Convolutional Neural Networks and CPAQV 100 pattern for Human Movement Analysis

ISSN: 2178-7514

Guanis de Barros Vilela Junior^{1,2,3}, Carlos Henrique Prevital Fileni^{1,2,3}, Ricardo Pablo Passos^{1,2,3}

Vol. 12 | Nº. 1 | Ano 2020

RESUMO

Um dos tipos de redes neurais artificiais (RNA) mais utilizados para análise de imagens são as Redes Neurais Convolucionais (RNC). **O objetivo** deste artigo é propor a partir do modelo adotado pelo CIFAR, um padrão de super classes e classes para treinamento de RNC para análise do movimento humano chamado de CPAQV 100, desenvolvido por pesquisadores do Centro de Pesquisas Avançadas em Qualidade de Vida (CPAQV). **Métodos:** Foi adotado o padrão do Canadian Institute for Advanced Research - CIFAR) para o desenvolvimento do presente critério de super classes e classes para análise do movimento humano. Na primeira etapa foram definidas as 20 super classes que são grandes conjuntos de atividade física voluntária que apresentam características em comum, como, por exemplo, atividades aquática indoor. O principal critério para criação das super classes foi abranger o maior espectro de diferentes atividades físicas em vários cenários (atividades da vida cotidiana, mundo do trabalho, esportes em geral atividades recreacionais fisicamente ativas, etc.). As classes foram definidas a partir de três critérios: 1) ser atividade física locomotora voluntária; 2) Que o movimento do critério anterior sendo atendido seja praticado por centenas de milhares ou milhões de milhões de pessoas no mundo; 3) Que preferencialmente sejam esportes olímpicos ou que tenham competições mundiais. **Resultados e Discussão:** O CPAQV 100 apresenta a seguinte estrutura: 20 super classes, abrangendo o maior espectro possível, de atividades físicas voluntárias, sendo que o CPAQV 100 apresenta 20 classes e cada classe cinco categorias. **Conclusão:** uma vez definidas as super classes e classes, alcançamos o objetivo de abranger 100 diferentes tipos de atividades físicas, segundo os critérios previamente definidos. É evidente que trata-se da primeira etapa da construção de uma database sobre movimento humano voluntário, que certamente será ampliado nos próximos anos. Mas foi dado o primeiro passo.

Palavras-chave: banco de dados; movimento humano; redes neurais artificiais

ABSTRACT

One of the types of artificial neural networks (ANN) most used for image analysis are Convolutional Neural Networks (RNC). **The objective** of this article is to propose, based on the model adopted by CIFAR, a standard of super classes and classes for training RNC for the analysis of human movement called CPAQV 100, developed by researchers from the Center for Advanced Research in Quality of Life (CPAQV). **Methods:** The Canadian Institute for Advanced Research (CIFAR) standard was adopted for the development of the present hyper-class and class criterion for the analysis of human movement. In the first stage, the hyper classes were defined, which are large sets of voluntary physical activity with common characteristics, such as, for example, indoor water activities. The main criterion for creating the hyper classes was to cover the widest spectrum of different physical activities in various scenarios (activities of daily life, world of work, sports in general, physically active recreational activities, etc.). The classes were defined based on three criteria: 1) being voluntary locomotor physical activity; 2) That the movement of the previous criterion being met is practiced by hundreds of thousands or millions of millions of people in the world; 3) Which are preferably Olympic sports or have world competitions. **Results and Discussion:** The CPAQV 100 has the following structure: 20 super classes, covering the largest possible spectrum, of voluntary physical activities, with the CPAQV 100 presenting 20 classes and each class five categories. **Conclusion:** once the super classes and classes are defined, we reach the goal of covering 100 different types of physical activities, according to the previously defined criteria. It is evident that this is the first stage of building a database on voluntary human movement, which will certainly be expanded in the coming years. But the first step was taken.

Keywords: database; human movement; Artificial neural networks

1 Programa de Pós Graduação Ciências do Movimento Humano da Unimep, Piracicaba-SP

2 Centro de Pesquisas Avançadas em Qualidade de Vida(CPAQV), Campinas-SP

3 Nucleo de Pesquisa em Biomecânica Ocupacional e Qualidade de Vida(NPBOQV), Unimep/CNPq

Autor de correspondência

Guanis de Barros Vilela Junior

Rod. Açúcar, km 52

Campus Taquaral, Piracicaba-SP

E-mail: Guanis.Junior@unimep.br

DOI: doi.org/10.36692/cpaqv-v12n1-0

INTRODUÇÃO

As Redes Neurais Convolucionais (RNC) são bastante eficientes em reconhecer imagens do corpo humano em situações clínicas, como exames por imagens, tais como, RX, ultrassom, tomografia, dentre outras. Entretanto, para análise do movimento humano não existe nenhuma padronização de super classes e classes que constituam em um banco de dados disponível publicamente que padronize as mais diversas situações locomotoras humanas, nas atividades cotidianas, laborais, recreativas e esportivas.

