

DOI:

MANAGEMENT OF THE FLOW OF PEOPLE IN EARLY CARE UNITS (24 HS UPA) USING COMPUTATIONAL VISION

GESTÃO DO FLUXO DE PESSOAS EM UNIDADES DE PRONTO ATENDIMENTO (UPA 24 HS) USANDO VISÃO COMPUTACIONAL

Marcos Vinithius Melo Filho

CENTRO UNIVERSITÁRIO ESTÁCIO DO CEARÁ - ORCID: <https://orcid.org/0000-0002-2603-4511>

Wellington Sousa Aguiar

CENTRO UNIVERSITÁRIO ESTÁCIO DO CEARÁ - ORCID: <https://orcid.org/0000-0003-0677-5782>

Rafael Santana Aguiar

UNIVERSIDADE DE FORTALEZA - UNIFOR - ORCID: <https://orcid.org/0000-0002-3826-7048>

Péricles Alves Ferreira De Arruda

CENTRO UNIVERSITÁRIO ESTÁCIO DO CEARÁ - ORCID: <https://orcid.org/0000-0001-6713-7915>

Abstract

The objective of this work is to use computer vision using convolutional neural networks to control the flow of people in an Emergency Care Unit (UPA 24 hours), capturing images of patients, inferring their age, gender, date and time. Generating statistical data for management and decision making.

Know the characteristics and behavioral pattern of the population that seeks the UPAs 24 hours, thus improving the quality of primary health care, generating strategic knowledge to plan and prioritize the scales of health professionals based on automatically generated statistical data.

The nature of this research is quantitative, bibliographical and applied, with data collected through a software developed with the purpose of collecting daily data at the UPA, generating statistical knowledge for management.

The detection of faces of "Adult men" had the highest accuracy with 79.32%, this being the highest average among the 4 (four) categories existing in the training sample, the other category with greater assertiveness was "Adult women" with 76, 59%, followed by "Young women" and "Young men".

This multidisciplinary research between Computing and Public Health presents a practical application of the use of low-cost Artificial Intelligence in the real world of primary health care, the gateway to SUS for more than 75% of our population.

This research applies in the real world the knowledge acquired by student researchers of Computer Science courses in solving problems in our community that seeks primary health care, supporting the management of human resources at the 24-hour health post.

Key words: Artificial intelligence, Neural networks, Facial recognition, UPA, Primary attention

Resumo

O objetivo deste trabalho é utilizar a visão computacional usando redes neurais convolucionais no controle do fluxo de pessoas em uma Unidade de Pronto Atendimento (UPA 24 hs), captando imagens dos pacientes, inferindo sua idade, sexo, data e a hora. Gerando dados estatísticos para gestão e tomada de decisões.

Conhecer as características e o padrão comportamental da população que procura as UPAs 24 hs, melhorando assim a qualidade na atenção básica de saúde, gerando conhecimento estratégico para planejar e priorizar as escalas de profissionais de saúde baseado em dados estatísticos gerados automaticamente.

A natureza desta pesquisa é quantitativa, bibliográfica e aplicada, com dados coletados por meio de um software desenvolvido com a finalidade da coleta dos dados diários na UPA, gerando conhecimento estatístico para a gestão.

A detecção de rostos de "Homens adultos" teve a maior acurácia com 79.32%, sendo essa a maior média entre as 4 (quatro) categorias existentes na amostra de treinamento, a outra categoria com maior assertividade foi de "Mulheres adultas" com 76,59%, seguidas de "Mulheres jovens" e "Homens jovens".

Essa pesquisa multidisciplinar entre Computação e Saúde Pública, apresenta uma aplicação prática do uso da Inteligência Artificial de baixo custo no mundo real da atenção básica de saúde, porta de entrada do SUS para mais de 75% da nossa população.

Essa pesquisa aplica no mundo real os conhecimentos adquiridos por alunos pesquisadores dos cursos de Ciência da Computação na solução de problemas da nossa comunidade que busca a atenção básica de saúde, apoiando à gestão dos recursos humanos do posto de saúde 24 horas.

Palavras-chave: Inteligência Artificial, Redes Neurais, Reconhecimento facial, UPA, Atenção primária

O FLUXO DE PESSOAS EM UNIDADES DE PRONTO ATENDIMENTO (UPA 24 hs) USANDO VISÃO COMPUTACIONAL

A Unidade de Pronto Atendimento (UPA 24hs) faz parte da Rede de Atenção às Urgências para atender a população em urgências e emergências pediátricas, clínicas e odontológicas de baixa e média complexidade, reduzindo assim as filas nos prontos-socorros dos hospitais. O objetivo deste trabalho é utilizar a visão computacional com o uso de redes neurais convolucionais no controle do fluxo de pessoas em uma Unidade de Pronto Atendimento (UPA 24 hs), captando imagens dos pacientes e inferindo sua idade e sexo, além de registrar a data e a hora que o paciente entrou na UPA, gerando assim dados estatísticos para a tomada de decisões. A natureza desta pesquisa é quantitativa, bibliográfica e aplicada, com dados coletados por meio de um software desenvolvido com a finalidade da coleta dos dados. A detecção de rostos de “Homens adultos” teve a maior assertividade com 79.32%, sendo essa a maior média entre as 4 (quatro) categorias existentes na amostra, a outra categoria com maior assertividade foi de “Mulheres adultas” com 76,59%, seguidas de “Mulheres jovens” e “Homens jovens”. Concluindo, a pesquisa mostrou a eficácia da visão computacional para detecção e reconhecimento facial usando redes neurais convolucionais, obtendo de forma rápida e clara os dados de controle do fluxo de pessoas nas UPAs, categorizando a entrada dos pacientes pelo dia e hora, usando suas características faciais para obtenção da faixa etária e sexo.

Palavras-chaves: Inteligência Artificial; Redes Neurais; Reconhecimento Facial.

THE FLOW OF PEOPLE IN EARLY CARE UNITS (UPA 24 hs) USING COMPUTATIONAL VISION

The Emergency Care Unit (24hs UPA) is part of the Emergency Care Network to serve the population in pediatric, clinical and dental emergencies of complex low and medium, assimilated as queues in hospital emergency rooms. The objective of this work is to use a computer vision with the use of convolutional neural networks in the flow of people in an Emergency Care Unit (24 hs UPA), capturing images of patients and inferring their age and gender, in addition to recording data and the time the patient entered the UPA, thus generating statistical data for decision-making. The nature of this research is quantitative, bibliographical and applied, with data collected through a software developed with the data collection. The detection of faces of "adult men" had a greater assertiveness with 79.32%, this being the highest average among the 4 (four) categories in the sample, the other category with greater assertiveness was "Adult women" with 76, 59%, followed by “Young women” and “Young men”. In conclusion, a survey showed the effectiveness of computer vision for facial detection and recognition using convolutional neural networks, quickly and clearly obtaining data to control the flow of people in UPAs, categorizing patient entry by day and time, using their characteristics to obtain the age and gender.

