

# Análise Comparativa de Algoritmos de ICA para Correção de Artefatos de Sinais de EEG em Pacientes com Doença de Parkinson

Marcel G. Nascimento, Jamana B. Paula, Caroline P. A. Moraes, Aline Neves, Diogo C. Soriano, Maria S. G. Rocha e André K. Takahata

**Resumo**— Este trabalho apresenta uma análise comparativa de quatro algoritmos de Análise de Componentes Independentes (ICA – *Independent Component Analysis*) aplicados na correção de artefatos de sinais de eletroencefalograma (EEG) de pacientes com Doença de Parkinson em estado de repouso. Foram avaliados SOBI, FastICA, Infomax Estendido e AMICA, em que foram verificados, tempo de execução, qualidade de separação, estimada pela (*Mutual Information Reduction* – MIR), e distribuição de componentes classificados utilizando o módulo ICLabel, seguido de refinamento manual. Os registros de EEG foram analisados em duas configurações espaciais, com 64 e 47 canais, a fim de investigar o impacto da redução do número de canais no custo computacional e na qualidade da separação de fontes. Os resultados mostram que o SOBI apresenta a melhor relação entre tempo de processamento e desempenho de separação. Também se observou que o aumento do número de canais de EEG selecionados tende a melhorar os valores de MIR, embora ao custo de um aumento de tempo de execução.

**Palavras-Chave**— EEG, ICA, Correção de Artefatos, Doença de Parkinson, MIR, ICLabel

**Abstract**— This paper presents a comparative analysis of four Independent Component Analysis (ICA) algorithms applied to artifact correction in electroencephalogram (EEG) signals from patients with Parkinson's disease at resting state. The evaluated algorithms were SOBI, FastICA, Extended Infomax, and AMICA, considering processing time, separation quality estimated by Mutual Information Reduction (MIR), and the distribution of independent components classified using ICLabel followed by manual refinement. The EEG recordings were analyzed in two spatial configurations, with 64 and 47 channels, in order to investigate the impact of channel reduction on computational cost and source separation quality. The results indicate that SOBI achieved the best trade-off between processing time and statistical separation performance, while the use of a larger number of channels tended to improve MIR values at the cost of increased execution time.

**Keywords**— EEG, ICA, Artifact Correction, Parkinson's Disease, MIR, ICLabel

Marcel G. Nascimento, Caroline P. A. Moraes, Aline Neves, Diogo C. Soriano e André K. Takahata estão vinculados à Universidade Federal do ABC (UFABC), Santo André-SP, Brasil. E-mails: {marcel.nascimento, caroline.moraes, aline.panzio, diogo.soriano, andre.takahata}@ufabc.edu.br. Jamana B. Paula e Maria S. G. Rocha estão vinculadas ao Hospital Santa Marcelina, São Paulo-SP, Brasil. E-mails: jamanabarbosa@gmail.com, ms-rocha@uol.com.br. André K. Takahata também está vinculado ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP), Campinas-SP, Brasil. Este estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Processo 2022/03242-0.

## I. INTRODUÇÃO

A Doença de Parkinson (DP) é uma condição neurodegenerativa progressiva caracterizada por sintomas motores, como tremor de repouso, rigidez e bradicinesia, além de manifestações não motoras. O EEG tem sido utilizado como ferramenta complementar no estudo da DP por permitir a análise funcional da atividade cerebral com elevada resolução temporal, de forma não invasiva e com custo relativamente reduzido. Estudos recentes também apontam seu potencial para a investigação fisiopatológica e o desenvolvimento de biomarcadores complementares em pacientes com DP [1]–[3]. Entretanto, os sinais EEG são altamente suscetíveis à contaminação por artefatos, como piscadas, movimentos oculares, atividade muscular, ruído da rede elétrica e ruído instrumental [4], [5]. Por esse motivo, técnicas robustas de separação e correção de artefatos são fundamentais para aumentar a confiabilidade das análises realizadas nesse contexto. A Análise de Componentes Independentes (ICA, do inglês *Independent Component Analysis*) decompõe sinais multicanais em componentes estatisticamente independentes, facilitando a identificação de artefatos em registros de EEG [6], [7]. Nesse contexto, este trabalho apresenta uma comparação entre quatro algoritmos de ICA: *Second-Order Blind Identification* (SOBI), FastICA, Infomax Estendido e *Adaptive Mixture Independent Component Analysis* (AMICA), disponíveis na *toolbox* EEGLAB [8]. O objetivo é avaliar esses algoritmos na correção de artefatos em sinais de EEG de pacientes com DP em estado de repouso. A análise considera o tempo de processamento, a identificação automática dos componentes por meio do classificador ICLabel [9], a qualidade da separação medida pela *Mutual Information Reduction* (MIR) e a inspeção manual dos componentes independentes (ICs, do inglês *independent components*).