Um dos desafios da automatização do reconhecimento de imagens relativas ao movimento humano e imagens de diagnóstico (fotos ou vídeos) na inteligência artificial, especialmente nas redes neurais convolucionais é a padronização das super classes e classes

Nogovitsyn et al ⁽¹⁾ utilizaram Redes Neurais Artificiais (RNC) para averiguar sua eficiência no mapeamento do hipocampo em sujeitos saudáveis uma vez que pequenas alterações no volume do hipocampo podem ocorrer durante processos fisiológicos e fisiopatológicos. Tal mapeamento usualmente é manual e demorado, e as RNC têm potencialidade para diminuir este tempo e aumentar a precisão. No estudo, compararam a RNC de Thyreau et al ⁽²⁾ com a avaliação manual em 200 sujeitos em intervalos de semanas até 12 meses. Foi constatado alto nível de reprodutibilidade e estabilidade de medidas volumétricas do hipocampo, que sabidamente está associado a neuropatologias como déficit

cognitivo e Alzheimer. A principal vantagem da utilização foi a redução do tempo gasto para determinação do volume do hipocampo, que no modo manual, requer por volta de 16 horas por imagem de um profissional treinado, ao passo que a RNC realiza mesma tarefa em 20 segundos, ou seja, mais de 2800 vezes mais veloz, com elevada acurácia.

Yang et al ⁽³⁾ ao desenvolver um sistema de processamento de linguagem natural que identifique relações de medicamentos com eventos adversos a medicamentos nas narrativas clínicas, comparou uma RNC com uma rede neural recorrente (RNR) de memória de longo prazo. Em seus estudos, a RNC se mostrou mais eficiente que a RNR.

Suganya et al ⁽⁴⁾ utilizou uma RNC de duas camadas para diagnóstico de cirrose em imagens de ultrassom que apresentou acurácia de 100% na identificação e classificação de pacientes com cirrose.

Avci et al ⁽⁵⁾, Oh et al ⁽¹³⁾ utilizaram uma RNC para detectar vibrações através de redes wireless em estruturas, como edifícios, pontes, viadutos e residências em zonas de risco, uma vez que são comuns desabamentos decorrentes de chuvas fortes e/ou fadiga de materiais, muitos dos quais levam centenas de pessoas a óbito. A RNC, mostrou-se elevada confiabilidade em prever situações de risco para tais estruturas. Portanto o sistema pode acionar alertas e a defesa civil em situações onde cada minuto pode fazer muita diferença.

Kiranyaz et al ⁽⁶⁾ utilizaram a praticidade de usar uma RNC unidimensional, pois estas, em oposição às 2D, não precisam de tratamento prévio dos dados e nem do big data para evitar o problema do overfitting, podendo trabalhar com dados brutos. As conhecidas limitações de processamento de RNC 2D em tempo real em dispositivos portáteis (exemplo, smartphones) é de fato um problema para análise de imagens e vídeos. Os autores, utilizaram a Discrete Fourier Transform (DFT) cujos sinais foram concatenados em uma matriz para alimentar uma RNC capaz de detectar e classificar arritmias em sinais de eletrocardiograma (ECG); os resultados mostraram que a RNC-1D foi capaz de identificar em tempo real 100% das arritmias cardíacas.

Cai et al ⁽⁷⁾ ao pesquisar dropouts mais eficientes em RNC, utilizaram a referência do Canadian Institute for Advanced Research (CIFAR) 10 e 100 ⁽⁸⁾ para treinar a machine learning. A tabela 1 mostra as super classes e classes utilizadas no CIFAR 100 para identificar imagens em RNC.

O objetivo deste artigo é propor a partir do modelo adotado pelo CIFAR, um padrão de super classes e classes para treinamento de RNC para análise do movimento humano chamado de CPAQV 100, desenvolvido por pesquisadores do Centro de Pesquisas Avançadas em Qualidade de Vida (CPAQV).