Keywords: Artificial Intelligence; Neural Networks; Facial recognition.

INTRODUÇÃO

A Unidade de Pronto Atendimento (UPA 24hs) faz parte da Rede de Atenção às Urgências. O objetivo é concentrar os atendimentos de saúde de complexidade intermediária, compondo uma rede organizada em conjunto com a atenção básica, atenção hospitalar, atenção domiciliar e o Serviço de Atendimento Móvel de Urgência - SAMU 192 (BRASIL, 2020).

Atualmente as UPAs não têm um controle de entrada e saída de pacientes, impossibilitando um melhor atendimento para a população. Não existe uma maneira eficaz, por exemplo, saber quantas crianças entraram em um dia específico.


Em 2015, Ariadne, usuária da Unidade de Pronto Atendimento, relatou que um dia a UPA de Mendanha, na Zona Oeste do Rio de Janeiro, tinha mais de 50 crianças para um único médico atender (G1, 2020).

Ainda não existe estatisticamente uma maneira de provar, por exemplo, que mais pessoas adultas estão indo às UPAs nas quintas-feiras às 18 horas do que aos sábados às 8 horas da manhã, mas usando-se visão computacional podemos garantir um controle de fluxo contínuo por reconhecimento e categorização de faces humanas. Essa pesquisa propõe gerar dados estatísticos rapidamente, agilizando o trabalho no atendimento, pois é muito comum que as medicações para pessoas idosas sejam diferentes das que são prescritas para crianças e adultos.

Em maio/2020, no auge da primeira grande onda de COVID-19 em Fortaleza-CE, as UPAs contavam com 170 leitos de observação para pacientes com suspeita e casos confirmados de coronavírus, segundo dados do Sistema IntegraSUS.

Em Fortaleza, capital do estado do Ceará, existem 12 (doze) UPAs 24hs em funcionamento atendendo a população em casos de urgências e emergências, inclusive os casos de Covid-19 durante a pandemia. O Gráfico 1 abaixo, nos mostra a grande importância e capacidade das UPAs no enfrentamento da Covid-19, bem como a necessidade de conhecermos e mapearmos o público que procura as UPAs como porta de entrada do serviço público de saúde .

Gráfico 1 – Atendimentos realizados nas UPAs de Fortaleza-CE em 2021.



Fonte: IntegraSUS, atualizado em 01/06/2021.

Visão computacional é um campo da inteligência artificial que treina computadores para interpretar e entender o mundo visual. Usando imagens digitais de câmeras e vídeos, junto a modelos de *Deep Learning*, as máquinas podem identificar e classificar objetos corretamente e, então reagir ao que elas “veem”.

As primeiras experiências em visão computacional aconteceram em 1950, com o uso de algumas das primeiras redes neurais para detectar os limites de um objeto e para classificar objetos simples em categorias como círculos e quadrados. Em 1970, o primeiro uso comercial de visão computacional interpretou textos manuscritos e digitados usando reconhecimento ótico de caracteres. Esse avanço tinha como objetivo interpretar textos escritos para deficientes visuais (SAS, 2020).

Com o uso da visão computacional para gerar estatísticas, podemos antecipar aos profissionais de saúde para averiguar o estoque de remédios daqueles pacientes. Com essa previsão, torna-se possível evitar a falta de medicamentos ou a convocação de outros profissionais especializados da área de saúde para o atendimento, por exemplo, um idoso com problemas do coração ou uma criança com uma simples virose.

Este trabalho procurou entender como o reconhecimento de imagens para detecção e identificação facial pode ajudar na gestão do fluxo de pessoas na UPA.

Uma grande demanda de pacientes e uma administração que não tem uma ferramenta adequada de controle de fluxo, pode acarretar muitas horas de espera, alta demanda e poucos médicos, podendo ocorrer, por exemplo, que pacientes, como crianças, não consigam um rápido atendimento com um pediatra, ou um idoso hipertenso que não consiga ser atendido com prioridade.

A finalidade das UPAs são urgências e emergências para estabilização de casos graves e encaminhamento aos hospitais, seguindo com esses acontecimentos, ocorre a superlotação e o atendimento pode acabar perdendo a qualidade (OLIVEIRA, 2011).

“não é culpa do paciente, é culpa do sistema, que não consegue acolher esse paciente. Esse cara até tentou ir lá [posto], a gente vê esse registro no prontuário, mas disseram para ele que não tinha médico, ou que não tinha vaga na agenda, ou que ele tinha que marcar (E10); como é difícil o acesso ao posto, eles vêm até a UPA, porque eles sabem que a gente não pode negar atendimento, então acham mais fácil vim aqui, do que ir lá de madrugada, pegar fichinha (T10)” (OLIVEIRA, 2011).

Para auxiliar as UPAs seria necessário a criação de uma ferramenta para gerar dados estatísticos da previsão de quantidade e categoria do público, assim teriam como controlar melhor o fluxo de pessoas e solicitar médicos específicos para os dias em que a demanda de uma categoria for maior. Por exemplo, se há demanda de atendimento para crianças em um dia específico que foi comprovado estatisticamente, o atendimento médico especializado já estaria previsto e de prontidão naqueles dias indicados.

O objetivo principal dessa pesquisa foi desenvolver um software para identificar e categorizar faces humanas por sexo e faixa etária por meio de imagem ou vídeo para coletar dados capazes de gerar estatísticas do fluxo de pessoas, auxiliando assim a tomada de decisão dos gestores da saúde pública.

Como objetivos específicos, podemos citar ainda: Descrever conceitos de visão computacional e inteligência artificial; Apresentar um exemplo prático de uma aplicação da Identificação facial; e Aplicar técnicas de desenvolvimento de software com Inteligência Artificial em problemas da comunidade em que estamos inseridos, através de uma aplicação no mundo real.

REFERENCIAL TEÓRICO

Gestão do serviço público de saúde.

Os movimentos sanitários, após a criação do Centro Brasileiro de Estudos da Saúde (CEBES) em 1976, iniciaram uma grande mobilização social, com publicações e divulgações de ideias, para o começo do Sistema Único de Saúde (SUS), visando um acesso universal, descentralizado, com participação social e financiado pelo Poder Público (CAMPOS et al, 2012).

Visto isso, o SUS trabalha dentro de princípios (Universalidade, Integralidade e equidade) e diretrizes (Descentralização, Regionalização, Hierarquização e Participação social) (MOREIRA, 2016).