## II. FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta os fundamentos da BSS e da ICA aplicados à separação de atividade neural e artefatos em sinais de EEG.

### A. Separação Cega de Fontes

Separação Cega de Fontes (BSS – *Blind Source Separation*) corresponde ao problema de estimar sinais provenientes de múltiplas fontes a partir de observações indiretas, que podem ser modeladas como combinações de uma ou mais fontes, em que não há conhecimento prévio do sistema de mistura e o uso de sinais de treinamento [7]. No caso, é considerado que cada

eletrodo registra uma combinação linear de múltiplas fontes neurais e não neurais [6], [10]. De forma simplificada, esse modelo pode ser descrito por:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t), \quad (1)$$

em que  $\mathbf{x}(t)$  representa os sinais observados nos eletrodos,  $\mathbf{s}(t)$  representa as fontes e  $\mathbf{A}$  corresponde à matriz de mistura. Considerando que, no máximo, uma das fontes é gaussiana, e são independentes entre si, é possível aplicar a ICA para a realização da BSS [7]. Nesse contexto, uma matriz de separação  $\mathbf{W}$  é estimada com uso da ICA de modo a se obter:

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t), \quad (2)$$

em que as componentes independentes,  $\mathbf{y}(t)$ , correspondem assim às estimativas das fontes, a menos de ambiguidades de escala e permutação. Após a decomposição, componentes associados a artefatos podem ser identificados e removidos, permitindo reconstrução de sinais EEG com atenuação desses componentes [5], [8].

#### B. Análise de Componentes Independentes

A ICA corresponde a uma família de métodos baseada na hipótese de independência entre fontes latentes observadas indiretamente [6]. Em processamento de sinais de EEG, a ICA é frequentemente utilizada para decompor os sinais registrados nos eletrodos em ICs, permitindo separar atividade neural de artefatos, como piscadas, movimentos oculares, atividade muscular e ruídos instrumentais [5], [8], [10]. Desse modo, no presente trabalho foram avaliados quatro algoritmos de ICA disponíveis no EEGLAB [8], conforme já mencionado na Seção I. O SOBI baseia-se na diagonalização conjunta de matrizes de covariância em múltiplos atrasos temporais, explorando a estrutura temporal dos sinais [11]. O FastICA utiliza maximização da não gaussianidade por iterações de ponto fixo, geralmente apresentando rápida convergência em diversos cenários [12]. O Infomax Estendido implementa aprendizado baseado em gradiente natural e estimação da matriz de separação por um critério equivalente à máxima verossimilhança, assumindo que as fontes são estatisticamente independentes podendo ser sub ou supergaussianas, sendo tradicionalmente um dos métodos mais difundidos no processamento de EEG [13], [14]. O AMICA pode ser descrito como uma estrutura hierárquica composta por três camadas. Nas duas primeiras, considera-se uma combinação probabilística de múltiplos modelos de ICA, os quais modelam diferentes padrões estatísticos e a natureza não estacionária dos sinais. Na terceira camada, as distribuições das fontes são modeladas por meio de misturas de distribuições gaussianas generalizadas. Essa estrutura contempla uma ampla gama de comportamentos estatísticos, porém a um processamento computacional significativamente superior [15].

