



Identificação da Doença de Parkinson com Aprendizado Profundo: uma revisão integrativa

Deep Learning Parkinson's Disease Identification: an integrative review

Identificación de la enfermedad de Parkinson por Aprendizaje Profundo: una revisión integradora

Anne de Souza Oliveira¹, João Victor Campos de Negreiro², Cícero Ferreira Fernandes Costa Filho³, Marly Guimarães Fernandes Costa⁴

RESUMO

Descritores: Doença de Parkinson; Smartphone; aprendizado profundo

Objetivo: Buscou-se identificar e analisar os trabalhos científicos que tratam da identificação precoce da doença de Parkinson em propostas que associam uso de *smartphones* e aprendizagem de máquina profundo. **Métodos:** A busca foi realizada nas bases de dados *IEEE Xplore Digital Library*, *Web of Science* e *PubMed*. Dos 9 artigos identificados no *IEEE Xplore*, dos 7 identificados na base do *Web of Science* e dos 8 identificados no *PubMed*, após as fases de triagem e aplicação de critérios de exclusão, restaram 10 artigos. Desses 10, 4 foram publicados em revistas científicas e 6 em conferências, no período de 2018 a 2020. **Resultados:** Após análise dos artigos, verificou-se a existência de duas abordagens de identificação da doença de Parkinson: a identificação da doença, no estágio inicial, por meio da voz e a identificação da doença, em um estágio mais avançado, por meio dos sintomas motores. Com relação ao tipo de arquitetura de aprendizagem de máquina, a maioria dos trabalhos usou redes neurais convolutivas. Apenas três trabalhos utilizaram redes neurais recorrentes. **Conclusões:** Permanece ainda o desafio, em face das limitações de *hardware* e poder computacional, a possibilidade de embarcar o método de aprendizado profundo em *smartphones*.

ABSTRACT

Keywords: Parkinson's Disease; Smartphone; Deep Learning

Objective: To identify and analyze the scientific studies that deal with the early identification of Parkinson's disease in proposals that associate the use of smartphones and deep learning. **Methods:** The search was carried out in the *IEEE Xplore Digital Library*, *Web of Science* and *PubMed* databases. Of the 9 papers identified in the *IEEE Xplore*, the 7 identified in the *Web of Science* and the 8 identified in the *PubMed*, after the screening and application of exclusion criteria, 10 paper remained. Of these 10, 4 were published in journals and 6 in conferences proceedings, from 2018 to 2020. **Results:** After analyzing the papers, it was found that there are two approaches to identify Parkinson's disease: the identification of the disease, at the stage initial, through the voice and the identification of the disease, in a more advanced stage, through the motor symptoms. Regarding the type of machine learning architecture, most studies used convolutional neural networks. Only three studies used recurrent neural networks. **Conclusions:** The challenge of the Deep Learning embedded on smartphones still remains, in face of the limitations of hardware and computing power of the smartphones.

RESUMEN

Descriptores: Enfermedad de Parkinson; Teléfono Inteligente; Aprendizaje Profundo

Objetivo: Identificar y analizar los estudios científicos que abordan la identificación temprana de la enfermedad de Parkinson en propuestas que asocian el uso de teléfonos inteligentes y el aprendizaje profundo. **Métodos:** La búsqueda se realizó en las bases de datos *IEEE Xplore Digital Library*, *Web of Science* y *PubMed*. De los 9 artículos identificados en el *IEEE Xplore*, los 7 identificados en la *Web of Science* y los 8 identificados en lo *PubMed*, tras la selección y aplicación de los criterios de exclusión, quedaron 10 artículos. De estos 10, 4 fueron publicados en revistas y 6 en congresos, de 2018 a 2020. **Resultados:** Tras analizar los trabajos, se encontró que existen dos enfoques para identificar la enfermedad de Parkinson: la identificación de la enfermedad, en la etapa inicial, a través de la voz y la identificación de la enfermedad, en una etapa más avanzada, a través de los síntomas motores. En cuanto al tipo de arquitectura de aprendizaje profundo, la mayoría de los estudios utilizaron redes neuronales convolucionales. Solo tres estudios utilizaron redes neuronales recurrentes. **Conclusiones:** el desafío del *Deep Learning* integrado en los teléfonos inteligentes aún permanece, dadas las limitaciones del hardware y la potencia informática de los teléfonos inteligentes.