MÉTODOS

Para o desenvolvimento do padrão CPAQV 100 para análise do movimento humano

três pesquisadores em Ciências do Movimento Humano elaboraram coletivamente quais seriam os critérios para definição das 20 super classes, 20 classes e 100 categorias. Para isto foi adotado como referência o CIFAR 100 mostrado na tabela 1, uma vez que o mesmo é amplamente utilizado em pesquisas com redes neurais convolucionais.

Tabela 1 - CIFAR 100 utilizado para treinamento de RNC

Super classe	Classes
mamíferos aquáticos	castor, golfinho, lontra, foca, baleia
peixes de aquário	peixes, chatos, raia, tubarão, truta
flores	orquídeas, papoulas, rosas, girassóis, tulipas
recipientes para alimentos	garrafas, tigelas, latas, copos, pratos
frutas e legumes	maças, cogumelos, laranjas, peras, pimentões
dispositivos elétricos domésticos	relógio, teclado computador, lâmpada, telefone, tv
móveis para casa	cama, cadeira, sofá, mesa, guarda-roupa
insetos	abelha, besouro, borboleta, lagarta, barata
grandes carnívoros	urso, leopardo, leão, tigre, lobo
grandes construções ao ar livre	ponte, castelo, casa, estrada, arranha-céu
grandes cenas naturais ao ar livre	nuvem, floresta, montanha, planície, mar
grandes onívoros e herbívoros	camelo, gado, chimpanzé, elefante, canguru
mamíferos de tamanho médio	raposa, porco-espinho, gambá, guaxinim, gambá
invertebrados não insetos	caranguejo, lagosta, caracol, aranha, verme
peças	bebê, menino, menina, homem, mulher
répteis	crocodilo, dinossauro, lagarto, cobra, tartaruga
pequenos mamíferos	hamster, rato, coelho, musaranho, esquilo
árvores	bordo, carvalho, palma, pinheiro, salgueiro
veículos 1	bicicleta, ônibus, motocicleta, caminhonete, trem
veículos 2	cortador de grama, foguete, bonde, tanque, trator

São elencadas na Tabela 2 a referência do CPAQV 100 para ilustrar o padrão de imagens do movimento humano em diferentes contextos, que serão disponibilizadas em futuros trabalhos nos formatos binário, matricial, dentre outros.

Os critérios para definição das super classes e classes foram:

Que o movimento humano apresentado na imagem seja claramente intencional, realizado voluntariamente pela musculatura esquelética do aparelho locomotor humano.

Que o movimento do critério anterior seja atendido e praticado por centenas de milhares ou milhões de milhões de pessoas no mundo.

Que preferencialmente sejam esportes olímpicos ou que tenham competições mundiais.

O conjunto de dados CPAQV 100 para análise do movimento humano consiste em 100000 (cem mil) imagens coloridas 32x32 distribuídas em 20 super classes, cada uma com 5000 (cinco mil) imagens. Cada superclasse se divide em cinco classes, compondo portanto, 1000 imagens distintas para cada elemento de cada classe.

Propondo o padrão CPAQV 100 para análise do movimento humano, Todos os dados para criação e validação do padrão CPAQV 100 será coletados por pesquisadores do Núcleo de Pesquisas em Biomecânica Ocupacional e Qualidade de Vida (NPBOQV) e do Centro de Pesquisas Avançadas em Qualidade de Vida (CPAQV).

O conjunto de dados CPAQV 100

O CPAQV 100 passará por uma fase de treinamento com 60000 imagens de treinamento e 40000 imagens de teste por categoria. As 100 classes no CPAQV-100 estão agrupadas em 20 super classes. Cada imagem vem com um rótulo “específico” (a classe à qual pertence) e um rótulo “genérico” (a superclasse à qual pertence).

A tabela 02 mostra as super classes e classes que compõem o CPAQV 100.

Super classes

Esporte de Campo
Esporte de Quadra
Esporte de Combate
Esporte de Aquáticos Indoor
Esporte de Aquáticos Outdoor
Atividades Física Cotidianas Gerais
Corrida de Rua
Atletismo
Exercícios Membros Inferiores
Exercícios Membros Superiores
Esporte na Natureza
Treinamento Funcional
Cross fit
GAP
Dança
Alongamento com movimento articular voluntário
Body pump
Atividades Alternativas
Atividades físicas domésticas
Atividades físicas no trabalho

Classes

Golf, Futebol, futebol de areia, Rugby, volei de areia

Tenis, futsal, basquete, volei, badminton

Jiu-jitsu, judo, karate, taekwondo, boxe

Natação, polo, nado sincronizado, salto ornamentais, hidroginástica

Natação, mergulho, surf, remo e canoagem

Caminhar, correr, saltar, subir escadas, rastejar

5 km, 10km, 15km, Meia maratona, Maratona

100 m, 200 m, 400 m, 800 m, 1500 m

Avanço, Agachamento, pular corda, box jump, squat sumo.

