso realizado por máquinas computacionais. Shirai (2021), ressalta que a visão computacional é estudada em conjunto com a inteligência artificial desde início:

O objetivo da visão computacional é permitir que um computador entenda seu ambiente a partir de informações visuais. O processamento de informação visual ocupa uma posição importante nas atividades inteligentes dos humanos. A visão computacional, portanto, tem sido de interesse como tema de pesquisa em inteligência artificial (IA) e tem sido estudada desde os estágios iniciais da pesquisa em IA. (SHIRAI, 2021, p.01).

Desde a contribuição de Alan Turing no campo dos computadores digitais, o objetivo tem sido equipar os computadores com a capacidade de processar informações de maneira semelhante aos humanos. Em outras palavras, há um esforço contínuo para replicar a capacidade cognitiva humana em máquinas.

Nos últimos anos, a área de inteligência artificial tem experimentado avanços notáveis. Hoje, existem sistemas capazes de ouvir, enxergar e até mesmo interagir com usuários. A visão computacional, em particular, é empregada atualmente para a descrição precisa e eficiente de imagens e até mesmo vídeos, em conjunto com o aprendizado de máquina, que por sua vez busca resolver problemas utilizando algoritmos estatísticos baseado em uma massa de dados como modelo. A aplicabilidade da VC é vasta, estendendo-se a diversas áreas. Em cenários onde a visão computacional tem ganho mais força, pode-se notar que ela vem modificando o meio no qual se insere, melhorando a produtividade, minimizando erros humanos e servindo como apoio, como por exemplo, o Seeing AI da Microsoft que é um aplicativo para IOS que através da câmera do dispositivo, informa ao usuário de forma audível, o que a câmera detecta.

Apesar da VC ser um campo da Tecnologia da Informação, é notável as contribuições de outras áreas em seu desenvolvimento, como por exemplo, da Neurobiologia: área comprometida na busca de compreensão dos sistemas

biológicos da visão. Ainda são conduzidos estudos para que se possa entender de forma plena a visão humana e como funciona a interpretação realizada pelo cérebro humano e algo que é curioso de se pensar, é que quando um humano está no início da vida, nem tudo que ele enxerga possui um significado em sua mente e muitas vezes, segundo Slater (2010), certas percepções estão condicionadas ao aprendizado. Kellman e Arterberry (2007), abordaram sobre a dificuldade encontrada nos estudos de percepção de objetos por adultos que geralmente possuem inferências baseadas no conhecimento prévio, por conta disso, tal estudo é direcionado para bebês, devido a mínima experiência que eles possuem. Levando em consideração a informações levantadas, o processo de aprendizagem exerce forte influência na atribuição de significado ao que é captado pelo sistema visual. A partir disso, é possível vislumbrar onde os maiores esforços devem ser empregados para maximizar os avanços na visão computacional: *machine learning*. Algoritmos sofisticados de aprendizado de máquina, podem auxiliar a ensinar máquinas enquanto elas estão ativas.

Apesar de tantos avanços, a visão computacional por si só não é capaz de descrever imagens com o mesmo nível de detalhe que uma pessoa, decorrente disso é que se aplica o uso de modelos probabilísticos ou machine learning que se baseiam em grandes conjuntos de exemplos para garantir maior assertividade na análise da imagem processada. A introdução do ML associado a Visão computacional se deu na década de 2000, com isso algumas técnicas foram dominadas como reconhecimento de cena, panorama e localização. O ML nos possibilitou utilizar de dados rotulados massivos para apoiar no desenvolvimento de soluções com visão de máquina sem a necessidade da supervisão humana.

A partir de 2010, o aprendizado de máquina ganhou ainda mais relevância para o desenvolvimento da visão computacional, e foi viabilizado pelo projeto ImageNet que é definido como: “um grande banco de dados visual projetado para uso em pesquisa de software de reconhecimento visual de objetos” (IMAGENET, 2024). Além do ImageNet tivemos a contribuição do Microsoft COCO e LVIS.

As redes neurais de arquitetura convolucional também tiveram forte contribuição no aprimoramento de soluções de visão computacional, e em seu livro “*Computer Vision: Algorithms and Applications*” Szeliski destaca: “elas são agora a única arquitetura considerada para tarefas de reconhecimento e segmentação semântica” (SZELISKI, 2022, p.21).

Apesar da versatilidade da aplicação da VC em diversas indústrias, podemos citar duas que mais geram impacto em todas as camadas da sociedade: assistência médica e segurança. Na área da saúde, sua aplicação se dá na análise de imagens médicas que por muitas vezes pode ser mais precisa do que a análise humana na detecção de anomalias, como tumores por exemplo e no auxílio em procedimentos cirúrgicos. Já em segurança, é empregado no reconhecimento facial e detecção de anomalias em espaços públicos.

Segundo pesquisa realizada pelo Gartner, o mercado de visão computacional é promissor e é estimado uma movimentação de US\$ 386 bilhões até 2031:

Os principais mercados empresariais de visão computacional ultrapassarão US\$ 386 bilhões até 2031, com os mercados de manufatura, automotivo e varejo oferecendo as oportunidades de crescimento de receita mais rápidas. Os líderes de produtos devem inovar, integrar e atualizar os sistemas de visão para permanecerem competitivos. (GARTNER, 2024).

## 2.1. Características

Os processos inerentes a Visão Computacional são classificados em três níveis diferentes: baixo-nível, onde as operações realizadas buscam a redução de ruído da imagem e melhora do contraste; nível médio, onde o foco é a segmentação da imagem e classificação e, por fim, o alto nível que está relacionada com a inferência da imagem e “replicação” da cognição humana. Embora a visão computacional e o processamento de imagens conceitualmente não sejam a mesma coisa, eles são utilizados em conjunto para viabilizar as soluções. Utilizamos o processamento de imagens para tratar as imagens com o objetivo de que o sistema de visão computacional possa compreendê-la melhor. Szeliski ressalta sobre o cuidado necessário no processamento de imagens para obtenção de um resultado aceitável em alguns sistemas:

Embora alguns possam considerar que o processamento de imagem esteja fora do alcance da visão computacional, na maioria dos aplicativos de visão computacional, como a fotografia computacional e até mesmo o reconhecimento, exigem cuidados na concepção das etapas de processamento de imagem para alcançar resultados aceitáveis. (SZELISKI, 2022, p.109).