¹ Aluna de doutorado em Engenharia Elétrica, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

² Aluno de mestrado em Engenharia Elétrica, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil

³ Professor Titular do Departamento de Eletrônica e Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

⁴ Professora Titular do Departamento de Eletrônica e Computação da Faculdade de Tecnologia, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

INTRODUÇÃO

Os distúrbios neurológicos são a principal causa de incapacidade no mundo⁽¹⁾. Entre esses distúrbios neurológicos, o que mais cresce é a doença de Parkinson (DP), cujo crescimento está superando o da doença de Alzheimer⁽¹⁾. O Estudo da Carga Global da Doença estima que 6,2 milhões de pessoas atualmente são acometidos dessa doença. De 1990 a 2015, a prevalência, a incapacidade e, em consequência, as mortes por conta do Parkinson mais do que dobrou⁽¹⁾.

Como a incidência do Parkinson aumenta agudamente com a idade e, considerando que a população mundial está envelhecendo, o número de indivíduos afetados está prestes a crescer exponencialmente. Segundo Dorsey e Bloem⁽²⁾, ao se aplicar os dados de prevalência mundial de uma meta-análise de 2014⁽³⁾ às projeções da população futura do mundo⁽⁴⁾, o número de pessoas com Parkinson em 2040 será de 14,2 milhões. Os referidos autores mencionam que independentemente da precisão dessa projeção, se a DP fosse uma doença infecciosa, seria corretamente considerada como uma pandemia de DP⁽²⁾.

A doença de Parkinson é uma doença degenerativa associada a diversos espectros de sintomas, dentre os quais, citam-se: lentidão de movimento (bradicinesia), rigidez, tremor em repouso, instabilidade ao caminhar, problemas na voz, dificuldades de engolir e dificuldades relacionadas ao sono. A maioria dos sintomas não são óbvios no estágio inicial e vão crescendo gradualmente. Assim, a detecção precoce da DP é em geral difícil. Embora a DP não possa ser completamente curada, a detecção e tratamento precoces podem beneficiar os pacientes através do alívio de sintomas e do aumento de expectativa de vida⁽⁵⁻⁶⁾.

A rotina de um paciente com DP deve incluir o acompanhamento de um neurologista, através de consultas periódicas (a cada 3-6 meses). Nessas oportunidades o médico realiza exames motores que avaliam principalmente, os membros inferiores e superiores do corpo, com o fim de estimar a gravidade da doença e os efeitos dos medicamentos, para possíveis ajustes de medicação. Entretanto, na consulta o médico testemunha apenas uma pequena parte das funções diárias do paciente. Por exemplo, nesse cenário único de acompanhamento o médico não consegue monitorar como o paciente responde aos medicamentos prescritos, pois ele só tem acesso ao relato do paciente, o qual pode não ser confiável, especialmente se o paciente sofre de demência, uma comorbidade frequentemente associada à DP. Outro problema relativo a referido cenário, conforme relatado em⁽⁷⁾ é a adesão (ou conformidade) ao medicamento (dosagem correta, nos intervalos corretos), pois doses inferiores às prescritas podem não gerar os efeitos terapêuticos necessários e doses muito grandes podem causar efeitos colaterais adversos⁽⁸⁾.

Segundo Dorsey e Bloem⁽²⁾, o acesso aos cuidados para DP é limitado. Em nações ricas como os Estados Unidos, mais de 40% dos indivíduos com mais de 65 anos com DP não consulta um neurologista e aqueles que não o fazem têm maior probabilidade de cair, ser internados em uma enfermaria especializada e morrer. Da mesma forma, uma pesquisa *on-line* em 35 países europeus mostrou que 40%

dos entrevistados nunca havia consultado um especialista em DP. Em nações menos ricas, muitos nunca são diagnosticados. Em um estudo porta a porta na Bolívia, nenhum dos indivíduos com DP jamais foi diagnosticado ou recebeu tratamento. Mesmo em países com especialistas, a demanda por atendimento excede a oferta⁽²⁾.