A Universalidade se caracteriza pela garantia do acesso ao serviço de saúde de qualquer cidadão sem discriminação; a Integralidade garante a assistência continuada com o objetivo de oferecer a promoção, proteção, cura e reabilitação de indivíduos e da comunidade, realizando uma abordagem multidisciplinar ao processo saúde-doença; a Equidade se baseia na prioridade às populações mais vulneráveis (CAMPOS et al, 2012).

Já a Descentralização é caracterizada pela distribuição do poder político nas esferas federal, estadual e municipal com o Ministério da Saúde (esfera federal), Secretarias Estaduais de Saúde (esfera estadual) e Secretarias Municipais de Saúde (esfera municipal); a Regionalização tem como objetivo distribuir os serviços de saúde no território de acordo com a necessidade da região, realizando uma organização racionalizada no território; a Participação social ocorre com a participação de Conselhos e Conferências de Saúde afim de garantir uma democracia com a participação popular; por último, a Hierarquização do sistema organiza os fluxos de assistência de acordo com a complexidade do serviço utilizado (CAMPOS et al, 2012), sendo as principais portas de entrada a atenção primária, caracterizada pela Unidade Básica de Saúde (UBS), serviços de urgência e emergência, por exemplo as UPAs e os Centros de Atenção Psicossocial (CAPS) (MOREIRA, 2016).

Atenção Básica de Saúde

A Conferência Internacional de Alma Alta em 1978 foi um marco para diversas reformas nos sistemas de saúde ao redor do mundo, levando mudanças do modelo assistencial e melhor uso de recursos. Uma das principais estratégias atualizadas foi a adoção da Atenção Básica em Saúde e, no caso do Brasil, a Atenção Básica em Saúde se baseia principalmente no Programa Saúde da Família (PSF) (GIL, 2006).

Além disso, a Atenção Básica deve ser a principal porta de entrada para o SUS e a Política Nacional de Atenção Básica a define como um conjunto de ações que levam a promoção e a proteção da saúde, prevenção, diagnóstico, tratamento e reabilitação de enfermidades (BRASIL, 2017). Para sua prática eficiente, é necessário que as equipes de saúde levem em consideração a

dinamicidade da região somadas com as características individuais dos usuários, a fim de resolver as queixas mais frequentes e relevantes do território (TANAKA, 2011).

Unidade de Pronto Atendimento (UPA)

O paciente que procura atendimento de urgência e emergência deve ser atendido em qualquer nível de atenção à saúde (OLIVEIRA, 2015) e ser encaminhado de acordo com a sua necessidade (GARLET et al., 2009). A Unidade de Pronto Atendimento (UPA) nesse contexto com o objetivo de facilitar o fluxo de pacientes e articulação de serviços no sistema de saúde (Ministério da Saúde (BR). Política Nacional de Atenção às Urgências. Brasília (DF): MS; 2006.).

A UPA devem funcionar 24 horas por dia, nos finais de semana e feriados, além de atender pacientes com quadros agudos, realizando a estabilização e o encaminhamento para outros serviços de saúde (BRASIL, 2002). Ademais, é importante, para o serviço na UPA, realizar a classificação de risco para garantir o atendimento rápido para pacientes mais graves (BRASIL, 2002). Uma vez que, segundo Bittencourt e Hortale (2009), a superlotação e, conseqüentemente, atraso no atendimento da UPA podem causar aumento da mortalidade nos serviços de emergência e urgência.

Processamento de imagens

O primeiro registro de processamento de imagens ocorreu com o intuito para melhorar as imagens digitalizadas para jornais. Essas imagens eram enviadas por cabos submarinos de Londres a Nova York na década de 20. Esse sistema se chamava Bartlane. Dessa maneira foi reduzido de mais de uma semana para três horas no transporte de imagens pelo oceano atlântico, conforme a Figura 1, em que é possível ver o resultado dessa transmissão (GONZALEZ, WOODS, 2000).

Figura 1 - Figura digital produzida em 1921.



Fonte: Gonzales e Woods (2000).

A Figura 1 foi construída utilizando-se de um equipamento especial de impressão que codificava as imagens para transmissão via cabo, e eram reconstruídas as imagens em um terminal receptor em uma impressora telegráfica que continha caracteres para simular os tons. Esse método foi evoluindo e foi substituído por uma reprodução fotográfica que é feita a partir de fitas perfuradas

no terminal receptor telegráfico. Os níveis de brilho foram aumentando de 5 para 15 níveis em meados de 1929, trazendo uma melhora em qualidade tonal e resolução.

Após 35 anos de evolução, foi combinado o uso de computadores digitais, como foi o caso do programa espacial, em que foi utilizado o emprego de técnicas de melhoramento de imagens que foram produzidas pela sonda espacial “Ranger 7” em 1964, que corrigiam algumas distorções que eram provenientes da lente da câmera de televisão a bordo (GONZALEZ, WOODS, 2000).

Visão Computacional

A visão computacional ganhou muita ênfase nos últimos anos por causa dos seus grandes avanços, provendo ser uma ferramenta muito eficaz para resolver vários problemas em múltiplas áreas, por exemplo, agronomia, astronomia, biologia, medicina e entre outras, sendo possível aplicar em quase todas as áreas de conhecimento (NEVEZ; VIEIRA NETO; GONZAGA, 2016).

Podemos definir visão computacional como a área de estudo que tenta repassar para máquinas a incrível capacidade de visão. Quando falamos de visão, não estamos nos referindo apenas ao ato de captar imagens. Apesar de essa capacidade ser impressionante (basta que estudemos um pouco sobre o funcionamento de um olho para constatar isso), ela é apenas o início de um processo muito mais vasto e rico. A visão consiste em captar imagens, melhorá-las (por exemplo, com retirada de ruídos, aumento de contraste etc.), separar as regiões ou objetos de interesse de uma cena, extrair várias informações dependendo da imagem analisada, como, por exemplo, forma, cor e textura, e, finalmente, relacionar as imagens com outras vistas previamente (BACKES, SÁ JUNIOR, 2016).


A visão computacional consiste simplesmente em trazer a capacidade para uma máquina de manipular e interpretar determinadas imagens conforme o algoritmo que foi aplicado.

Características Haar

A detecção facial usando as características Haar foi inicialmente explorada por Viola-Jones em seu artigo Robust Real-time Object Detection, em que se tem uma “estrutura de detecção de objetos visuais capaz de processar imagens extremamente rápidas e alcançar altas taxas de detecção” (PAUL VIOLA; MICHAEL JONES, 2001).

O algoritmo é dividido em três partes. A primeira contribuição é a criação da “imagem integral” que usa um conjunto de recursos que lembram a base Haar, a segunda contribuição é a construção de um classificador que usa o AdaBoost para trazer recursos importantes, pois a quantidade de recursos do tipo Harr é muito grande, e a terceira contribuição é uma estrutura em cascata de classificadores mais complexos que aumentam a velocidade do detector, concentrando recursos em uma área mais promissora e evitando falsos-positivos, conforme definidas por Paul Viola e Michael Jones (2001) na Figura 2 abaixo.