As etapas envolvidas em soluções que utilizam visão computacional são: aquisição de imagens, pré-processamento, segmentação, extração de características e por fim a classificação e interpretação.

### 2.1.1. Aquisição de imagens

A aquisição de imagens é o primeiro passo no processamento de imagens realizado na visão computacional. Esta etapa é realizada utilizando dispositivos que são equipados com câmeras ou sensores capazes de capturar imagens, como por exemplo: equipamentos de ultrassonografia, raio-x, ressonância magnética e os mais comuns como câmeras e celulares. As imagens obtidas, que serão processadas em etapas posteriores, podem tanto ser fotos quanto vídeos. Cada imagem oferece um conjunto único de informações que podem ser exploradas durante o processamento e análise.

Figura 1 - Exemplo de aparelhos para aquisição de imagens



Fonte: Compilação da autora <sup>1</sup>

### 2.1.2. - Pré-processamento

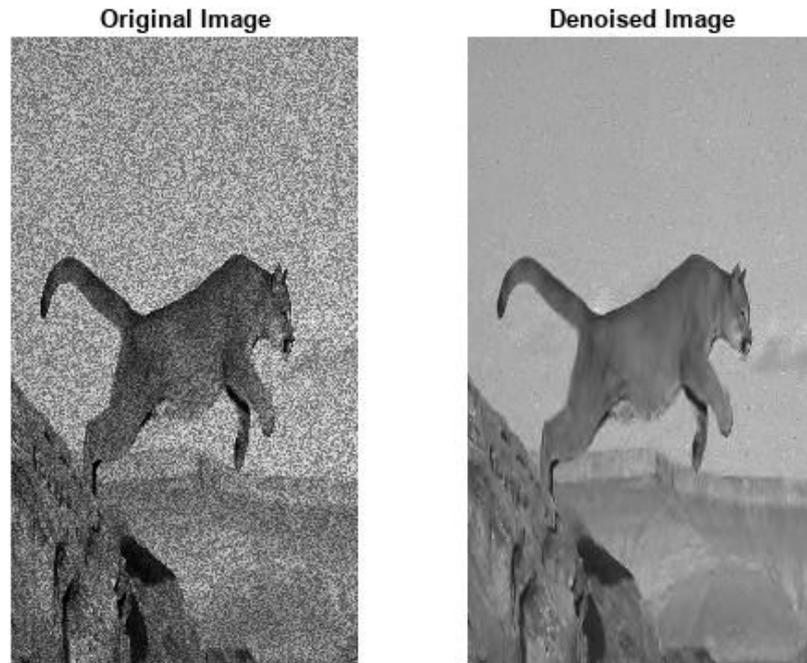
Esta é uma das etapas de baixo nível no processamento de imagens. Após a aquisição da imagem, o sistema realiza uma série de operações de processamento no intuito de garantir que seja gerado um artefato com a qualidade requerida para a segmentação. Durante esta fase, são realizadas várias operações, incluindo a redução de ruídos, que visa minimizar as distorções indesejadas na imagem, e o ajuste de contraste, que melhora a clareza da imagem ao maximizar a diferença de cor e brilho entre os objetos e o fundo. Além disso, outros aspectos relacionados à

---

<sup>1</sup> Montagem a partir de imagens retiradas dos sites Reviews Guide, Hcor, EcoCentro e CNN Brasil via google imagens.

qualidade da imagem, como nitidez, equilíbrio de cores e correção de gama, também são abordados nesta etapa.

Figura 2 - Exemplo de pré-processamento de imagem (redução de ruído)



Fonte: MathWorks (2024)

### 2.1.3. Segmentação

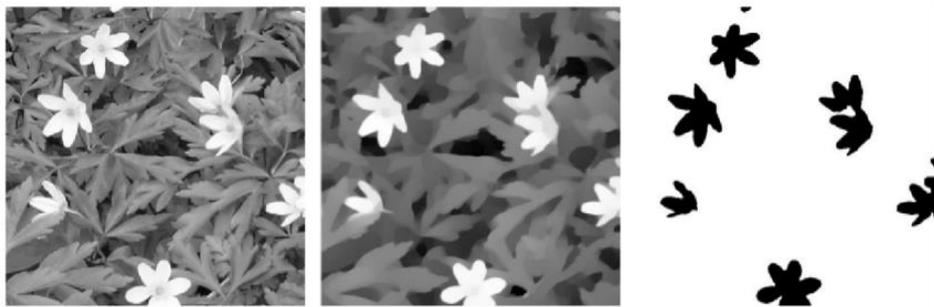
A segmentação de imagens é um processo que envolve a divisão da imagem em grupos de pixels, com o objetivo de simplificar e/ou alterar a representação de uma imagem em algo mais significativo e fácil de analisar. Existem várias técnicas de segmentação de imagens, cada uma com suas próprias especialidades e aplicações. Entre as técnicas baseadas em formas, temos a detecção de descontinuidades, que identifica pontos de mudança abrupta na imagem; a detecção de pontos, que localiza pontos de interesse na imagem; a detecção de linhas, que identifica linhas proeminentes; e a detecção de bordas, que destaca os limites entre diferentes regiões da imagem.

Além disso, temos a segmentação baseada em características dos pixels, que inclui a segmentação por cores, que agrupa pixels com cores semelhantes, e a

segmentação por intensidade, que agrupa pixels com níveis de intensidade semelhantes.

Por fim, temos técnicas de segmentação baseadas em histograma, que utilizam a distribuição de intensidade de pixels para segmentar a imagem, e técnicas que utilizam movimento, que são especialmente úteis em aplicações de vídeo. Cada uma dessas técnicas tem suas próprias vantagens e desvantagens, e a escolha da técnica apropriada depende muito do problema específico que se está tentando resolver.

Figura 3 - Exemplo de um processo de segmentação de imagem



Fonte: Solem (2012)

#### **2.1.4. Extração de característica**

Após a etapa de segmentação da imagem, inicia-se o processo de extração de características. Nesta fase, extraímos informações que identificam os objetos e regiões detectados na imagem, como por exemplo: dimensões, área, contornos, formas e cores. Este processo é fundamental, pois lida diretamente com as propriedades matemáticas e geométricas da imagem, eventualmente auxiliará o sistema distinguir objetos semelhantes detectados na mesma imagem. A extração de características permite a transformação de dados visuais brutos gerados na segmentação em um formato estruturado, facilitando a análise da etapa de classificação e a tomada de decisões baseadas em padrões identificados nas características extraídas.