Nesse contexto o uso de tecnologias móveis, como os *smartphones* que, atualmente, são mais um dispositivo inteligente que uma simples ferramenta de comunicação, pois interagem com vários sensores (câmera, microfone, acelerômetro, giroscópio, etc.), pode ser um aliado tanto para os médicos (ao viabilizar o acesso a mais informações colhidas fora do ambiente de consultório) quanto ao pacientes, posto que permite um contato mais estreito com o médico.

Muitos são os trabalhos publicados que tratam da detecção e monitoramento da doença de Parkinson utilizando tecnologias móveis, conforme Zhang e colaboradores analisam⁽⁹⁾.

Associadas ao uso das mais modernas tecnologias móveis as propostas de sistemas de detecção e monitoramento, são implementadas a partir de algoritmos de aprendizado de máquinas (embarcados ou não nos celulares). Nosso interesse nesse trabalho, restringe-se a revisar os trabalhos científicos que tratam da identificação precoce da doença de Parkinson em propostas que associam uso de *smartphones* a métodos de aprendizado profundo (última geração de aprendizagem de máquina), buscando avaliar como essa associação está sendo operacionalizada, uma vez que devido à limitação da capacidade computacional e também da bateria dos celulares, embarcar um modelo de detecção de DP baseado em aprendizado de máquina profundo é ainda um desafio. Adicionalmente, buscaremos identificar bases de dados que viabilizem a comparação entre métodos de aprendizagem profunda em aplicações de detecção precoce de DP.

MÉTODOS

Foi realizada uma revisão integrativa com o objetivo de responder a seguinte questão de pesquisa: Existem estudos usando aprendizado profundo para identificar a doença de *Parkinson* embarcado em dispositivos móveis? Para conduzir a pesquisa, foram selecionadas as bases de dados *IEEE Xplore Digital Library*, *Web of Science* e *PubMed*. Essas bases foram acessadas através do Portal de Periódicos CAPES/MEC via Comunidade Acadêmica Federada (CAFe).

As palavras-chave utilizadas para realizar a busca foram: *deep learning*, *parkinson disease*, *mobile device* or *smartphone*. A estratégia de busca adaptada para cada base de dados é apresentada na tabela 1, assim como o tipo de busca realizada e, ainda, se foi utilizado algum filtro.

Para a base de dados do *IEEE*, a busca retornou 9 artigos, para a base do *Web of Science* houve um retorno de 7 artigos e para a base do *PubMed*, o retorno foi de 8 artigos, totalizando 24 artigos. Após exclusão das duplicações restaram 20 artigos para a fase de triagem. O critério estabelecido para exclusão do artigo para a próxima fase foi: artigos de revisão, tutoriais e artigos que utilizavam

somente outros métodos de aprendizagem de máquina que não o aprendizado profundo. Na fase de triagem foram mantidos 10 artigos e excluídos 10. Na fase de análise não foi estabelecido um critério de exclusão dos artigos porque todos os trabalhos respondiam à pergunta realizada no início da revisão. A figura 1 apresenta um

diagrama com todas as etapas realizadas para seleção dos artigos.

A revisão bibliográfica realizada ficou então composta por 10 artigos, dos quais, 4 foram publicados em revistas científicas e 6 em conferências. O período de publicação dos artigos selecionados foi de 2018 a 2020.

Tabela 1 – Adequação das estratégias de busca para cada base de dados

Base de dados	Tipo da Busca	Composição da Estratégia	Filtros adicionais
IEEE Xplore	Avançada	("All Metadata":deep learn*) AND ("All Metadata":parkinson) AND ("All Metadata":mobile OR smartphone)	-
Web of Science	Básica	Metadata":deep learn*) AND ("All Metadata":parkinson) AND ("All Metadata":mobile OR smartphone)	Tópico
PubMed	Básica	(deep learn*) AND (disease parkinson) AND ((device mobile) OR (smartphone))	

RESULTADOS E DISCUSSÃO

Após análise dos artigos, verificou-se a existência de duas abordagens de identificação da doença de Parkinson: a identificação da doença, no estágio inicial, por meio da voz e a identificação da doença, em um estágio mais avançado, por meio somente dos sintomas motores ou por meio da combinação de diferentes domínios, como sintomas motores, voz e memória. Os artigos que trabalharam com a identificação da doença no estágio inicial são apresentados na tabela 2.