### III. MÉTODOS

Esta seção descreve os dados, o pré-processamento, o pipeline e as métricas utilizadas na avaliação dos algoritmos ICA.

#### A. Mutual Information Reduction

No presente trabalho, a MIR foi utilizada como métrica quantitativa da independência estatística obtida após a decomposição

por ICA. Essa medida estima a redução da dependência entre os sinais antes e após a separação, de modo que valores mais elevados indicam componentes estatisticamente mais independentes [16], [17]. Ressalta-se, contudo, que a MIR não mensura diretamente a preservação da atividade neural nem a efetividade da remoção de artefatos. Por esse motivo, ela foi interpretada como figura de mérito que deve ser complementada com outros fatores como o tempo de processamento, a classificação pelo ICLabel e a inspeção visual dos sinais reconstruídos. A MIR é definida como a diferença entre a informação mútua estimada antes e após a separação das fontes, podendo ser representada por:

$$\begin{aligned} \text{MIR} &= I(\mathbf{x}) - I(\mathbf{y}) \\ &= \sum_{i=1}^n H(x_i) - \sum_{i=1}^n H(y_i) + \log(|\det(\mathbf{W})|), \end{aligned} \quad (3)$$

em que  $\mathbf{x} = [x_1, x_2, \dots, x_n]$  representa o conjunto dos sinais observados originais e  $\mathbf{y} = [y_1, y_2, \dots, y_n]$  corresponde ao conjunto dos ICs estimados após a aplicação da ICA. Assim, os termos  $H(x_i)$  e  $H(y_i)$  representam as respectivas entropias marginais. Valores maiores de MIR indicam maior redução da dependência estatística, mas não garantem, isoladamente, a preservação da atividade neural ou a efetividade da remoção de artefatos. Esse ponto é reforçado pela ocorrência de componentes atribuídos à classe *Other*, indicando que a MIR deve ser analisada em conjunto com a classificação automática realizada pelo ICLabel e com a inspeção visual dos componentes [5], [8], [9]. Neste estudo, a inspeção visual foi realizada por um engenheiro de computação.

#### B. Dataset

Os sinais utilizados neste estudo foram provenientes de pacientes com Doença de Parkinson acompanhados no Hospital Santa Marcelina, em São Paulo, Brasil. A amostra foi composta por 10 pacientes em estado de repouso, identificados como S01–S10, com idades entre 57 e 84 anos, sendo 6 homens e 4 mulheres. O estudo foi conduzido em conformidade com os princípios éticos para pesquisa envolvendo seres humanos, com aprovação do Comitê de Ética em Pesquisa (CEP), sob o CAAE nº 23885019.1.0000.0066. As aquisições foram realizadas com o sistema de EEG *ActiveThree* da BioSemi, e os arquivos brutos foram armazenados no formato *BioSemi Data Format* (BDF). Os registros foram adquiridos por meio de 72 canais, incluindo canais de EEG e auxiliares, com frequência de amostragem de 1024 Hz. Para as análises de ICA, foram considerados inicialmente 64 canais EEG distribuídos sobre o escalpo conforme o sistema internacional 10–20 [18]. O tempo de aquisição dos sinais variou de 912 s, no paciente S01, a 1001 s, no paciente S04, correspondendo respectivamente a 933888 e 1025024 amostras por canal. Ainda assim, os sinais apresentaram artefatos, como piscadas, movimentos oculares, atividade muscular residual e interferências instrumentais ou ambientais, justificando o uso de técnicas de BSS e ICA.