#### **2.1.5. Classificação e interpretação**

No término do processamento realizado por sistemas de visão computacional, chegamos às etapas de classificação e interpretação. Nesse ponto, as informações são definidas em um nível mais elevado, determinando a representação da imagem

e classificando-a em grupos com as mesmas características. A inferência realizada pode ser extremamente precisa, fornecendo uma descrição detalhada do que a imagem representa como por exemplo: um carro, uma pessoa, um cachorro etc. Alternativamente, a inferência pode se concentrar em descrever características mais gerais da imagem, como sua forma geométrica, cor e tamanho.

### 3. Machine Learning

O Machine Learning ou Aprendizado de Máquina, foi o propulsor para as capacidades alcançadas no campo da VC, pode-se dizer que é até um tanto difícil falar de um tema sem nos remeter ao outro. É um subcampo da inteligência artificial que busca replicar o aprendizado humano, no entanto, em seu desenvolvimento são utilizadas abordagens matemáticas: probabilidade, estatística, cálculo e álgebra linear. O ML possui algumas diversas definições, em alguns casos, ele é tido como a capacidade de um sistema aprender e alterar seu funcionamento com base em seu próprio histórico de funcionamento, ou seja, a cada interação humano-máquina pressupõe-se que o sistema fará ajustes de forma autônoma em seu funcionamento. Burkov (2019) traz uma definição mais voltada para a construção dos algoritmos e como uma resolução de problemas utilizando estatística:

O aprendizado de máquina é um subcampo da ciência da computação que se preocupa com a construção de algoritmos que, para serem úteis, dependem de uma coleção de exemplos de algum fenômeno. Esses exemplos pode vir da natureza, ser feito à mão por humanos ou gerado por outro algoritmo.

O aprendizado de máquina também pode ser definido como o processo de resolução de um problema prático por 1) reunir um conjunto de dados e 2) construir algorítmicamente um modelo estatístico baseado nesse conjunto de dados. Supõe-se que esse modelo estatístico seja usado de alguma forma para resolver o problema prático. (BURKOV, 2019, p. 03).

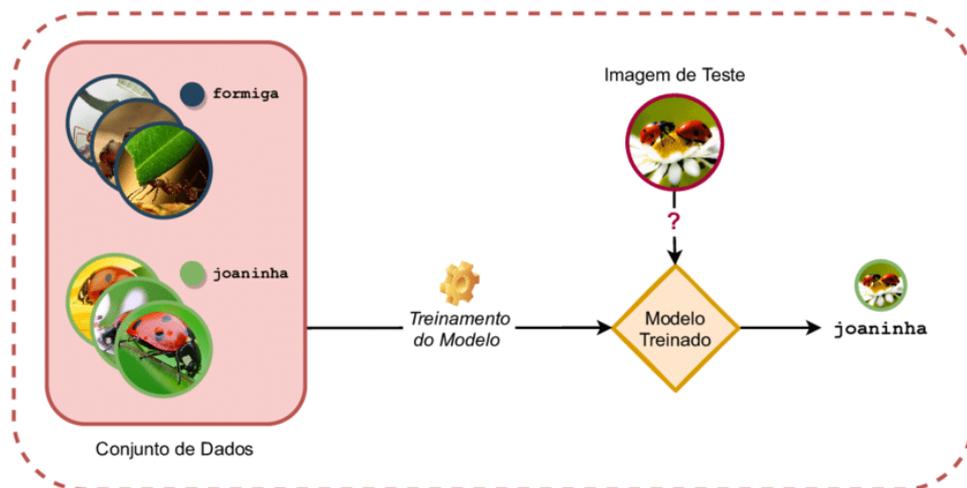
Um dos grandes desafios que enfrentamos no *machine learning*, está relacionada com a disponibilidade de massa de dados e qualidade deles para o treinamento dos modelos, para manutenção dessa massa de dados é requerida uma atenção especial com intuito de manter os dados sempre atualizados. Frente a esse problema que é enfrentado no aprendizado de máquina, estudos focados em aprendizado auto supervisionado tem sido conduzido, com o intuito de minimizar a quantidade de dados de exemplo necessários para treinamento de modelos.

Dentro do ML, temos 4 maneiras diferentes para construção dos nossos modelos de aprendizado, são elas: supervisionada, não-supervisionada, semi-supervisionada e por reforço.

### 3.1. Aprendizado Supervisionado

No Aprendizado Supervisionado, o conjunto de dados utilizados devem ser rotulados, ou seja, as imagens têm a descrição do que elas representam. Tecnicamente, são denominados *Input* e *Output*, onde o *Input* pode ser qualquer tipo de informação como imagens, mensagens de e-mail e até mesmo informações provenientes de sensores, já o *Output* é o rótulo com uma inferência pré-definida do que o *Input* representa. O Aprendizado Supervisionado também é tido como um aprendizado superficial na maioria das vezes, pelo fato de os dados serem rotulados.

Figura 4 - Exemplo do Aprendizado Supervisionado para classificação de imagens



Fonte: Rêgo (2022)

### 3.2. Aprendizado não-supervisionado

No Aprendizado não-supervisionado, não possuímos o rótulo dos dados que estão sendo transmitidos para treinamento, apenas o conjunto de dados a serem analisados, e a partir disso o algoritmo identifica características semelhantes na coleção fornecida e os agrupa de acordo com o que encontrar, essa técnica pode ser chamada de *Clustering*. O aprendizado não-supervisionado, dentro do campo da VC geralmente é aplicado para detecção de objetos.

### **3.3. Aprendizado semi-supervisionado**

Quanto aos Modelos semi-supervisionados, existe a mescla de dados do modelo que inclui rótulo e dados sem rótulo. Geralmente, a quantidade de dados que não são rotulados é maior do que a quantidade de dados rotulados.

Podemos dizer que é uma tentativa de simplificar o aprendizado supervisionado, uma vez que ele implica em custos operacionais demandados do esforço humano.

### **3.4. Aprendizado por reforço**

O Aprendizado por Reforço é uma metodologia onde o treinamento de modelos é realizado através da análise contínua do ambiente em que estão inseridos. Essa técnica, que se assemelha ao processo de aprendizagem humana, utiliza um sistema de recompensas como sinal principal. O objetivo do sistema é otimizar suas ações para maximizar a obtenção dessas recompensas, através de tentativas e erros para aprimorar suas decisões.