O trabalho de Zhang *et al.*⁽¹⁰⁾ é composto por três etapas: aquisição dos áudios através de um *smartphone*, transformação do áudio gravado em um espectrograma e classificação do espectrograma como pertencente ou não a doença de Parkinson. Tanto a etapa de obtenção do espectrograma, quanto a sua classificação são executadas em um servidor. A duração de cada áudio gravado foi de 10 segundos, mas os autores descobriram uma saturação dos resultados a partir de 5 segundos. A arquitetura de Rede Neural Convolutiva (RNC) utilizada foi baseada na *AlexNet*⁽¹²⁾ e adaptada para o problema em questão, sendo

Tabela 2 – Resumo dos artigos encontrados na revisão da literatura que utilizaram a voz para detectar a doença de Parkinson.

Autor	Tipo de Pub.	Base de dados			Aprendizado profundo	
		Quant.	Conteúdo de voz	Disponibilidade	Classificador	Métrica (%)
Zhang <i>et al.</i> ⁽¹⁰⁾	Conferência	1000	"Aaaaah" (10s)	Sim	RNC	Acurácia: 90,45±1,71
Lauraitis <i>et al.</i> ⁽¹¹⁾	Revista	339	Poema	Não	RNR	Acurácia: 94,50

RNC: Rede Neural Convolutiva RNR: Rede Neural Recorrente

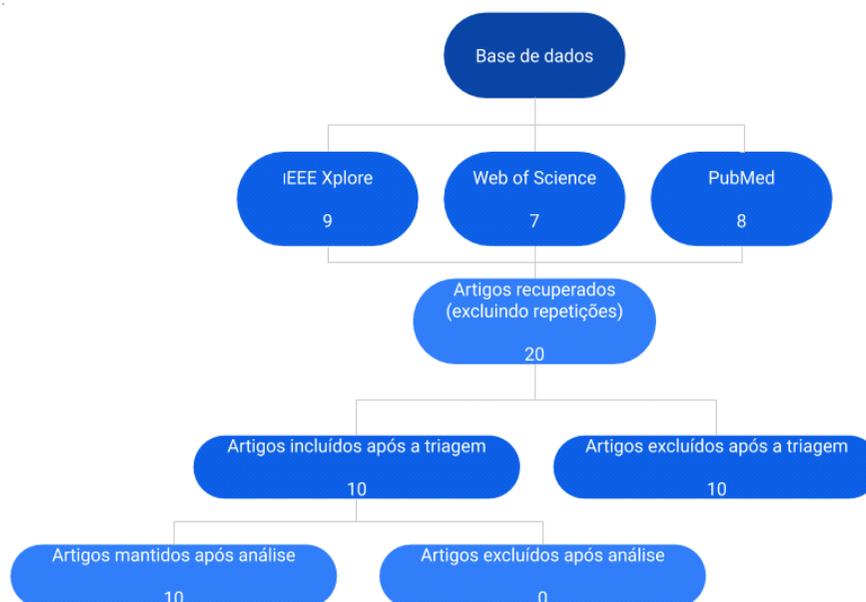


Figura 1 – Diagrama com o fluxo de seleção dos artigos sobre a utilização de aprendizado profundo na detecção da doença de Parkinson

composta pela seguinte sequência: por uma camada de convolução seguida de *Rectified Linear Unit (ReLU)*; uma camada de convolução seguida de camadas ReLU e *maxpooling*; e uma camada inteiramente conectada. O *dataset* utilizado foi composto por 500 amostras de voz de indivíduos com doença de Parkinson e 500 amostras de voz de indivíduos saudáveis. A divisão do *dataset* em amostras de treinamento e de teste baseou-se na técnica de *hold-out* com proporção de 4:1 para 10 repetições.