#### C. Configuração dos Canais e Pré-processamento

Para as análises, foram considerados inicialmente os 64 canais EEG do sistema BioSemi. A configuração reduzida com 47

canais foi obtida pela remoção de 17 eletrodos periféricos mais suscetíveis a artefatos oculares, musculares ou instabilidades de contato: Fp1, Fp2, AF7, AF3, AFz, AF4, AF8, PO7, PO3, POz, PO4, PO8, O1, Oz, O2 e Iz. Assim, permaneceram os canais frontais, centrais, temporais e parietais de maior interesse para a análise da DP. O pré-processamento foi realizado com apoio do EEGLAB. Inicialmente, os dados foram filtrados por filtro FIR passa-faixa entre 1 Hz e 45 Hz, visando atenuar variações lentas da linha de base e componentes de alta frequência associados a ruídos musculares e instrumentais. Em seguida, os sinais foram rerreferenciados pela média comum dos canais EEG. Não foi realizada rejeição automática adicional de canais ruins individualizada por paciente antes da ICA, de modo a manter a comparabilidade entre algoritmos e entre as configurações espaciais avaliadas.

#### D. Pipeline de Processamento

Inicialmente, os sinais EEG foram submetidos, no EEGLAB, a um filtro notch em 60 Hz para atenuação da interferência da rede elétrica. Em seguida, como mostrado na Figura 1, aplicou-se um filtro FIR passa-faixa entre 1 Hz e 45 Hz, visando atenuar deriva de linha de base, oscilações lentas e interferências de alta frequência associadas a ruídos musculares e instrumentais. Em seguida, os sinais foram rerreferenciados pela média comum dos canais EEG, reduzindo a dependência em relação a um eletrodo de referência específico.




Figura 1: Fluxograma do pipeline de processamento aplicado aos sinais EEG.

Após a decomposição por ICA, as componentes independentes foram classificadas pelo ICLabel, ferramenta disponível no pacote EEGLAB baseada em um modelo de aprendizado de máquina treinado com componentes rotuladas manualmente [9]. Neste trabalho, componentes com probabilidade superior a 80% para classes correspondentes a artefatos foram inicialmente pré-selecionadas para remoção, buscando aumentar a especificidade da classificação automática e reduzir a remoção indevida de componentes neurais. A inspeção manual posterior não se limitou a confirmar os componentes pré-selecionados automaticamente. Componentes com probabilidade inferior a 80% ou atribuídos inicialmente à classe *Other* foram reavaliados quando apresentavam mapa topográfico, série temporal ou espectro de potência compatíveis com artefatos. Assim, os valores após inspeção manual não correspondem necessariamente a um subconjunto dos componentes automáticos. Esse refinamento foi usado como estratégia complementar para reduzir ambiguidades, especialmente na classe *Other*, sem constituir um *ground-truth* absoluto.

## IV. RESULTADOS

Esta seção apresenta os resultados de tempo de processamento, classificação dos componentes, MIR e inspeção visual dos sinais.

#### A. Tempo de processamento em função do número de eletrodos

A Tabela I apresenta o tempo médio de execução dos algoritmos ICA nas configurações com 47 e 64 canais. De forma geral, o aumento do número de canais elevou o tempo de processamento em todos os métodos, refletindo o impacto da dimensionalidade espacial no processamento dos sinais de EEG.

TABELA I: Tempo de execução médio (min) para pacientes S01–S10 em estado de repouso.

| Algoritmo         | 47 canais    | 64 canais    |
|-------------------|--------------|--------------|
| SOBI              | 0,37 ± 0,06  | 0,50 ± 0,09  |
| FastICA           | 0,75 ± 0,19  | 2,30 ± 1,88  |
| Infomax Estendido | 6,68 ± 2,24  | 9,14 ± 2,21  |
| AMICA             | 47,17 ± 3,53 | 63,85 ± 5,10 |

Os experimentos foram realizados em um computador com Windows 11 de 64 bits, processador AMD Ryzen 5 3400G de 3,70 GHz, 32 GB de memória RAM e placa gráfica Radeon RX550/550 Series com 4 GB de memória dedicada. O SOBI apresentou os menores tempos médios em ambas as configurações, mantendo execução inferior a um minuto mesmo com 64 canais. O FastICA também apresentou baixo tempo de execução com 47 canais, mas exibiu aumento expressivo e maior variabilidade com 64 canais. O Infomax Estendido apresentou custo intermediário, enquanto o AMICA demandou os maiores tempos de processamento, comportamento esperado devido à sua estrutura probabilística baseada em múltiplos modelos de ICA. Ainda assim, em aplicações *offline* de EEG clínico, tempos maiores podem ser aceitáveis quando associados a melhor separação ou maior interpretabilidade das componentes [19], [20].