Figura 2 - Exemplo de retângulos de características.



Fonte: Viola e Jones (2001).

O item (A) da Figura 2 é uma divisão horizontal, (B) é uma divisão vertical, (C) possui 2 divisões horizontais e a (D) é formada por divisões horizontais e verticais. A soma dos pixels que estão dentro dos retângulos brancos é subtraída da soma dos pixels nos retângulos cinza, segundo definido por Paul Viola e Michael Jones (2001). Dessa maneira será o resultado representado pela característica para a região.

Reconhecimento facial

O reconhecimento facial é uma das várias técnicas utilizadas no contexto de biometria, estabelecendo sua identificação por atributos físicos, neste caso, é levado em consideração algumas características, como formato da boca, do rosto, distância dos olhos, entre outras (SILVA, 2015).

Conforme descreve Silva, um ser humano é capaz de reconhecer alguém familiar, mesmo com muitos obstáculos, como distância, sombras ou visão parcial do rosto, porém, uma máquina precisa realizar um conjunto de processos para fazer esse reconhecimento, sendo necessário extrair as características para fazer a rotulação de uma face conhecida ou não.

Redes Neurais

Na computação as redes neurais são como nós interconectados que procuram simular os neurônios humanos, porém, usando-se de algoritmos para suas predições. A primeira citação de um modelo artificial para um neurônio biológico foi em 1943 por Warren McCulloch e Walter Pitts no artigo *A logical Calculus of the ideas immanet in nervous activity*, em que se explicava como os neurônios deveriam funcionar. Warren e Walter modelaram suas ideias com uma rede neural simples com circuitos elétricos.

As pesquisas de inteligência artificial seguiram crescendo nos anos seguintes, mas o foco inicial era uma rede neural com a capacidade de resolver problemas como um cérebro humano, percebeu-se, porém, que com a eficácia das redes neurais em resolver tarefas específicas, haveria muito mais ganho, não se limitando a uma abordagem totalmente biológica.

No mundo atual, graças a essas mudanças, temos diversas áreas de atuações específicas em que a rede neural soluciona problemas, sendo elas: visão computacional, reconhecimento de fala, diagnósticos médicos e entre outras soluções (SAS, 2020).

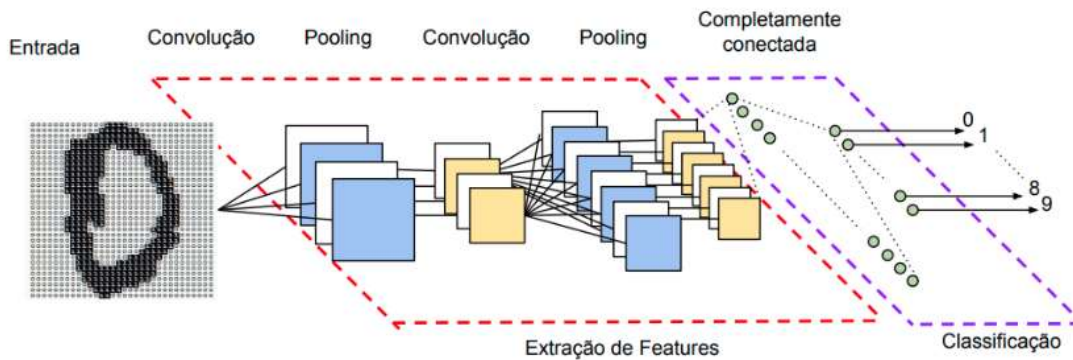
Redes Neurais Convolucionais

A construção de uma Rede Neural Convolutiva é baseada nas redes de Perceptron de Múltiplas Camadas, que, em sua formulação clássica, é um conjunto de neurônios divididos em camadas em que cada neurônio é conectado a todos os outros neurônios da camada anterior. Já em uma Rede Neural Convolutiva, apenas um subconjunto de entradas é conectado a cada neurônio, esse processo tem forte inspiração biológica, tendo inspiração no processamento biológico de dados visuais (VARGAS; PAES; VASCONCELOS, 2016).

O passo inicial para esses estudos ocorreu em 1962 por Hubel e Wiesel, baseado em um experimento em que neurônios eram ativados juntos quando eram expostos a algumas linhas ou curvas, produzindo reconhecimento visual.

A primeira aplicação de uma Rede Neural Convolutiva que teve sucesso foi em 1998, por Yann LeGun. Em sua Rede Neural Convolutiva foram aplicadas 7 camadas entre convoluções e fully connected. Neste ponto em diante, as Redes Neurais Convolucionais ficaram mais complexas e profundas, transformando-as, como a conhecemos hoje (ALVES, 2018), conforme mostra a Figura 3.

Figura 3 - Exemplo de Rede Neural Convolutiva.



Fonte: Vargas, Paes e Vasconcelos (2016).


Na Figura 3 é possível ver uma Rede Neural Convolutiva que se classifica a partir de uma imagem que representa um manuscrito e dizer qual número essa imagem representa.

O item (Entrada) da Figura 3 é uma imagem para o processamento, (Convolução) é a primeira camada da Rede Neural Convolutiva que extrai os recursos da imagem de entrada, ela está presente nas outras camadas. (Polling) faz a redução da imagem para diminuir a quantidade de parâmetros para o treinamento. (Completamente conectados), que é mais conhecido como Fully connected, faz parte da camada de classificação e tem uma quantidade específica de neurônios (VARGAS; PAES; VASCONCELOS, 2016).

Convolução

A camada de Convolução funciona como um filtro, sendo composta por diversos neurônios. A imagem é percorrida em um conjunto de pixels, esse percurso é feito por uma operação chamado Stride, que faz o pulo dos pixels entre cada janela. Cada conexão recebe um peso, que passa a camada seguinte, o peso atribuído a cada neurônio é o diferencial, pois permite que criem filtros ainda mais complexos que aproveita as informações dos dados treinados. A Figura 4 exemplifica esse processo da convolução que percorrer os pixels da imagem (VARGAS; PAES; VASCONCELOS, 2016).

Figura 4 - Exemplo de Convolução.




Fonte: Alves (2018).

O item (Input neurons) da Figura 4 é a imagem de entrada com 28x28 pixels, e o filtro cobre 5x5 pixels, (First hidden layer) é o resultado da filtragem.

Padding

Antes da convolução também temos o Padding, em que podemos, ou não, adicionar alguns pixels ao redor da imagem. A representação dessa borda é por zeros na matriz, dessa maneira, se evita que a imagem reduza mais rápido do que o necessário no aprendizado, conforme a Figura 5 (ALVES, 2018).