Lauraitis *et al.*⁽¹¹⁾ realizam o reconhecimento de desordens do sistema nervoso central no estágio inicial, inclusive da doença de Parkinson a partir de gravações de voz, onde o paciente faz a leitura de dois poemas. A

gravação é realizada por um aplicativo móvel, denominado de *Neural Impairment Test Suite (NITS)*, proposto pelos autores. Dos 15 participantes, 7 apresentavam as seguintes desordens do sistema nervoso: doença de Huntington, Parkinson, paralisia cerebral, derrame e demência precoce. Os demais participantes eram indivíduos saudáveis. A arquitetura de Rede Neural Recorrente (RNR) utilizada foi a do tipo *Bidirectional Long Short-Term Memory (BiLSTM)* com duas camadas inteiramente conectadas com 100 neurônios cada e o *dataset* foi dividido em 70% para treinamento e 30% para teste. O modelo projetado foi implantado no aplicativo móvel NITS para alertar os pacientes sobre a piora da deficiência da fala.

Tabela 3 – Resumo dos artigos encontrados na revisão da literatura que utilizaram sintomas motores para detectar a doença de *Parkinson*.

Autor	Tipo de Publicação	Quant.	Conteúdo/ evento	Disponibilidade	Classificador	Métrica (%)
Papadopoulos <i>et al.</i> ⁽¹³⁾	Revista	45 indivíduos	Sinal do acelerômetro/tremor	Sim	RNC	F1-Score: 94,30±3,4
Zhang <i>et al.</i> ⁽⁸⁾	Conferência	6 indivíduos	Sinal do acelerômetro/tremor	Não	RNC/PMC	AUC: 88,70
Shaban ⁽¹⁴⁾	Conferência	102/102 imagens	Desenho: onda/espiral	Sim	RNC	Acurácia (onda/espiral): 88,00/ 89,00
Cheng <i>et al.</i> ⁽¹⁵⁾	Conferência	79 indivíduos	Sinal do acelerômetro/caminhar/correr/sentar/levantar/deitar/subir escada	Sim	RNC/RNR	Acurácia: 98,00
Prince <i>et al.</i> ⁽¹⁶⁾	Conferência	1815 indivíduos	Sinal do acelerômetro/tocar	Sim	RNC	F1-Score: 63,40±1,97
Zhang <i>et al.</i> ⁽¹⁷⁾	Revista	2804 indivíduos	Sinal do acelerômetro/caminhar	Sim	RNC	AUC: 87,00
Iakovakis <i>et al.</i> ⁽¹⁸⁾	Revista	292 indivíduos	Sinal do acelerômetro/tocar	Sim	RNC	AUC: 89,00
Schwab e Karlen ⁽¹⁹⁾	Conferência	1853 indivíduos	Sinal do acelerômetro/caminhar/tocar voz memória	Sim	RNC/RNR	AUC: 85,00

PMC: Perceptron Multicamada; T/A: tremor/atividade

Os artigos que abordaram a identificação da Doença de Parkinson no estágio mais avançado, a partir de anormalidades motoras, estão resumidos na tabela 3. Os 7 primeiros artigos detectaram a doença de Parkinson considerando apenas os sintomas motores de maneira isolada. A exceção foi o trabalho de Schwab e Karlen⁽¹⁴⁾ que, para detectar a doença, utilizou vários domínios como sintomas motores, voz e memória.

Em Papadopoulos *et al.*⁽¹³⁾, os episódios de tremores relacionados a doença de Parkinson foram detectados através de sinais *Inertial Measurement Unit (IMU)* capturados por um *smartphone*. O aplicativo opera em segundo plano, salvando os sinais do acelerômetro durante 75 segundos a partir do momento em que o indivíduo recebe ou realiza uma ligação telefônica através do seu *smartphone*. Os dados são armazenados localmente até que as condições estabelecidas para transmitir a informação para um servidor sejam atendidas. Devido à grande variedade de smartphones, foi realizada uma etapa de pré-processamento com alguns critérios para excluir sinais capturados pelo acelerômetro. O *dataset* foi composto

por 31 indivíduos com a doença de Parkinson e 14 sem a doença. Para dividir o *dataset* foi utilizada a técnica *Leave One Subject Out (LOSO)*. A arquitetura de RNC utilizada é composta por 5 camadas: 4 de convolução, seguidas de *leaky-RELU* e *maxpooling*, e uma camada inteiramente conectada. Com essa abordagem os valores dos sinais são utilizados diretamente na entrada da rede.

Zhang *et al.*⁽⁸⁾ trabalharam com tarefas que imitavam atividades diárias e com testes clínicos. Nesse trabalho, os autores buscaram detectar tremores de pacientes com DP, a partir de acelerômetros usados nos pulsos dos 6 indivíduos testados. A proposta extrai as características utilizando uma RNC e classifica as mesmas com um PMC.