#### B. Distribuições Médias dos Artefatos

Após a decomposição por ICA, os ICs foram classificados automaticamente utilizando o ICLabel [9]. Nesta etapa, foram analisadas as classes *Muscle*, *Eye*, *Heart*, *Line Noise*, *Channel Noise* e *Other*, associadas aos artefatos, ruídos instrumentais e componentes residuais presentes em registros de EEG. As classes *Brain* e *Line Noise* não foram incluídas nas Tabelas II e III. A classe *Brain* foi omitida porque o foco da análise recaiu sobre os componentes associados a artefatos.

TABELA II: Número médio de ICs atribuídos a cada classe de artefato após classificação automática inicial (*Aut.*), com limiar de probabilidade superior a 80%, e posteriormente confirmados por inspeção manual (*Man.*) para o caso de 47 canais.

| Alg.    | <i>Muscle</i> |             | <i>Eye</i>  |             | <i>Heart</i> |             | <i>Ch. Noise</i> |             | <i>Other</i> |             |
|---------|---------------|-------------|-------------|-------------|--------------|-------------|------------------|-------------|--------------|-------------|
|         | <i>Aut.</i>   | <i>Man.</i> | <i>Aut.</i> | <i>Man.</i> | <i>Aut.</i>  | <i>Man.</i> | <i>Aut.</i>      | <i>Man.</i> | <i>Aut.</i>  | <i>Man.</i> |
| SOBI    | 5,7           | 3,8         | 6,1         | 1,4         | 0,4          | 0,3         | 2,2              | 1,9         | 32,2         | 14,5        |
| FastICA | 6,1           | 3,0         | 5,0         | 2,0         | 0,2          | 0,1         | 3,5              | 2,8         | 30,6         | 17,3        |
| INFOMAX | 6,7           | 4,3         | 4,8         | 1,7         | 0,1          | 0,0         | 5,4              | 4,8         | 26,3         | 15,1        |
| AMICA   | 7,4           | 4,6         | 4,3         | 0,9         | 0,3          | 0,2         | 7,0              | 6,3         | 24,6         | 15,8        |

A classe *Line Noise* não foi detectada automaticamente pelo ICLabel, pois um filtro *notch* foi aplicado como etapa de pré-processamento para atenuar as interferências da rede elétrica. As Tabelas II e III apresentam os números médios de compo-

TABELA III: Número médio de ICs atribuídos a cada classe de artefato após classificação automática inicial (*Aut.*), com limiar de probabilidade superior a 80%, e posteriormente confirmados por inspeção manual (*Man.*) para o caso de 64 canais.

| Alg.    | Muscle |      | Eye  |      | Heart |      | Ch. Noise |      | Other |      |
|---------|--------|------|------|------|-------|------|-----------|------|-------|------|
|         | Aut.   | Man. | Aut. | Man. | Aut.  | Man. | Aut.      | Man. | Aut.  | Man. |
| SOBI    | 5,3    | 5,4  | 5,7  | 3,3  | 0,1   | 0,1  | 3,1       | 2,8  | 42,6  | 19,1 |
| FastICA | 4,2    | 4,6  | 5,0  | 3,1  | 0,1   | 0,1  | 6,3       | 5,7  | 40,7  | 19,4 |
| INFOMAX | 6,4    | 7,2  | 7,8  | 3,0  | 0,1   | 0,1  | 9,1       | 8,3  | 34,1  | 17,0 |
| AMICA   | 6,3    | 6,6  | 7,1  | 1,6  | 0,3   | 0,2  | 10,5      | 9,9  | 34,5  | 20,2 |