Figura 5 – Exemplo de Padding.




Fonte: Elaborado pelo autor.

O item (a) da Figura 5 é uma imagem com 4x3 pixels e um filtro, e stride por 2x2 pixels, com o Padding a imagem está com 4x4 pixels. O item (b) é o resultado da imagem com o padding após a execução do MaxPooling.

ReLU

ReLU é uma função de ativação, existem várias outras, mas a ReLU se tornou computacionalmente melhor. Essa função torna o sistema em não linear, dessa maneira, a rede consegue aprender qualquer funcionalidade, essa função de ativação pega todos os valores negativos da camada anterior e transforma em zero. Matematicamente, o ReLU seria $y = \max(0, x)$, conforme mostrado na Figura 6 (ALVES, 2018).

Figura 6 – Exemplo de ReLU.




Fonte: Clappis (2019).

Pooling

Após o uso da camada de Convolução, é necessário utilizar-se da camada de agrupamento, conhecido como Pooling, essa camada é responsável por reduzir as dimensões. Com o Pooling aplicado, podemos ter mais agilidade no treinamento com o agrupamento de dados, reduzindo a altura e largura de um mapa (VARGAS; PAES; VASCONCELOS, 2016).

Existem alguns tipos de Pooling, sendo eles o MaxPooling, SumPooling e o AveragePooling. Atualmente o mais utilizado é o MaxPooling, esse tipo de Pooling percorre uma determinada região, levando em consideração a operação de Stride, e pega o maior elemento daquela região, conforme a Figura 7 (CLAPPIS, 2019).

Figura 7 - Exemplo de MaxPooling.




Fonte: Clappis (2019).

O item (Single depth slice) da Figura 7 é uma matriz de 4x4 pixels com um Stride de valor 2, o que equivale na matriz a 4 agrupamentos de pixels, cada agrupamento possui 4 valores e o valor maior de cada grupo, respectivamente, é 6, 8, 3 e 4 será o resultado do MaxPooling.

Flatten

Após o mapa em Pooling ser obtido, é feito o achatamento da matriz, transformando-a em um array. O Flatten é a entrada da rede neural tradicional, conforme exemplificado na Figura 8 (CLAPPIS, 2019).

Figura 8 - Exemplo de Flatten.




Fonte: Clappis (2019).

O item (Pooled Feature Map) da Figura 8 é a matriz obtida pela camada de agrupamento Polling, o item (Flattening) é o array obtido pela camada Flatten.

Fully connected

O Fully connected faz parte da camada de classificação. Essa camada fica no final do processo, em que a entrada é a saída da camada anterior, e na saída tem uma quantidade específica de neurônios, conforme a Figura 9 (ALVES, 2018).

Figura 9 - Exemplo de Flatten com Fully connected.



Fonte: Ng et al (2019).

Após a camada de Pooling (Pooling Layers) da Figura 9, é feito o achatamento da camada (Flatten) para servir de entrada ao Fully connected (Fully connected Layers), e sua saída faz a classificação (Output Layer).

Python

Python é uma linguagem de programação simples e com uma curva de aprendizado muito curta, por isso, a sua popularidade em várias áreas, sendo possível criar aplicações muito complexas de maneira bastante fácil e rápida, por exemplo, no âmbito de aprendizado de máquina, pois existem várias bibliotecas disponíveis pela comunidade (Data Science Academy, 2020).

OpenCV

OpenCV é uma biblioteca para visão computacional e aprendizado de máquina de código aberto. Atualmente possui mais de 18 milhões de downloads e é bastante utilizada em empresas, grupos de pesquisa e órgãos governamentais.

Ele possui além de uma interface para Python, também para C++, Java e MATLAB, sendo escrito nativamente em C++ (OpenCV, 2020?).

NumPy

NumPy é uma biblioteca de código aberto desenvolvido em 2005, seu foco é na computação numérica e é mantida por uma comunidade da própria biblioteca e da comunidade científica Python (NumPy, 2020?).

Keras

Keras é uma API construída sobre o TensorFlow 2.0, ela possui uma estrutura robusta no setor de aprendizado de máquina profundo, sendo utilizada por muitas comunidades científicas ao redor do mundo (Keras, 2020?).

TensorFlow

TensorFlow é uma poderosa ferramenta de aprendizado de máquina de código aberto, sendo possível criar modelos facilmente. O TensorFlow utiliza a API do Keras para fazer a definição e treinar as redes neurais (TensorFlow, 2020?).

Matplotlib

Matplotlib é uma biblioteca de criação de gráficos estatísticos para Python, sendo possível ter animações e interatividade (Matplotlib, 2020?).

METODOLOGIA

Essa pesquisa caracteriza-se como uma pesquisa aplicada, em que os conceitos estudados são utilizados em uma aplicação no mundo real para gerar resultados imediatos sobre o tema levantado. A pesquisa aplicada tem como objetivo resolver problemas concretos, tendo um propósito prático e específico para gerar o conhecimento ou o avanço dele (ALEGRIA et al., 2011).

Um dos objetivos específicos dessa pesquisa foi incentivar jovens pesquisadores aplicar os conhecimentos técnicos obtidos na graduação ou na especialização em um problema do mundo real, dentro das comunidades onde eles estão inseridos, permitindo propor soluções imediatas para problemas concretos da sociedade.

A natureza desta pesquisa é de cunho quantitativo. A metodologia quantitativa é qualquer pesquisa que possa ser medida em números, classificada e analisada no estudo. Essa metodologia usa técnicas estatísticas para a elaboração de seus dados, objetivando resultados que não tragam distorções de análise e interpretação, trazendo uma maior margem de segurança (DALFOVO, 2008).

O estudo utilizou ainda a pesquisa bibliográfica, utilizando-se de livros, artigos científicos, matérias jornalísticas, sites oficiais do governo e da área de inteligência artificial. A pesquisa bibliográfica possibilita um amplo alcance de informações, trazendo uma melhor construção a uma definição do quadro conceitual do estudo proposto, sendo necessária leitura para identificar informações e os dados contidos para se ter uma reflexão pessoal e fundamentar teoricamente o objeto de estudo (LIMA; MIOTO, 2020).

Para a elaboração deste trabalho foi desenvolvida uma aplicação que usa os recursos das redes neurais convolucionais e da visão computacional para gerar e visualizar os dados estatísticos obtidos com o objetivo de controlar o fluxo nas unidades de pronto atendimento 24 horas.

O projeto foi desenvolvido no primeiro semestre de 2020, período crítico de pandemia causada pelo Corona vírus (COVID-19), e limitou os testes por questões de segurança ao uso de vídeos contendo pessoas em movimento, mas que fosse possível visualizar a parte frontal do rosto para extração dos dados para o projeto.