No trabalho de Shaban⁽¹⁴⁾ foi utilizado um *dataset* composto por desenhos manuscritos de ondas e espirais. O objetivo deste trabalho foi classificar os padrões de desenhos para indivíduos saudáveis e com a doença de Parkinson em diferentes estágios, incluindo o estágio grave, com classificação *Unified Parkinson Disease Rating Scale (UPDRS)* > 24. A arquitetura de RNC utilizada para classificar o *dataset* foi a *Visual Geometry Group-19 (VGG-*

19) com a técnica de *fine tuning*. A divisão do conjunto de dados foi realizada com a técnica de *10-fold cross validation* com aumento de dados, o que resultou em 400 imagens de ondas e 400 imagens de espirais.

Cheng *et al.*⁽¹⁵⁾ classificaram 6 atividades (caminhar, sentar, levantar, correr, deitar e subir escada) realizadas por dois grupos de indivíduos: pacientes com DP e um grupo controle (GC). O grupo com DP foi constituído de 44 pacientes e o grupo controle com 35 indivíduos saudáveis de mesma idade e gênero. Os pacientes com DP foram monitorados de forma passiva durante 24 semanas e o GC foi monitorado durante 6. Essas monitorações resultaram em 24.104 horas e 8.604 horas, respectivamente. Para construção do modelo foi implementada a arquitetura de rede que combina RNC com RNR. Essa arquitetura é composta de 2 camadas de convolução seguidas de *batch normalization* e *maxpooling*, mais 2 camadas LSTM e uma camada inteiramente conectada. Na fase de treinamento do modelo foram usadas duas bases de dados públicas.

Prince *et al.*⁽¹⁶⁾ identificaram problemas motores relacionados a doença de Parkinson através de um teste realizado em laboratório que solicita dos indivíduos o toque alternado com os dedos na tela de um *smartphone*. Os dados utilizados neste trabalho foram retirados do *mPower**, e envolveram apenas participantes com idade superior a 45 anos. Com isso, o total de envolvidos foram 866 indivíduos saudáveis e 949 indivíduos com a doença de Parkinson. Para classificar os sinais capturados pelo acelerômetro em conjunto com o toque na tela foi utilizada uma RNC associada a duas técnicas para evitar *overfitting*: *dropout* e aumento de dados. Para dividir o conjunto de dados foi utilizada a técnica de *10-fold cross validation* e os autores utilizaram o teste estatístico não paramétrico Kolmogorov-Smirnov para validar os resultados alcançados.

Em Zhang *et al.*⁽¹⁷⁾ a atividade escolhida para identificar a doença de Parkinson foi a caminhada. O teste realizado pelos participantes foi composto por: caminhar em linha reta de 20 a 30 segundos, descansar 30 segundos, e então retornar por mais 20 ou 30 segundos. O conjunto de dados utilizado foi o DREAM, que é composto por dados extraídos do *mPower**. A quantidade de pessoas que se registraram como tendo a doença de Parkinson foi de 656 e a quantidade de indivíduos saudáveis foi de 2148, sendo, portanto, um banco desbalanceado. A arquitetura de rede utilizada foi a RNC com normalização e aumento de dados e para dividir o banco de dados foi utilizada a técnica *5-fold cross validation*.

Iakovakis *et al.*⁽¹⁸⁾ trabalharam com o pressionar dos dedos na tela do *smartphone*. Para capturar os dados, os autores desenvolveram um aplicativo chamado *iPrognosisapp*. A arquitetura utilizada foi uma RNC baseada em *autoencoder* com a técnica de *fine tuning*. Os dados foram divididos em desenvolvimento e teste com diferentes proporções entre os indivíduos com e sem a doença de Parkinson. O conjunto completo é composto por 17 indivíduos saudáveis, 22 com a doença e 253 que informaram seu estado de saúde.