## 4. Aprendizado Profundo

O aprendizado profundo ou *deep learning*, é o aprendizado de máquina composto por múltiplas camadas de processamento, camadas essas que hoje são chamadas de redes neurais artificiais, as camadas intermediárias denominadas camadas ocultas podem ter milhares de unidades neurais (nós). Com as melhorias realizadas ano após ano, já é possível observar uma taxa de sucesso no reconhecimento de imagens superior à de pessoas comuns, tendo sido registrado uma taxa de erro de apenas 3,5%. “A aprendizagem profunda é particularmente adequada a contextos em que os dados são complexos e onde existem grandes conjuntos de dados disponíveis” (KELLEHER, 2019, p. 01). Um fato curioso sobre o *deep learning*, é que teoricamente o tema está atrasado em relação a prática, apesar de todo interesse que o assunto gera na comunidade científica e tecnológica. É apontado por Roberts e Yaida (2021) que existe uma desconexão entre a teoria e a prática:

[...]embora os profissionais tenham alcançado marcos surpreendentes, ultrapassaram em muito os teóricos, cujas análises muitas vezes envolvem suposições tão irrealistas que levam a conclusões que são irrelevantes para a compreensão das redes neurais profundas, como são normalmente usadas. (ROBERTS; YAIDA, 2021, p.01).

As redes neurais possuem uma estrutura que são matematicamente baseadas no cérebro humano, composta por nós interconectados onde cada um possui seus respectivos pesos e limites, assemelhando-se a neurônios. Dentro das redes neurais existem dois tipos, as convolucionais e as recorrentes. Em “*The Principles of Deep Learning Theory*”, Roberts e Yaida (2021) explicam o paralelo entre redes neurais artificiais e biológicas:

[...] vagamente baseadas em redes neurais biológicas redes como o seu cérebro, as redes neurais artificiais são provavelmente mais bem pensadas como uma maneira especialmente interessante de especificar um conjunto flexível de funções, construído a partir de muitas funções básicas blocos computacionais chamados neurônios. (ROBERTS; YAIDA, 2021, p.01).

- **Redes Neurais Recorrentes (RNNs):** São adequadas para o processamento de sequências temporais, como texto e fala. Elas possuem conexões que permitem que informações anteriores influenciem as saídas atuais.
- **Redes Neurais Convolucionais (CNNs):** São projetadas especificamente para o processamento de imagens. Elas aplicam operações de convolução e pooling

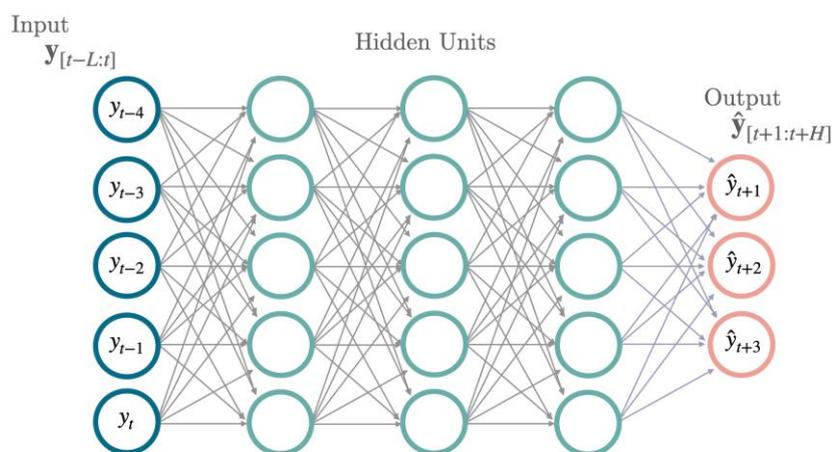
para detectar padrões locais em uma imagem. As CNNs têm sido fundamentais em tarefas de visão computacional, como classificação e detecção de objetos.

As CNNs fazem o uso da álgebra linear, especificamente a multiplicação de matrizes para detecção de padrões em uma imagem. Concebidas especialmente para o processamento de imagens, as CNNs tem sido determinante para realizar tarefas em visão computacional que anteriormente eram tidas como impossíveis. Uma das aplicações das redes neurais convolucionais em visão computacional, é no reconhecimento de ação humana. Esse reconhecimento é realizado por máquinas que se baseiam na postura do corpo humano, como por exemplo reconhecimento de linguagem de sinais, extração de características de articulações além disso é possível extrair padrões de espaço-tempo a partir de um vídeo 3D.

Dentro dos desafios do *deep learning*, devemos ressaltar os dados de modelo utilizado em seus treinamentos, onde é necessário um alto volume de dados e dados esses que tenham alta qualidade.

Na figura 6, representamos uma rede neural onde cada círculo nas três camadas intermediárias (*Hidden Units*), representa um neurônio que é responsável por executar uma função e cada uma dessas funções geram um artefato de saída que vai ser processado pelo próximo “neurônio”, as setas representam as interconexões numa rede neural e no qual será realizado o próximo processamento do artefato ou *output* gerado.

Figura 5 - Esquema de uma rede neural, onde temos o Input (entrada de dados), as camadas ocultas e o Output (saída de informações).



Fonte: Filho (2023)

## 5. Mal Súbito

O mal súbito é caracterizado pela perda inesperada de consciência, é similar ao desmaio, no entanto, em muitos casos pode ser fatal quando o devido atendimento não é prestado em tempo ágil. Em suas causas, podemos ter as seguintes:

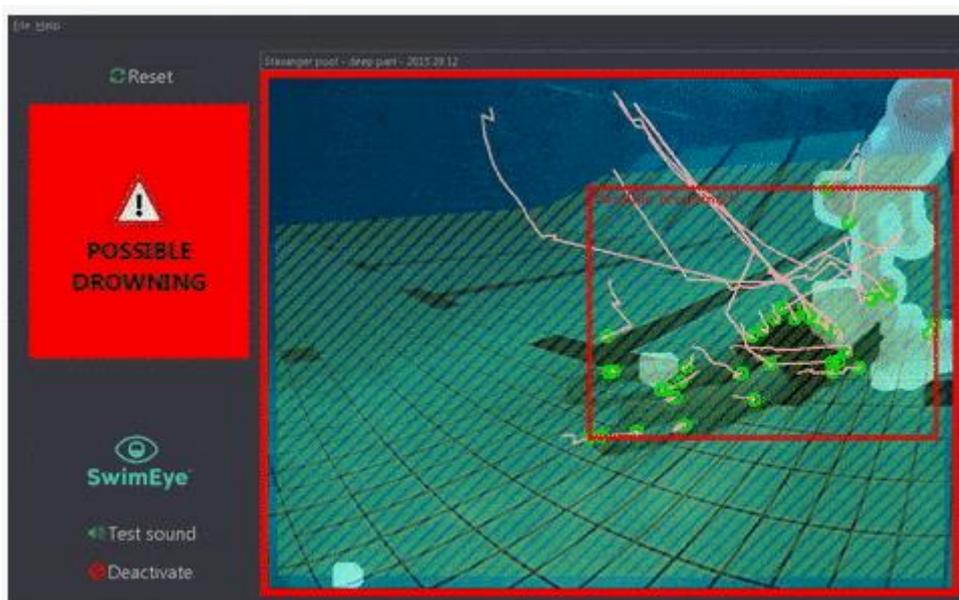
- Infarto: “Infarto do miocárdio é a necrose (morte) de uma parte do músculo cardíaco causada pela ausência da irrigação sanguínea que leva nutrientes e oxigênio ao coração” (VARELLA, 2011).
- Arritmia cardíaca: A arritmia é quando há um descompasso nos batimentos do coração. Por exemplo: quando uma pessoa mesmo estando em repouso, percebe um aceleração nos batimentos cardíacos sem razão aparente.
- Acidente Vascular Cerebral: Ocorre devido a interrupção no envio de sangue para o cérebro. “O AVC pode se originar de uma obstrução de vasos sanguíneos, o chamado acidente vascular isquêmico, ou de uma ruptura do vaso, conhecido por acidente vascular hemorrágico” (BIBLIOTECA VIRTUAL EM SAÚDE MS, 2006).
- Convulsões: “Convulsão é a contração involuntária da musculatura, que provoca movimentos desordenados. Geralmente é acompanhada pela perda da consciência” (BIBLIOTECA VIRTUAL EM SAÚDE MS, 2004).

É válido lembrar que o mal súbito não se limita às situações identificadas anteriormente, mas podemos dizer que essas situações representam alto risco de morte. De acordo com o ministério da saúde, estima-se que no Brasil, ocorra de 300 mil a 400 mil infartos anuais e dentro dessa estimativa a cada 5 ou 7 casos é previsto que 1 venha a óbito. É ressaltado também que para salvar vidas, é de suma importância que o atendimento emergencial seja realizado nos primeiros minutos. Em 2023, houve 110.818 mortes de brasileiros decorrentes de AVC e de acordo com estudo divulgado pelo jornal O Globo e conduzido pela Organização Mundial do AVC, estima-se que nas próximas 3 décadas os casos de acidente vascular cerebral aumentarão em 50% no mundo e pode chegar até 10 milhões de casos até 2050.

## 6. Soluções existentes

Atualmente, contamos com alguns exemplos da utilização da visão computacional para monitoramento de ação humana. Uma das soluções que podemos destacar é a SwimEye que foi desenvolvida para detectar afogamentos em piscinas, ela avalia quando um indivíduo está em contato com o fundo de uma piscina e sem movimentos, após 3 segundos em inércia é disparado um aviso para os salva-vidas e para a central de monitoramento.

Figura 6 – Software SwimEye



Fonte: SwimEye (2024)

O SwimEye indiretamente serve ao propósito de monitorar possível mal súbito em piscinas. Como pode-se analisar na figura 6, ele usa o rastreamento de articulações-chaves para monitorar a posição e movimento do indivíduo de acordo com o fundo da piscina.

Apesar da VC ser pouco explorada no Brasil, atualmente temos um sistema implantado nas estações do metrô de São Paulo para monitorar as dependências por câmera e otimizar a ação da segurança em situações anormais. Visando melhorar a segurança, o sistema foi implantado em novembro de 2022, mas ainda é pouco conhecido entre os usuários, visando proporcionar maior bem-estar para as pessoas, esse sistema de segurança acomodaria bem uma abordagem de análise de mal súbito e otimizaria o trabalho de primeiros socorros em estações de parada. O socorro a um indivíduo, em muitos casos, está

facultado a ação de outras pessoas em comunicar ao maquinista do trem. Atualmente, os modelos de predição de movimento estão sendo explorados, esses modelos podem tornar o monitoramento ainda mais eficiente e possibilitar a agilidade na prestação de socorro.

Os avanços na predição de movimentos foram explorados pelos pesquisadores da *Columbia Engineering*, que conseguiram êxito em desenvolver um modelo de aprendizado de máquina preditivo, que é capaz de prever uma ação que está prestes a ocorrer similarmente a capacidade de identificação humana, o estudo foi apresentado na Conferência Internacional sobre Visão Computacional e Reconhecimento de Padrões.

É o método mais preciso até o momento para prever eventos de ação em vídeo até vários minutos no futuro, dizem os pesquisadores. Depois de analisar milhares de horas de filmes, jogos esportivos e programas como “The Office”, o sistema aprende a prever centenas de atividades, desde apertos de mão até socos. Quando não consegue prever a ação específica, encontra o conceito de nível superior que os liga, neste caso, a palavra “saudação”. (EVARTS, 2021).

A predição de movimentos em soluções de visão computacional, depende de uma quantidade de modelos expressiva, no entanto, uma vez que a solução é viabilizada, pode se utilizar o *deep learning* para conferir maior confiabilidade a visão e interpretação realizada pela máquina.

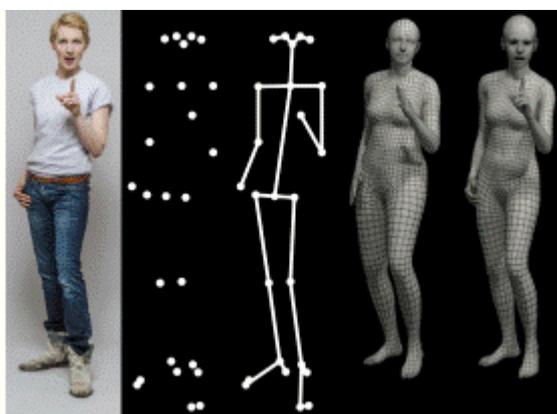
Um dos países que podemos citar como modelo no uso da VC, é a China com o seu sistema de vigilância. Existem investimentos expressivos do governo chinês para ter o controle em tempo real das ações dos habitantes do país. O reconhecimento facial implementado no sistema de segurança chinês, é capaz de associar a imagem do indivíduo com os dados pessoais que ficam em posse do governo. De acordo com informação transmitida por Zmoginski (2019), para aproximadamente 83% dos chineses, o reconhecimento facial transmite uma maior sensação de segurança.