Para este projeto foi usado a biblioteca Tensorflow com a linguagem de programação Python 3.6 com uma ferramenta para criação e treinamento de redes neurais. O Tensorflow é uma biblioteca *open source* amplamente usado na comunidade que estuda e trabalha com inteligência artificial.


LEVANTAMENTO DOS DADOS E ANÁLISES

Os dados da pesquisa foram obtidos através do desenvolvimento de um software usando algoritmos baseados em redes neurais convolucionais e visão computacional.

Esse software utilizou um vídeo de setenta e oito segundos como exemplo. Este vídeo contém uma considerável circulação de pessoas, sendo possível testar a detecção facial frontal das pessoas que caminham em direção à câmera, dessa maneira foi possível detectar e mapear cada rosto por faixa etária e sexo, além de guardar a data e horário da detecção.

O desenvolvimento do software permitiu mapear o rosto humano em foto ou vídeo, sendo gravado ou capturado em tempo real, e categorizar cada rosto pela média de idade e sexo. Foram utilizadas, no treinamento da inteligência artificial, imagens de rostos humanos para cada categoria com 48x48 *pixels* em tons de cinza, conforme a Figura 10 abaixo.

Figura 10 - Amostra de imagens utilizadas na categoria de mulher jovem.




Fonte: Biblioteca do Kaggle.com One Million Fake Faces.

Na Figura 10 é possível ver o enquadramento do rosto de cada pessoa do sexo feminino. Foi utilizado a técnica de características *Haar* para o mapeamento do rosto e enquadramento da área de interesse, dessa maneira, o treinamento da rede neural convolucional ficou mais assertiva, pois as características *Haar* detectam o rosto humano e validam se a imagem usada contém ou não um rosto, evitando o uso desnecessário de pixels, por exemplo centralizando o rosto e evitando utilizar o ambiente ao redor.

As características *Haar* são usadas tanto na criação do *dataset* para o treinamento da rede neural convolucional como no mapeamento das imagens que serão utilizadas para validação das categorias definidas. No Gráfico 2 abaixo, é possível avaliar de maneira estatística a divisão das imagens utilizadas por cada categoria no treinamento.

Gráfico 2 - Quantidade de imagens por categoria.



Fonte: Elaborado pelo autor.

O Gráfico 2 apresenta a quantidade de imagens por cada categoria utilizada nesse treinamento, respectivamente, homem idoso, homem adulto, homem jovem, mulher idosa, mulher adulta e mulher jovem; as suas quantidades respectivamente são: 204 imagens para a categoria de homem idoso, 431 para homem adulto, 171 para homem jovem, 185 para mulher idosa, 452 para mulher adulta e 181 para mulher jovem, dando um total de 1624 imagens para a criação do *dataset*.

Tanto no treinamento da rede neural convolucional como na validação, ocorre um processamento de imagens utilizando uma biblioteca na linguagem Python, chamado de OpenCV, ela é responsável por manipular as imagens, fazendo os cortes da área de interesse utilizando as características *Haar*, também convertendo cada imagem para os tons de cinza, dessa maneira o treinamento e as validações ficam mais rápidas, pois a imagem terá apenas uma camada, diferente do RGB que é formado por três camadas. Também são utilizadas outras bibliotecas para auxiliar o OpenCV, por exemplo, a biblioteca NumPY que auxilia na manipulação de *arrays* e matrizes multidimensionais e tem um grande acervo de funções matemáticas. É possível ver os resultados do processamento do OpenCV na Figura 11 abaixo.

Figura 11 - Frame processado com as informações desenhadas.



Fonte: Coletado do vídeo de treinamento.

Conforme a Figura 11 apresenta, é possível ver que o OpenCV também adiciona informações importantes na imagem, como desenhar o quadrado na região do rosto e adicionar textos informativos, por exemplo, o nome da categoria do rosto e a sua porcentagem de acurácia, além de outras informações, como: a velocidade do processamento em tempo real; a quantidade de rostos detectados a cada frame do vídeo ou imagem e a quantidade de cada categoria já cadastrada.

A aplicação foi desenvolvida com a linguagem de programação Python na versão 3.6. Essa linguagem é comumente usada em projetos de inteligência artificial devido suas inúmeras bibliotecas disponíveis pela comunidade, como a biblioteca OpenCV, bastante usada no nosso projeto.

No aprendizado de máquina foi utilizado a biblioteca TensorFlow que é integrada com a biblioteca Keras. Essa biblioteca é responsável pelo treinamento do modelo utilizando-se de redes

neurais convolucionais, além de responsável por carregar um modelo já treinado e validar a imagem processada, gerando a predição que determina qual categoria definida pelo *dataset* pertence a imagem.

Para a exibição dos dados estatísticos e geração de gráficos complexos, foi utilizada a biblioteca Matplotlib, também bastante utilizada pela comunidade científica.

O reconhecimento facial também é utilizado neste projeto para evitar a criação de falsos-positivos quando se detecta um rosto a cada frame, também sendo delimitado que o registro do rosto detectado será adicionado somente caso a sua acurácia seja acima de cinquenta por cento, se não, a imagem será descartada dando início ao próximo rosto detectado no mesmo frame ou no frame seguinte.

Caso a acurácia do rosto seja acima do cinquenta por cento (delimitação usada no nosso projeto), será feita a validação de reconhecimento facial, havendo uma verificação dos pontos de referência do rosto do frame atual com todos os rostos já cadastrados. Caso o rosto do frame atual já tenha o registro salvo, mesmo sendo acima de cinquenta por cento, não haverá o salvamento, dessa maneira, o projeto só salvará cada registro de um rosto detectado caso seja acima de cinquenta por cento de acurácia, e que não tenha sido salvo nenhum registro daquele rosto anteriormente no projeto, assim, não teremos a geração de falsos-positivos, pois, se não tivesse essa validação, poderíamos repetir o registro de um único rosto várias vezes quando o algoritmo percorresse cada frame.

Dependendo da quantidade de imagens utilizadas no aprendizado de máquina é possível ter uma acurácia ainda mais satisfatória. Neste projeto foi possível chegar a uma acurácia de 64% no treinamento com as 1624 imagens. Com essa porcentagem é possível ter uma boa variação na detecção dos rostos e suas categorias.

O vídeo de setenta e oito segundos foi processado às 20 horas, 25 minutos e 44 segundos do dia 27 de maio de 2020, gerando um arquivo de extensão CSV. A Tabela 1 abaixo apresenta uma amostra dos dados coletados.

Tabela 1 – Amostra dos dados coletados dos rostos identificados do vídeo.