Flexão de braço, barra fixa, desenvolvimento com barra ou halter, tríceps banco, supino.

Escalada, rapel, rafting, tirolesa, trekking

Burpee, swing com kettlebell, remada baixa trx, stiff com barra ou halter, jump high knees.

Front squat, deadlift, air squat, muscle up, push press.

Elevação de quadril em ponte, abdominal borboleta, glúteo em prancha, passa plyo alternada, agachamento drop.

Ballet, Street dance, Valsa, tango, samba

Gastrocnêmio, quadríceps, tríceps, ombro, isquiotibial.

Agachamento barra, supino, remada alta, levantamento terra, remada curvada.

Yoga, pilates, riverdance, pedalar, atividades recreativas

Varrer, fazer faxina, lavar louça, cortar grama, passar roupa

Empurrar, arrastar, puxar, levantar, digitar,

Treinamento do CPAQV 100

A fase de treinamento refere-se a etapa da rede neural convolucional (RNC) onde o algoritmo aprende a identificar e classificar diferentes imagens. Para isto, usualmente, em imagens coloridas é utilizado o color filter array (CFA) Bayer, para adequar a imagem ao padrão RGB que posteriormente será vetorizada.

Treinar o algoritmo, ensinar com imagens o que é cada movimento (correr, pedalar, saltar, dentre outras). Quanto mais imagens diferentes executando o mesmo movimento tiver, melhor será o algoritmo para análise do movimento humano.

Na figura 1 e na tabela 2 é apresentado o modelo de treinamento e teste das Super classes, classes e suas respectivas categorias. No total das 20 super classes teremos 20 classes, possuindo 5 categorias cada, dando um total de 100 categorias.

Tabela 03 - Divisão do CPAQV 100

NOME	QUANTIDADE
Superclasse	20 (tendo 20 classes)
Classes	20 (tendo 100 categorias)
Categorias	100 (tendo 1000 imagens cada)

Figura 01 - Fluxograma CPAQV 100, teste de cada categoria.

RESULTADOS E DISCUSSÃO

Alawad et al ⁽⁹⁾ utilizou a RNC para fazer extração automática de informações reportáveis do registro de câncer a partir de relatórios patológicos de texto livre, obtendo precisão de classificação superior para suportar a codificação automatizada de documentos de patologia para uma variedade de cânceres e múltiplas tarefas de extração de informações, mantendo tempos de treinamento e inferência semelhantes aos de um único modelo de tarefa específica.

Nos estudos de Hatamzadeh et al ⁽¹⁰⁾ indica que o sistema especialista projetado é capaz de diagnosticar o estado de saúde do Ligamento cruzado anterior (LCA) com precisão de 95,8%. Nesse método não invasivo, as imagens pseudo Wigner–Ville distribution (PWVD) dos sinais eletromiográficos (EMG) são escolhidas como entradas do deep convolutional neural network (DCNN), em vez das imagens de ressonância magnética, que, além de sua alta precisão no

diagnóstico, são mais seguras e muito mais baratas.

Sanderson et al ⁽¹¹⁾, analisaram se os modelos de redes neurais recorrentes, redes neurais convolucionais unidimensionais e árvores por gradiente podem melhorar o desempenho das previsões de morte por suicídio, usando dados administrativos do sistema de saúde, os modelos desenvolvidos neste estudo mostraram-se promissores, porém, mais pesquisas são necessárias para determinar os limites de desempenho dos modelos estatísticos e de machine learning que quantificam o risco de suicídio para desenvolver modelos de previsão otimizados para implementação em contextos clínicos.

Radhika et al. ⁽¹²⁾ têm dado contribuições importantes para o reconhecimento biométrico em quaisquer situações, uma vez que vários métodos de reconhecimento de imagens, requerem um nível de controle na aquisição

das mesmas, por exemplo, plano de captura, condições de iluminação, objetos diversos no fundo da imagem, dentre outras. Nesta pesquisa desenvolveram uma RNC que foi comparada com outras quatro redes pré treinadas para o mesmo fim, identificar a orelha dos sujeitos. O principal desafio foi a seleção da arquitetura apropriada de deep learning para o reconhecimento irrestrito das orelhas. O resultado de rede desenvolvida (NASNet) através da otimização de células selecionadas constituiu uma mudança de paradigma na área.