Quando buscamos por soluções de reconhecimento de ação humana, na maioria das vezes identificamos modelos de *machine learning* prontos para serem utilizados no desenvolvimento. A ferramenta mais popular é o Tensorflow que é utilizado para implementações de softwares de visão computacional, e um de seus modelos é a estimativa de poses, onde 16 articulações são rastreadas para monitoramento. Alguns *datasets* também disponíveis para uso são: Kinetics-700, ARID, DAHLIA. O Kinetics-700 é um *dataset* que cobre 700 ações humanas

a partir de um treinamento realizado com aproximadamente 650 mil vídeos do Youtube, o que é um alto número para garantir qualidade da identificação de ação. O ARID já é mais voltado para detecção de ação humana em ambientes com pouca iluminação, no entanto, só tem cobertura de 11 ações humanas. Por fim o DAHLIA, ele é focado em casas inteligentes e aplicado para monitoramento de atividades diárias, com ele é possível obter uma interpretação em alto nível como por exemplo: “Preparando o almoço”, “Limpendo a casa”. Como os modelos de treinamento representam grande desafio para sistemas de monitoramento utilizando visão computacional, quanto mais ações catalogadas, podemos garantir quais ações não correspondem ao comportamento que indica um possível mal súbito.

Especificamente em visão computacional, existem métodos desenvolvidos que buscam aprimorar a interpretação de imagens a partir da transformação de dados 2D em 3D, como abordado no artigo “*Expressive Body Capture: 3D Hands, Face, and Body from a Single Image*”, onde foi aprimorada a ferramenta SMPL que possibilita a conversão de imagens 2D em 3D rastreando o corpo, movimento das mãos, as expressões faciais e o gênero do indivíduo presente na imagem. A maioria dos modelos, antes não davam importância para a expressão facial e movimento das mãos, mas no estudo é ressaltado: “Para compreender o comportamento humano, contudo, temos de captar mais do que as principais articulações do corpo – precisamos da superfície 3D completa do corpo, mãos e rosto” (PAVLAKOS et al., 2019).

Figura 7 – Exemplo do SMPL-X

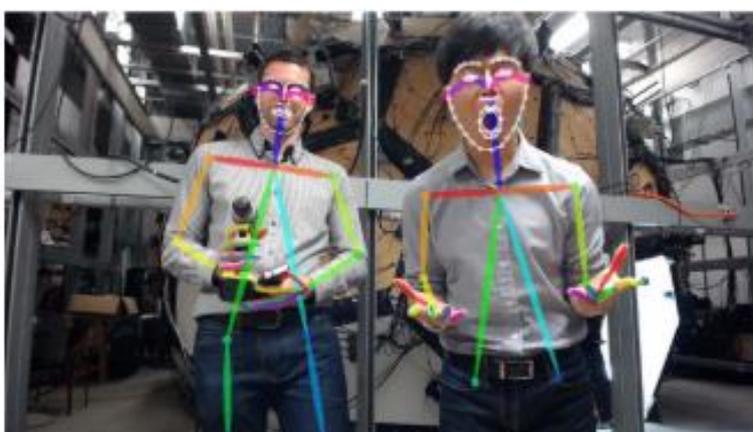


Fonte: Pavlakos (2019)

Ao realizar testes em ferramentas de visão computacional, com a entrada de uma imagem de um indivíduo desmaiado, como saída obtemos: “uma pessoa deitada no chão”, mas se possuísse um rastreamento do rosto, seria possível identificar que a pessoa também está com os olhos fechados e com a boca aberta ou fechada. O modelo apresentado por Pavlakos et al. (2019), viabiliza ainda mais o rastreio do mal súbito que possa ser ocasionado por doenças que apresentam mais sinais físicos, como por exemplo o AVC.

Outra solução existente é o OpenPose, que se trata de uma biblioteca de estimativa de pose. Atualmente disponível tanto em 2D quanto em 3D, ela utiliza redes neurais para detecção de articulações, rosto e mãos. Na versão 2D a detecção de pontos chaves em tempo real realizada pela ferramenta, pode rastrear mais que 1 indivíduo. Já no modelo 3D, é possível a detecção de pontos chaves em tempo real de apenas 1 pessoa. O OpenPose é capaz de monitorar quedas, realizar monitoramento de multidões e até mesmo análise de postura, sua aplicabilidade é bastante vasta. Além do OpenPose, existem soluções semelhantes, que em alguns casos, possuem código aberto ou custo reduzido como por exemplo, o Detectron2 e o MMPose, no entanto, em relação ao OpenPose, o Detectron2 possui maiores requisitos computacional e complexidade e quanto ao MMPose tem uma acuracidade inferior. O OpenPose também realiza detecção dos pontos chaves da face, similar ao modelo SMPL-X abordado por Pavlakos et al. (2019) e dessa forma, também com viabilidade de rastrear outros sinais que possam especificar a causa do mal súbito.

Figura 8 – Exemplo de artefato de saída do OpenPose



Fonte: Huang, Zheng, Hu (2019)

## 7. Conclusão

Atualmente, podemos presenciar uma corrida tecnológica no campo de inteligência artificial. Alguns setores detêm os maiores investimentos, outros, no entanto, seguem um tanto desestimulados e quando aplicadas as soluções, particularmente no Brasil, é concebida com certo atraso. Países como Estados Unidos e China, estão sempre a frente em pesquisas e desenvolvimento de novas soluções e apesar do famoso sistema chinês de hiper vigilância não ser bem-vindo para a maior parte da população Brasileira, ainda sim, precisamos ocupar nosso espaço nessa jornada e desenvolver soluções que nos tragam uma melhor qualidade de vida, afinal esse é propósito do desenvolvimento da inteligência artificial.