TOTAL FACES	CATEGORIA	Probabilidade %	Data	Hora
4	young_female	56.06	27/05/2020	20:25:44
4	young_female	55.14	27/05/2020	20:25:44
2	young_female	54.20	27/05/2020	20:25:44
4	young_female	54.63	27/05/2020	20:25:45
4	young_female	57.23	27/05/2020	20:25:45
4	young_female	56.50	27/05/2020	20:25:46
7	young_female	53.72	27/05/2020	20:25:46
4	young_female	54.99	27/05/2020	20:25:48
4	adult_female	77.69	27/05/2020	20:25:53
4	young_female	52.78	27/05/2020	20:26:02
4	adult_female	93.02	27/05/2020	20:26:02
3	young_male	53.35	27/05/2020	20:26:08
2	young_female	65.44	27/05/2020	20:26:13

Fonte: Elaborada pelo autor.


A Tabela 1 apresenta por linha os registros de vários rostos detectados, validados e inseridos em um arquivo CSV para posterior processamento estatístico.

A primeira coluna apresenta o total de faces, quantidade de rostos que tinham sido encontrados no momento que um deles foi validado e inserido no arquivo CSV, não significando que todo o restante do total de faces da linha tenha sido aprovado na validação. Na segunda coluna temos todas as categorias em inglês que foram encontradas no vídeo naquele momento, também validadas e inseridas no respectivo arquivo de extensão CSV. Na terceira coluna é possível avaliar a probabilidade do rosto que foi validado e inserido. Nenhum dos registros desse vídeo ficou abaixo de 50 %, sendo o menor valor encontrado de 52.78%.

Na quarta coluna temos a data em que o rosto apresentado no vídeo foi validado e inserido no arquivo CVS. E na quinta e última coluna temos a hora, minuto e segundo em que o rosto apresentado no vídeo foi validado e inserido no arquivo CVS. Nota-se que o tempo entre o primeiro registro (20:25:44) e o último (20:27:02) é estimado em setenta e oito segundos.

O Gráfico 3 abaixo, apresenta a distribuição das categorias encontradas no vídeo usado nos testes.

Gráfico 3 - Gráfico do total de categorias do vídeo




Fonte: Elaborado pelo autor.

O Gráfico 3 foi gerado a partir do arquivo CSV, sendo que das 6 (seis) categorias possíveis, só obtivemos nesse vídeo de setenta e oito segundos 4 (quatro) categorias entre as cadastradas.

No Gráfico 4 abaixo, é possível avaliar as taxas de acerto de cada categoria identificada no vídeo teste, isto é, a acurácia por categoria.

Gráfico 4 - Gráfico em barras da Média da probabilidade de cada categoria.




Fonte: Elaborado pelo autor.

Nesse gráfico podemos perceber que nos registros de “Homem adulto” temos 79.32%, sendo essa a maior média entre as 4 (quatro) categorias existentes no vídeo, isso mostra que nessa categoria tivemos uma melhor acurácia na validação do vídeo de setenta e oito segundos. Respectivamente, as categorias com mais assertividade foram: “Homem adulto”; “Mulher adulta”; “Mulher jovem” e “Homem jovem”.

A Figura 12 abaixo, nos mostra a recepção da UPA Franco Silva em Sobral-CE no dia 11/06/2019, uma terça-feira pela manhã antes da pandemia da Covid-19, onde predomina a presença de mulheres adultas e algumas crianças com seus responsáveis. A visão computacional poderá ainda em trabalhos futuros, calcular o distanciamento adequado entre as pessoas nas UPAs, bem como avaliar a capacidade da UPA e medir o tempo do desconforto de pessoas que aguardam o atendimento em pé.

Figura 12 – Atendimento na recepção de uma UPA no estado do Ceará em 2019.



Fonte: Secretaria de Saúde do estado do Ceará, 2019.

CONCLUSÕES

A presente pesquisa teve o objetivo de otimizar o trabalho dos profissionais de saúde que se encontram alocados nas Unidades de Pronto Atendimento 24 horas utilizando-se de visão computacional para o gerenciamento e controle de fluxo de pacientes nessas unidades.

O desenvolvimento desse trabalho foi realizado no primeiro semestre de 2020 em que nos encontrávamos em um período crítico de pandemia causada pela Covid-19, conseqüentemente todos estávamos de quarentena, atendendo os protocolos da vigilância sanitária para garantir a integridade da saúde pública, o que impossibilitou a realização dos testes reais nas próprias unidades. Dessa forma, utilizamos outros recursos disponíveis, no nosso caso, o vídeo de pessoas caminhando em direção a uma câmera, o que tornou o estudo ainda viável e comprovável.

O estudo respondeu ao problema apresentado, ou seja, é possível gerenciar o fluxo de pacientes usando visão computacional, comprovado pelos gráficos estatísticos gerados das categorizações de cada rosto identificado e devidamente cadastrado na tabela de registros, apresentado pela imagem da captação dos rostos que o software gerou.

Um dos principais resultados encontrados neste estudo foi que o treinamento da inteligência artificial mostrou uma forte tendência para a identificação de rostos adultos e masculino, comprovando pela sua acurácia de 79,32% e pela quantidade de registros inferiores de rostos jovens e femininos.

Finalizando, essa pesquisa abre caminho para soluções com inteligência artificial e visão computacional, pois usando criatividade é possível usar essa tecnologia para resolver alguns problemas simples do nosso dia a dia, como no caso dessa pesquisa, controle de fluxo de pessoas, não só nas UPAs, mas também em terminais rodoviários e ferroviários, empresas, eventos e outros órgãos públicos.

Como trabalhos futuros, é possível adaptar a visão computacional para a detecção e reconhecimento facial em tempo real em várias situações, como: na área de segurança pública para identificação de criminosos; ainda na segurança pública para identificação de armas ou drogas em um ambiente específico; ou pelo Recursos Humanos de uma organização para controle de ponto mais inteligente ou análise de sentimentos do funcionário captados pelas expressões faciais dentro da empresa o nível de cansaço no uso de equipamentos de alto risco, entre outras aplicações.

Observa-se que a utilização de visão computacional é muito ampla, podendo ser facilmente adaptada em vários setores, como: segurança pública e privada, indústrias, medicina, civil, militar, entre outros meios. A tecnologia existe, é acessível e precisamos evoluir nesse tema na academia e nas organizações públicas e privadas.

REFERÊNCIAS BIBLIOGRÁFICAS

ALEGRIA, R., ALMEIDA, P., ARATANGY, V., VICTOR, B. Título: Teoria e Prática da Pesquisa Aplicada, Local de publicação: Rio de Janeiro, Elsevier Editora, 2011.

ALVES, Gisely. Entendendo Redes Convolucionais (CNNs), [S.I.] [2018]. Disponível em: <<https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>>. Acesso em: 09 mai. de 2020.

BACKES, André Ricardo, SÁ JUNIOR, Jarbas Joaci, Título: Introdução à Visão Computacional Usando MATLAB, Local de publicação: Rio de Janeiro, Alta Books Editora, 2016.