Schwab e Karlen⁽¹⁹⁾ investigaram as atividades de andar, pressionar a tela do *smartphone* com os dedos, a voz e a memória. Foi utilizada uma robusta base de dados sobre Parkinson construída pelo projeto *mPower**, cujos dados foram capturados através de um aplicativo de *smartphone*. Os autores optaram por utilizar um subgrupo de participantes com 45 anos ou mais, em face de haver poucos casos de diagnóstico clínico de Parkinson em idades mais jovens. O *dataset*, composto por indivíduos com e sem a doença, foi dividido em 70% para treinamento, 10% para validação e 20% para teste. Para construção do modelo foram utilizadas diferentes arquiteturas de redes neurais profundas. Para os casos de caminhada, voz e toque na tela foram usadas RNCs, já para tarefa de memória, os autores utilizaram uma RNR com uma arquitetura de memória de curto e longo prazo bidirecional. O melhor resultado obtido nesse trabalho foi através dos modelos treinados com as arquiteturas citadas, em conjunto com o resultado de modelos treinados com *Random Forest* (RF). Os autores também fizeram uso das técnicas de *dropout* e L2, para evitar *overfitting*.

A análise dos artigos mostrou que a utilização dos smartphones para detectar a doença de Parkinson ocorrem através de: - um monitoramento passivo^(13, 15), quando o indivíduo não precisa iniciar o aplicativo no smartphone e a obtenção dos dados ocorre de maneira automática; - ou através de um monitoramento ativo^(8, 10-11, 16-19), em que há a necessidade de inicialização no aplicativo por parte do indivíduo para realizar determinada tarefa.

Com relação as redes neurais profundas utilizadas para identificar a doença de Parkinson foram verificadas três abordagens: (1) uso de rede neural convolutiva^(10, 13-14, 16-18), (2) uso de rede neural recorrente⁽¹¹⁾ e (3) uso conjunto dos dois tipos de redes neurais^(15, 19). Houve ainda um caso onde a RNC foi utilizada apenas para extração de características⁽⁸⁾.

A disponibilidade de uma base de dados robusta sobre Parkinson como a construída pelo projeto *mPower* certamente é um fator relevante para que novos métodos e técnicas mais precisos de diagnóstico da doença de Parkinson sejam desenvolvidos. Nesse contexto, foram encontrados 4 trabalhos que fizeram uso desta base^(10, 16-17, 19) e ainda foram encontradas outras bases de dados disponíveis relacionadas a doença^(13-15, 18).

É importante ressaltar que um dos trabalhos analisados embarcou o modelo de detecção de DP no *smartphone*⁽¹¹⁾, porém na maioria dos casos, os dados foram coletados pelos *smartphones*, mas processados em um servidor. No trabalho que embarcou o modelo de detecção de DP no *smartphone*, os autores não detalham se há aprendizado contínuo a partir do modelo embarcado.

CONCLUSÃO

Esta revisão integrativa visou identificar o estado-da-arte na utilização de aprendizado profundo em associação utilizando *smartphones* para identificar a doença de Parkinson. A arquitetura de rede mais predominante foi a rede neural convolutiva (CNN). Nesse contexto, o trabalho de Papadopoulos e colaboradores⁽¹³⁾ foi o que apresentou

* <https://parkinsonmpower.org/>

o melhor resultado através da métrica F1-Score ($94,3 \pm 3,4\%$). Na maioria dos artigos, os dados foram coletados pelos smartphones e processados em um servidor, sendo necessário o envio de novos dados coletados para um ambiente remoto. Assim, permanece ainda o desafio de embarcar o método de aprendizado profundo em *smartphones*, notadamente, em face das limitações de *hardware* e poder computacional atual desses dispositivos.