Nessa pesquisa, o objetivo foi obter um conhecimento teórico, para que pudéssemos analisar a viabilidade de sistemas voltados para monitoramento de mal súbito. Foi constatado a oportunidade da possível aplicação da visão computacional para otimização de serviços de emergências, com isso teríamos otimização de tempo na prestação de socorros e conseqüentemente salvaríamos muitas vidas. Com as pesquisas realizadas, constatou-se que é totalmente viável a aplicação da VC para monitoramento de emergências, como visto no capítulo de soluções existentes, temos o SwimEye para monitoramento de afogamento e utilizando o OpenPose é possível desenvolver um sistema de visão computacional que avalie a expressão corporal de uma pessoa. Além disso, é possível ter modelos com qualidade superior, quando se trata de criar modelos 3D completos de acordo com estudo e desenvolvimento de Pavlakos et al. (2019).

O grande desafio no desenvolvimento de soluções que utilizam o aprendizado de máquina tanto a abordagem clássica quanto o aprendizado profundo, é a disponibilidade de *datasets*. Para o desenvolvimento de soluções utilizando algum dos métodos de aprendizado, se faz necessário a disponibilidade de uma quantidade substancial de modelos e quando pensamos no cenário proposto de monitoramento de mal súbito, seria necessário um investimento inicial para enriquecimento de informações.

Além da contribuição que a pesquisa oferece para análise de viabilidade da solução, também será útil porta de entrada para concepção de novas possibilidades dentro do campo da visão computacional.

## Referencial

BALLARD, D. H.; BROWN, C. M. **Computer vision**. 1. ed. Englewood Cliffs, N.J.: Prentice-Hall, 1982.

BARELLI, F. **Introdução a visão computacional: uma abordagem pratica com python e opencv**. 1. ed. [s.l.], Casa do Código, 2018.

BIBLIOTECA VIRTUAL EM SAÚDE MS. **Acidente vascular cerebral (AVC)**. Biblioteca Virtual em Saúde MS, ago. 2006. Disponível em: [<https://bvsmms.saude.gov.br/avc-acidente-vascular-cerebral/>]. Acesso em: 25 maio 2024.

BIBLIOTECA VIRTUAL EM SAÚDE MS. **Convulsão**. Biblioteca Virtual em Saúde MS, jun. 2004. Disponível em: [<https://bvsmms.saude.gov.br/convulsao/#:~:text=Convuls%C3%A3o%20%C3%A9%20a%20contratura%20involunt%C3%A1ria>]. Acesso em: 25 maio 2024.

BURKOV, A. **The Hundred-Page Machine Learning Book**. [s.l.], Andriy Burkov, 2019.

CAO, Z. et al. **OpenPose: realtime multi-person 2d pose estimation using part affinity fields**. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 43, n. 1, pp. 172-186, jan. 2021.

CNN BRASIL. **Festival de fotografia com celular resgata o modernismo de 1922**. Disponível em: [<https://stories.cnnbrasil.com.br/entretenimento/festival-de-fotografia-com-celular-resgata-o-modernismo-de-1922/>]. Acesso em: 03 maio 2024.

DEMARCO, G. **Complete Guide to OpenPose**. Ikomia, ago. 2023. Disponível em: [<https://www.ikomia.ai/blog/complete-openpose-guide>]. Acesso em: 31 maio 2024.

DOBES, M. **Visão computacional: conheça a importância para a transformação digital**. Certi, 27 jul. 2021. Disponível em: [<https://certi.org.br/blog/visaocomputacional/#:~:text=Aquisi%C3%A7%C3%A3o%20da%20imagem%3A%20por%20meio>]. Acesso em: 10 maio 2024.

DONG, S.; WANG, P.; ABBAS, K. **A survey on deep learning and its applications**. Computer Science Review, v. 40, p. 100379, 2021.

ECOCENTRO. **Ecocentro – Excelência em ecografia**. Disponível em: [<https://ecocentro.com.br/ecografia/>]. Acesso em: 03 maio 2024.

EVARTS, H. **AI Learns to Predict Human Behavior from Videos**. Columbia Engineering, 28 jun. 2021. Disponível em: [<https://www.engineering.columbia.edu/news/ai-learns-to-predict-human-behavior-from-videos>]. Acesso em: 27 maio 2024.

FILHO, M. **Como Prever Séries Temporais Com Redes Neurais em Python**. Mario Filho | Machine Learning, 30 jan. 2023. Disponível em: [https://mariofilho.com/como-prever-series-temporais-com-redes-neurais-em-python/]. Acesso em: 10 maio 2024.

GARTNER. **Emerging Tech: Revenue Opportunity Projection of Computer Vision: Growth Markets**. Gartner, 19 abr. 2024. Disponível em: [https://www.gartner.com/en/documents/5364563#:~:text=Key%20Findings,from%20%24126%20billion%20in%202022.]. Acesso em: 27 maio 2024.

GOVERNO DO ESTADO DE SÃO PAULO. **Metrô de SP ganha novo sistema de monitoramento eletrônico com inteligência artificial**. Governo de estado de São Paulo, 21 nov. 2022. Disponível em: [https://www.saopaulo.sp.gov.br/spnoticias/metro-de-sp-ganha-novo-sistema-de-monitoramento-eletronico-com-inteligencia-artificial/]. Acesso em: 3 jun. 2024.

HCOR. **Ressonância magnética - Exames e Diagnósticos**. Disponível em: https://www.hcor.com.br/imprensa/noticias/ressonancia-magnetica/. Acesso em: 03 maio 2024.

HOSPITAL ALEMÃO OSWALDO CRUZ. **TUDO SOBRE MAL SÚBITO: O QUE É, QUAIS SÃO OS SINTOMAS E COMO AGIR**. Hospital Alemão Oswaldo Cruz, 12 jan. 2024. Disponível em: [https://www.hospitaloswaldocruz.org.br/imprensa/hospital-na-midia/tudo-sobre-mal-subito-o-que-e-quais-sao-os-sintomas-e-como-agir/#:~:text=O%20mal%20s%C3%BAbito%20%C3%A9%20um,r%C3%A1pido%2C%20a%20pessoa%20pode%20morrer.]. Acesso em: 25 maio 2024.

HUANG, H.; ZHENG, Y.; HU, Z. **Video Abnormal Action Recognition Based on Multimodal Heterogeneous Transfer Learning**, Advances in Multimedia, [s.l.], p. 1-13, 2024.

IBM. **O que é Aprendizado não Supervisionado?** Disponível em: [https://www.ibm.com/br-pt/topics/unsupervised-learning]. Acesso em: 25 maio 2024.

IBM. **O que é o Deep Learning?** Disponível em: [https://www.ibm.com/br-pt/topics/deep-learning]. Acesso em: 25 maio 2024.