BRASIL, Ministério da Saúde. Unidade de Pronto Atendimento (UPA 24h): o que é, quando usar, diretrizes e competências, [S.I.] [2020?]. Disponível em: <<https://saude.gov.br/saude-de-a-z/unidade-de-pronto-atendimento-upa-24h>>. Acesso em: 28 abr. de 2020.

CLAPPIS, Alan Melo. Uma introdução as redes neurais convolucionais utilizando o Keras, [S.I.] [2019]. Disponível em: <<https://medium.com/data-hackers/uma-introdu%C3%A7%C3%A3o-as-redes-neurais-convolucionais-utilizando-o-keras-41ee8dcc033e>>. Acesso em: 09 mai. de 2020.

DALFOVO, Michael Samir; LANA, Rogério Adilson; SILVEIRA, Amélia. Título: Métodos quantitativos e qualitativos: um resgate teórico. Revista Interdisciplinar Científica Aplicada, Blumenau, 2008.

Data Science Academy. POR QUE A LINGUAGEM PYTHON É TÃO POPULAR EM MACHINE LEARNING E INTELIGÊNCIA ARTIFICIAL?. [S.I.] [2020]. Disponível em: <<http://datascienceacademy.com.br/blog/por-que-a-linguagem-python-e-tao-popular-em-machine-learning-e-inteligencia-artificial/>>. Acesso em: 24 mai. de 2020.

G1. Pacientes reclamam de espera e mau atendimento em UPAs do RJ, Rio de Janeiro, 22 abr 2015. Disponível em: <<http://g1.globo.com/rio-de-janeiro/noticia/2015/04/pacientes-reclamam-de-espera-e-mau-atendimento-em-upas-do-rj.html>>. Acesso em: 27 abr. de 2020.

GONZALEZ, R.C.; WOODS, R.E. Processamento de imagens digitais. São Paulo: Edgard Blücher, 2000. 1 p.

Keras. Simple, Flexible, Powerful. [S.I.] [2020?]. Disponível em: <<https://keras.io/>>. Acesso em: 24 mai. de 2020.

LIMA, T. C. S., MIOTO, R. C. T. Título: Procedimentos metodológicos na construção do conhecimento científico: a pesquisa bibliográfica. Revista Katálysis, 10 (esp.), Florianópolis, [2007] Disponível em: <https://www.scielo.br/scielo.php?pid=S1414-49802007000300004&script=sci_arttext> Acesso em: 20 mai. de 2020.

Matplotlib. Matplotlib: Visualization with Python. [S.I.] [2020?]. Disponível em: <<https://matplotlib.org/>>. Acesso em: 24 mai. de 2020.

NEVEZ, Luiz Antônio Pereira, VIEIRA NETO, Hugo, GONZAGA, Adilson, Título: Avanços em visão computacional, Omnipax Editora, 2012.

Ng, Wartini & Minasny, Budiman & Montazerolghaem, Maryam & Padarian, José & Ferguson, Richard & Bailey, Scarlett & Mcbratney, Alex. Convolutional neural network for simultaneous prediction of several soil properties using visible/near-infrared, mid-infrared, and their combined spectra. [Geoderma][2019]. Disponível em: <https://www.researchgate.net/figure/Illustration-of-flatten-layer-that-is-connecting-the-pooling-layers-to-the-fully_fig4_334783857> Acesso em: 10 mai. de 2020.

NumPy. About Us. [S.I.] [2020?]. Disponível em: <<https://numpy.org/about/>>. Acesso em: 24 mai. de 2020.

OLIVEIRA, Saionara Nunes de et al. Emergency Care Units (UPA) 24h: the nurses' perception. Texto Contexto - Enferm.,[s.l.], v. 24, n. 1, p.238-244, mar. 2015.

OpenCV. About. [S.I.] [2020?]. Disponível em: <<https://opencv.org/about/>>. Acesso em: 24 mai. de 2020.

PAUL VIOLA, MICHAEL JONES. Robust Real-time Object Detection. Second International Workshop on Statical and Computacional Theories of Vision - Modeling, Learning, Computing and Sampling, 2001.

SAS. Visão Computacional, o que é e qual a sua importância, [S.I.] [2020?]. Disponível em: <https://www.sas.com/pt_br/insights/analytics/computer-vision.html>. Acesso em: 28 abr. de 2020.

SILVA, A. L. & Cintra, M. E Reconhecimento de padrões faciais: Um estudo. In: Encontro Nacional de Inteligência Artificial e Computacional, 2015, Proceedings ENIAC, 224-231, 2015.

TensorFlow. Overview. [S.I.] [2020?]. Disponível em: <<https://www.tensorflow.org/overview>>. Acesso em: 24 mai. de 2020.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: Proceedings of the XXIX Conference on Graphics, Patterns and Images. 2016.

GIL, Célia Regina Rodrigues. Atenção primária, atenção básica e saúde da família: sinergias e singularidades do contexto brasileiro. Cadernos de Saúde Pública, v. 22, p. 1171-1181, 2006.

TANAKA, Oswaldo Yoshimi. Avaliação da atenção básica em saúde: uma nova proposta. Saúde e sociedade, v. 20, p. 927-934, 2011.

Brasil. Ministério da Saúde. Portaria nº 2.436, de 21 de setembro de 2017. Aprova a Política Nacional de Atenção Básica, estabelecendo a revisão de diretrizes para a organização da Atenção Básica, no âmbito do Sistema Único de Saúde (SUS). Brasília, DF: Ministério da Saúde, 2017.

OLIVEIRA, Saionara Nunes de et al. Unidade de Pronto Atendimento-UPA 24h: percepção da enfermagem. *Texto & Contexto-Enfermagem*, v. 24, p. 238-244, 2015.

GARLET, Estela Regina et al. Organização do trabalho de uma equipe de saúde no atendimento ao usuário em situações de urgência e emergência. *Texto & Contexto-Enfermagem*, v. 18, p. 266-272, 2009.

Ministério da Saúde (BR). Portaria n. 2048/GM/MS de 05 de novembro de 2002: Aprova o regulamento técnico dos sistemas estaduais de urgência e emergência. Brasília (DF): MS; 2002.

BITTENCOURT, Roberto José; HORTALE, Virginia Alonso. Intervenções para solucionar a superlotação nos serviços de emergência hospitalar: uma revisão sistemática. *Cadernos de Saúde Pública*, v. 25, p. 1439-1454, 2009.

CAMPOS, Gastão Wagner de Sousa et al. Tratado de saúde coletiva. In: *Tratado de saúde coletiva*. 2017. p. 968 p-968 p.

MOREIRA, T. M. M., et al (Org). *Manual de Saúde Pública*. Salvador: SANAR, 2016