Mohagheghi et al. ⁽¹⁴⁾ identificaram como objeto de estudo a segmentação hepática 3D e utilizaram um modelo de RNC de ponta e a aprimoraram para dados específicos, adequando sua arquitetura, algoritmo de otimização, funções de ativação e o número de filtros de convolução. Como resultado conseguiram utilizar menos dados no treinamento quando comparado a outros métodos.

Demir et al ⁽¹⁵⁾ em seu estudo se concentra no diagnóstico automático de doenças pulmonares utilizando RNC, na primeira abordagem, utilizou-se um modelo de RNC pré-treinado para extração de características e um classificador de máquina de vetores de suporte (SVM) na classificação dos sons pulmonares, na segunda abordagem, o modelo RNC profundo pré-treinado foi sintonizado (transferência de aprendizado) via imagens de espectrograma para classificação do som pulmonar. As precisões dos métodos propostos foram testadas usando

a validação cruzada de dez vezes. As precisões para o primeiro e o segundo métodos propostos foram de 65,5% e 63,09%, respectivamente. Os resultados encontrados podem ser classificados como satisfatórios em comparação com outros estudos.

Tais estudos mostram claramente a tendência de uma super especialização das RNC, dadas as peculiaridades de cada objeto de estudo. Tal tendência corrobora a presente pesquisa, pois, como já vimos, trata-se de um primeiro passo para a consolidação de um big data com imagens relativas ao movimento humano, que estimamos, em alguns anos chegar na ordem de centenas de milhões de imagens que contemplam cada uma das classes de movimentos locomotores voluntários definidas no CPAQV 100.

A tabela 4 mostra a primeira versão do CPAQV 100, suas super classes e classes.

Trata-se, é importante ressaltar, de uma iniciativa que deve ser pensada numa perspectiva orgânica, ou seja, plantamos aqui a célula germinal do CPAQV 100, que com as sinergias necessárias entres diferentes centros de pesquisas, consolidará o big data com conjunto de dados pré tratados sobre o movimento humano que será disponibilizado para a comunidade científica mundial, isto facilitará em muito, as pesquisas com RNC em suas diversas arquiteturas.

SUPER CLASSE			CLASSE E SUAS CATEGORIAS
ALONGAMENTO	COM	MOVIMENTO	Gastrocnêmio, Quadriceps, Triceps, Ombro, Isquiotibial.
ARTICULAR	VOLUNTÁRIO		
ATIVIDADES ALTERNATIVAS			Yoga, Pilates, Riverdance, Pedalar, Atividades Recreativas
ATIVIDADES FÍSICA COTIDIANAS GERAIS			Caminhar, Correr, Saltar, Subir Escadas, Rastejar
ATIVIDADES FÍSICAS DOMÉSTICAS			Varrer, Fazer Faxina, Lavar Louça, Cortar Grama, Passar Roupas
ATIVIDADES FÍSICAS NO TRABALHO			Empurrar, Arrastar, Puxar, Levantar, Digitar,
ATLETISMO			100 M, 200 M, 400 M, 800 M, 1500 M
BODY PUMP			Agachamento Barra, Supino, Remada Alta, Levantamento Terra, Remada Curvada.
CORRIDA DE RUA			5 Km, 10km, 15km, Meia Maratona, Maratona
CROSSFIT			☐ Front Squat, Deadlift, Air Squat, Muscle Up, Push Press
DANÇA			Ballet, Street Dance, Valsa, Tango, Samba
ESPORTE DE AQUÁTICOS INDOOR			Natação, Polo, Nado Sincronizado, Salto Ornamentais, Hidroginástica
ESPORTE DE AQUÁTICOS OUTDOOR			Natação, Mergulho, Surf, Remo E Canoagem
ESPORTE DE CAMPO			Golf, Futebol, Futebol De Areia, Rugby, Volei De Areia
ESPORTE DE COMBATE			Jiu-jitsu, Judo, Karate, Taekwondo, Boxe
ESPORTE DE QUADRA			Tenis, Futsal, Basquete, Volei, Badminton
ESPORTE NA NATUREZA			Escalada, Rapel, Rafting, Tirolesa, Trekking
EXERCÍCIOS MEMBROS SUPERIORES			Flexão De Braço, Barra Fixa, Desenvolvimento Com Barra Ou Halter, Triceps Banco, Supino.
EXERCÍCIOS MEMBROS INFERIORES			Avanço, Agachamento, Pular Corda, Box Jump, Squat Sumo.
GAP			Elevação De Quadril Em Ponte, Abdominal Borboleta, Glúteo Em Prancha, Passa Plyo Alternada, Agachamento Drop.
TREINAMENTO FUNCIONAL			Burpee, Swing Com Kettlebell, Remada Baixa Trx, Stiff Com Barra Ou Halter, Jump High Knees.