IBM. **O que são redes neurais convolucionais?** Disponível em: [https://www.ibm.com/br-pt/topics/convolutional-neural-networks]. Acesso em: 25 maio 2024.

IMAGENET. ImageNet. Disponível em: [https://en.wikipedia.org/wiki/ImageNet]. Acesso em: 03 maio 2024.

KELLEHER, J. D. Deep Learning. Cambridge, MA: MIT Press, 10 set. 2019.

KELLMAN, P. J.; ARTERBERRY, M. E. Infant Visual Perception. **Handbook of Child Psychology**, 1 jun. 2007.

LI, Z. et al. **A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects**. IEEE Transactions on Neural Networks and Learning Systems, v. 33, n. 12, p. 1–21, 2021.

LUDERMIR, T. B. **Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências**. Estudos Avançados, v. 35, n. 101, p. 85–94, abr. 2021.

MARENGONI, M.; STRINGHINI, S. **Tutorial: Introdução à Visão Computacional usando OpenCV**. Revista de Informática Teórica e Aplicada, v. 16, n. 1, p. 125–160, 8 mar. 2010.

MATHWORKS. **Wavelet Denoising - MATLAB & Simulink**. Disponível em: [<https://www.mathworks.com/help/wavelet/ug/wavelet-denoising.html>]. Acesso em: 14 maio 2024.

MICROSOFT. **Noções básicas sobre a Pesquisa Visual Computacional - Training**. Disponível em: [<https://learn.microsoft.com/pt-br/training/modules/get-started-ai-fundamentals/3-understand-computer-vision>]. Acesso em: 3 maio 2024.  
MINISTÉRIO DA SAÚDE. **Infarto**. Disponível em: [<https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/i/infarto>]. Acesso em: 25 maio 2024.

O GLOBO. **AVC provocará 10 milhões de mortes ao ano em 2050, diz estudo global; saiba as causas**. O GLOBO, 10, out. 2023. Disponível em: [<https://oglobo.globo.com/saude/noticia/2023/10/10/avc-provocara-10-milhoes-de-mortes-ao-ano-em-2050-diz-estudo-global-saiba-as-causas.ghtml>]. Acesso em: 25 maio 2024.

PAPERS WITH CODE. **DAHLIA Dataset**. Disponível em: [<https://paperswithcode.com/dataset/dahlia-daily-human-life-activity>]. Acesso em: 20 maio 2024.

PAPERS WITH CODE. **Kinetics-700 Dataset**. Disponível em: [<https://paperswithcode.com/dataset/kinetics-700>]. Acesso em: 20 maio 2024.

PAVLAKOS, G. et al. **Expressive Body Capture: 3D Hands, Face, and Body From a Single Image**. 15 jun. 2019.

RÊGO, L. et al. **Uso de Meta-Learning em Tarefas de Aprendizado Profundo**. p. 53–82, 19 set. 2022.

REVIEWS GUIDE. **Reviews Guide**. Disponível em: [<https://reviews.guide/>]. Acesso em: 03 maio 2024.

ROBERTS, D.; YAIDA, S. **The Principles of Deep Learning Theory: An Effective Theory Approach to Understanding Neural Networks**. Cambridge University Press, 26 jun. 2023

SHI, L. et al. **Action recognition via pose-based graph convolutional networks with intermediate dense supervision**. Pattern Recognition, v. 121, p. 108170, jan. 2022.

SHIRAI, Y. **Three-Dimensional Computer Vision**. [s.l.] Springer Science & Business Media, 2012.

SIS INTERNATIONAL. **Pesquisa de mercado de IA de visão computacional**. Disponível em: [<https://www.sisinternational.com/pt/solucoes/pesquisa-de-mercado-de-ia-e-consultoria-estrategica/pesquisa-de-mercado-de-ia-de-visao-computacional/>]. Acesso em: 27 maio 2024.

SLATER, A. et al. Visual Perception. **The Wiley-Blackwell Handbook of Infant Development**, p. 40–80, 21 jul. 2010.

SOLEM, E. Programming Computer Vision with Python: Tools and algorithms for analyzing images. O'Reilly Media, Inc., 19 jun. 2012.

SWIMEYE. **SwimEye develops, manufactures and retails rapid alerts for life-saving situations**. Disponível em: [<https://swimeye.com/>]. Acesso em: 20 maio 2024.

SZELISKI, R. **COMPUTER VISION: algorithms and applications**. 2. ed. S.L.: Springer, 2022.

TENSORFLOW. **Estimativa de pose**. TensorFlow, 30 ago. 2023. Disponível em: [[https://www.tensorflow.org/lite/examples/pose\\_estimation/overview?hl=pt-br](https://www.tensorflow.org/lite/examples/pose_estimation/overview?hl=pt-br)]. Acesso em: 20 maio 2024.

V7LABS. **Human Activity Recognition (HAR): Fundamentals, Models, Datasets**. v7, 27 mar. 2023. Disponível em: [<https://www.v7labs.com/blog/human-activity-recognition#h4>]. Acesso em: 20 maio 2024.

VARELLA, M. **Infarto do miocárdio (ataque cardíaco)**. Drauzio | uol, 12 abr. 2011. Disponível em: [<https://drauziovarella.uol.com.br/doencas-e-sintomas/infarto-do-miocardio-ataque-cardiaco/>]. Acesso em 25 maio 2024.

VISÃO EM FOCO. **O desenvolvimento da visão na criança**. Visão em foco. Disponível em: [<https://visaoemfoco.org.br/noticia/o-desenvolvimento-da-visao-na-crianca1665664813#:~:text=No%20primeiro%20m%C3%AAs%2C%20a%20vis%C3%A3o>]. Acesso em: 25 maio 2024.

WU, C.; CHENG, Z. A Novel Detection Framework for Detecting Abnormal Human Behavior. **Mathematical Problems in Engineering**, v. 2020, p. 1–9, 30 nov. 2020.

ZMOGINSKI, Felipe. **A sociedade mais vigiada do mundo: como a China usa o reconhecimento facial**. UOL Tilt, 19 jan. 2019. Disponível em: [<https://www.uol.com.br/tilt/noticias/redacao/2019/01/19/a-sociedade-mais-vigiada-do-mundo-como-a-china-usa-o-reconhecimento-facial.htm>]. Acesso em: 27 maio 2024.