nentes inicialmente identificados automaticamente como artefatos (*Aut.*), com probabilidade estimada pelo ICLabel superior a 80%, e dos ICs posteriormente confirmados por inspeção manual (*Man.*), considerando as configurações de 47 e 64 canais. Em 64 canais, a inspeção manual apresentou valores ligeiramente superiores para a classe *Muscle*. Isso ocorreu devido a alguns componentes abaixo do limiar automático de 80%, mas com características topográficas, espectrais e temporais compatíveis com atividade muscular, e por isso, foram contabilizados na avaliação visual. Como as diferenças variaram somente entre 0,1 e 0,8 IC, esse resultado representa um refinamento pontual da classificação automática. Para a classe *Other*, em 47 canais, SOBI e FastICA apresentaram os maiores valores na classificação automática inicial, com médias de 32,2 e 30,6 ICs, respectivamente. Após a inspeção manual, os valores dessa classe ficaram mais próximos entre os algoritmos, variando de 14,5 ICs para SOBI a 17,3 ICs para FastICA. Na configuração de 64 canais, também foram observados valores elevados para a classe *Other*, especialmente na classificação automática inicial, com maiores médias para SOBI e FastICA, correspondentes a 42,6 e 40,7 ICs. Após a inspeção manual, o AMICA apresentou a maior quantidade residual dessa classe, com média de 20,2 ICs. A etapa de refinamento manual reduziu a quantidade de componentes inicialmente agrupados como *Other*, indicando que parte desses ICs pôde ser melhor avaliada durante a inspeção complementar. Além disso, as classes *Muscle* e *Eye* apresentaram quantidades relevantes de artefatos em ambas as configurações, comportamento compatível com registros clínicos de pacientes com Doença de Parkinson [4], [5].

### C. Mutual Information Reduction

A qualidade estatística da separação obtida com ICA foi avaliada por meio da MIR, conforme a Eq. (3) [16]. A Figura 2 apresenta a distribuição dos valores obtidos para os quatro algoritmos nas configurações com 47 e 64 canais. Observa-se tendência de aumento da MIR na configuração com 64 canais, especialmente para SOBI, Infomax Estendido e AMICA. Esse comportamento sugere que o maior número de sensores fornece observações adicionais do processo de mistura, favorecendo a obtenção de componentes mais independentes do ponto de vista estatístico [16]. Entre os algoritmos avaliados, o SOBI apresentou as maiores medianas de MIR em ambas as configurações, enquanto o FastICA apresentou os menores valores. Infomax Estendido e AMICA exibiram comportamento intermediário, com melhora no cenário de 64 canais. A dispersão observada nos boxplots indica variabilidade entre pacientes, possivelmente associada a diferenças fisiológicas

individuais, características do escalpo e à variabilidade dos artefatos presentes nos registros de EEG.




Figura 2: Distribuição dos valores de MIR obtidos para os algoritmos SOBI, FastICA, Infomax Estendido e AMICA nas configurações de 47 e 64 canais.

Assim, considerando o tamanho amostral reduzido, os resultados devem ser interpretados como preliminares e exploratórios. Além disso, como já mencionado, a MIR não mensura diretamente a preservação da atividade neural nem a efetividade da remoção de artefatos, mas contribui para avaliar a redução da dependência estatística entre componentes independentes. Portanto, sua interpretação deve ser complementada pela classificação com ICLabel, pelo refinamento manual e pela inspeção visual dos sinais reconstruídos. Embora o SOBI tenha apresentado maiores valores de MIR, também resultou em maior quantidade de componentes classificados como *Other*, sugerindo que maior independência estatística não garante, isoladamente, melhor interpretabilidade fisiológica. Em contrapartida, Infomax Estendido e AMICA apresentaram menor incidência residual dessa classe, indicando maior compatibilidade entre os ICs estimados e os padrões reconhecidos automaticamente pelo ICLabel.

### D. Análise de Correção de Artefatos no Domínio do Tempo

A Figura 3 apresenta um exemplo ilustrativo da comparação temporal entre os sinais antes e após o processamento para o paciente S09, utilizando o algoritmo SOBI na configuração em um intervalo de 5 s de duração. Os sinais apresentados permitem observar a redução das oscilações associadas a artefatos oculares.