REFERÊNCIAS

1. GBD 2015 Neurological Disorders Collaborator Group. Global Burden of Disease Neurological Collaboration. Global, regional, and national burden of neurological disorders during 1990-2015: A systematic analysis for the global burden of disease study 2015. *Lancet Neurology*. 2017 Nov. 1; 16(11): 877-897.
2. Dorsey ER, Bloem, BR. The parkinson pandemic call to action. *JAMA Neurology*. 2018 Jan 1; 75(1):9-10.
3. Pringsheim T, Jette N, Frolkis A, Steeves TDL. The prevalence of Parkinson's disease: a systematic review and meta-analysis. *Mov Disord*. 2014; 29(13):1583-1590.
4. US Census Bureau [Internet]. International Programs: Region Summary [cited 2020 Set 29]. Available from: www.census.gov/population/international/data/idb/region.php.
5. Jankovic J. Parkinsons disease: clinical features and diagnosis. *Journal of Neurology, Neurosurgery & Psychiatry*. 2008 Apr; 79(4):368-376.
6. Pinto S, Ozsancak C, Tripoliti E, Thobois S, Limousin-Dowsey P, Auzou P. Treatments for dysarthria in parkinson's disease. *The Lancet Neurology*. 2004 Sep; 3(9):547-556.
7. Tong, RKY. *Wearable technology in medicine and health care*. 1st ed. Academic Press; 2018.
8. Zhang A, San-Segundo R, Panev S, Tabor G, Stebbins K, Whitford A. et al. Automated tremor detection in parkinson's disease using accelerometer signals. In: CHASE: 2018 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies. 2018 Sept. 26-28; Washington, DC. p. 13-14.
9. Zhang H, Song C, Rathore AS, Huang M, Zhang Y, Xu W. mHealth Technologies towards Parkinson's Disease Detection and Monitoring in Daily Life: A Comprehensive Review. In: *IEEE Reviews in Biomedical Engineering*. 2020 May 6.
10. Zhang H, Wang A, Li D, Xu W. Deepvoice: A voiceprint-based mobile health framework for parkinson's disease identification. In: BHI: 2018 IEEE EMBS International Conference on Biomedical & Health Informatics. 2018 March 4-7; Las Vegas, NV.
11. Lauraitis A, Maskeliūnas R, Damaševičius R, Krilavičius T. Detection of speech impairments using cepstrum, auditory spectrogram and wavelet time scattering domain features. *IEEE Access*. 2020 May 19; 8: 96162-96172.
12. Krizhevsky A, Sutskever I, Hinton G. E. Imagenet classification with deep convolutional neural networks. In: NIPS 2012: Advances in neural information processing systems. 2012. p. 1097-1105.
13. Papadopoulos A, Kyritsis K, Klingelhoefer L, Bostanjopoulou S, Chaudhuri KR, Delopoulos A. Detecting parkinsonian tremor from imu data collected in-the-wild using deep multiple-instance learning. *IEEE Journal of Biomedical and Health Informatics*. 2019 Dec. 24; 24(9):2559-2569.
14. Shaban M. Deep convolutional neural network for parkinson's disease based handwriting screening. In: ISBI Workshops: 2020 IEEE 17th International Symposium on Biomedical Imaging Workshops. 2020 April 4-4; Iowa City, IA.
15. Cheng W-Y, Scotland A, Lipsmeier F, Kilchenmann T, Jin L, Schjodt-Eriksen J, et al. Human activity recognition from sensor-based large-scale continuous monitoring of parkinson's disease patients. In: CHASE: 2017 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies. 2017 July17-19; Philadelphia, PA.
16. Prince J, Vos M. A deep learning framework for the remote detection of parkinson's disease using smart-phone sensor data. In: EMBC: 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 2018 July18-21; Honolulu, HI.
17. Zhang H, Deng K, Li H, Albin RL, Guan Y. Deep learning identifies digital biomarkers for self-reported parkinson's disease. *Patterns*. 2020 June 12; 1(3):100042.
18. Iakovakis D, Chaudhuri KR, Klingelhoefer L, Bostanjopoulou S, Katsarou Z, Trivedi D, et al. Screening of parkinsonian subtle fine-motor impairment from touchscreen typing via deep learning. *Nature*. 2020 July 28; 10(1):12623.
19. Schwab P, Karlen W. Phonemd: Learning to diagnose parkinson's disease from smartphone data. In: AAAI 2019: Conference on Artificial Intelligence 2019. 2019 Jan27-Feb1; Honolulu, Hawaii.

AGRADECIMENTOS

Essa pesquisa, desenvolvida no escopo do projeto Samsung-UFAM para Educação e Pesquisa (SUPER), de acordo com o Artigo 48 do Decreto n° 6.008/2006(SUFRAMA), foi financiada pela Samsung Eletrônica da Amazônia Ltda., sob os termos da Lei Federal n° 8.387/1991, através do convênio 001/2020, assinado com a UFAM e FAEPI, Brasil.