Vilela Junior ⁽¹⁶⁾ mostra detalhadamente as etapas de uma RNC destacando-o suas características, aplicabilidade, funções de ativação e limitações das mesmas em relação a capacidade de processamento à medida que o número de camadas ocultas aumenta.

CONCLUSÃO

O banco de dados relativos à imagem referentes ao movimento humano voluntário, CPAQV 100, conterà inicialmente, 100 mil imagens, tratadas para serem utilizadas em redes neurais artificiais convolucionais, ou até mesmo, outros tipos de redes neurais. É evidente que este número é pequeno diante dos milhões de movimentos e contextos diferentes, mas, a proposta, é que o mesmo seja permanentemente alimentado pelos pesquisadores do CPAQV e de instituições parceiras.

REFERÊNCIAS

1. Nogovitsyn et al. (2019). Testing a deep convolutional neural network for automated hippocampus segmentation in a longitudinal sample of healthy participants. *NeuroImage*. 197 589-597.
2. Thyreau et a. (2018). Segmentation of the hippocampus by transferring algorithmic knowledge for large cohort processing. *Medical image analysis volume 43*.
3. Yang et a. (2019). Identifying relations of medications with adverse drug events using recurrent convolutional neural networks and gradient boosting. *Journal of the American Medical Informatics Association*. 0(0), 2019, 1–8 doi: 10.1093/jamia/ocz144
4. Suganya et al. (2019). An efficient categorization of liver cirrhosis using convolution neural networks for health informatics. *Cluster Computing*. <https://doi.org/10.1007/s10586-017-1629-2>
5. Avci et al. (2020). Convolutional Neural Networks for Real-Time and Wireless Damage Detection. https://doi.org/10.1007/978-3-030-12115-0_17
6. Kiranyaz et al. (2019). 1-D Convolutional Neural Networks for Signal Processing Applications. *IEEE* 978-1-5386-4658-8/18/.
7. Cai et al. (2019). Effective and Efficient Dropout for Deep Convolutional Neural Networks. *arXiv:1904.03392v3*.
8. CIFAR - Canadian Institute for Advanced Research. (2020). <https://www.cifar.ca/>
9. Alawad et al. (2019). Automatic extraction of cancer registry reportable information from free-text pathology reports using multitask convolutional neural networks *Journal of the American Medical Informatics Association*, 0(0), 1–10
10. Hatamzadeh M, et al. (2019). A new method of diagnosing athlete's anterior cruciate ligament health status using surface electromyography and deep convolutional neural network. *Biocybern Biomed Eng* (2019), <https://doi.org/10.1016/j>.
11. Sanderson et al. (2020). Predicting death by suicide using administrative health care system data: Can recurrent neural network, one-dimensional convolutional neural network, and gradient boosted trees models improve prediction performance? *Journal of Affective Disorders*. 264 107-114
12. Radhika, K. et al (2020). Performance Analysis of NASNet on Unconstrained Ear Recognition. In *Studies in Computational Intelligence*. Springer.
13. Oh et al. (2020). Convolutional neural network-based data recovery method for structural health monitoring. *Structural Health Monitoring*. 1–18 <https://doi.org/10.1177/1475921719897571>
14. Mohagheghi, S. et al. (2020). Improving the Performance of Deep CNNs in Medical Image Segmentation with Limited Resources. In *Deep Learning in Healthcare*. Chen, Y.W. (org.) Springer

Nature Switzerland AG.

15. Demir et a. (2020). Convolutional neural networks based efficient approach for classification of lung diseases. 8:4 <https://doi.org/10.1007/s13755-019-0091-3>

16. Vilela Junior, G. B; (2020). Passos, R. P. (Org). Inteligência Artificial nas Ciências da Saúde. 1 ed. - Campinas, Editora CPAQV.

OBSERVAÇÃO: Os autores declaram não existir conflitos de interesse de qualquer natureza.

O pesquisador M.Sc Ricardo Pablo Passos é bolsista da CAPES.