Figura 3: Exemplo ilustrativo da comparação temporal entre sinais de pós-processamento e depois em canais frontais associados à classe *Eye*, no intervalo de 5 s, para o paciente S09, algoritmo SOBI, e configuração de 64 canais.

A janela apresentada foi definida com base na energia dos sinais EEG reconstruídos, na alteração visual da amplitude e

da forma de onda após a remoção dos artefatos e na amplitude máxima observada no intervalo analisado, priorizando trechos com maior evidência de atividade indesejada. Observa-se, no conjunto anterior ao processamento, a presença de oscilações de grande amplitude e sincronizadas entre canais frontais, padrão compatível com artefatos oculares. Após o processamento, nota-se atenuação dessas oscilações, resultando em sinais visualmente mais estáveis. Esse exemplo complementa as análises obtidas por MIR e ICLabel, indicando que a redução de componentes artefatuais também se reflete na melhora visual do traçado do EEG. Considerando as características motoras associadas à Doença de Parkinson, a inspeção qualitativa reforça a efetividade do procedimento adotado para mitigação de artefatos sem necessidade de descarte integral dos registros analisados.

## V. DISCUSSÃO

Os resultados indicam que a escolha do algoritmo ICA influencia tanto o tempo de execução quanto a separação estatística dos sinais EEG. O aumento de 47 para 64 canais elevou os valores de MIR, mas também aumentou o tempo de processamento. Entre os métodos avaliados, o SOBI apresentou maiores medianas de MIR e menores tempos médios, indicando eficiência na separação estatística das fontes independentes [11]. Contudo, a maior incidência de componentes classificados como *Other* reforça que maior independência estatística não garante, isoladamente, melhor interpretabilidade fisiológica ou remoção mais adequada de artefatos. O FastICA apresentou maior dispersão nos tempos de execução e nos valores de MIR na configuração de 64 canais, enquanto Infomax Estendido e AMICA produziram ICs mais facilmente identificáveis pelo ICLabel, embora com maior tempo de processamento [12], [15]. A classificação automática pelo ICLabel foi útil para identificação inicial de artefatos, especialmente nas classes *Eye* e *Muscle*; porém, a elevada incidência da classe *Other* reforçou a necessidade do refinamento manual. A análise visual também indicou atenuação de artefatos oculares após o processamento por ICA.

## VI. CONCLUSÃO

Este trabalho comparou os algoritmos SOBI, FastICA, Infomax Estendido e AMICA na correção de artefatos em sinais EEG de pacientes com Doença de Parkinson em repouso, considerando configurações de 47 e 64 canais. Os resultados preliminares indicaram que o SOBI apresentou melhor equilíbrio entre tempo de processamento e separação estatística, com maiores valores de MIR e menores tempos médios de execução. O aumento do número de canais favoreceu os valores de MIR, embora com maior tempo de processamento. A combinação entre ICLabel, refinamento manual e inspeção visual mostrou-se relevante para complementar a seleção de componentes independentes associadas a artefatos, especialmente nos casos classificados como *Other*. Como trabalhos futuros, propõe-se ampliar a base clínica analisada, incluir testes estatísticos complementares e investigar estratégias automáticas de refinamento da seleção de componentes independentes em EEG clínico.

## REFERÊNCIAS

- [1] D. J. McKeown *et al.*, “Medication-invariant resting aperiodic and periodic neural activity in parkinson’s disease,” *Psychophysiology*, vol. 61, no. 4, p. e14478, 2024.
- [2] M. F. Anjum *et al.*, “Resting-state eeg measures cognitive impairment in parkinson’s disease,” *npj Parkinson’s Disease*, vol. 10, no. 1, p. 6, 2024.
- [3] V. Mancazzo *et al.*, “Parkinson’s disease detection from resting-state eeg using a transformer model with multi-head attention explanations,” *Biomedical Signal Processing and Control*, vol. 119, p. 109811, 2026.
- [4] M. Fatourechhi, A. Bashashati, R. K. Ward, and G. E. Birch, “Emg and eeg artifacts in brain computer interface systems: a survey,” *Clinical Neurophysiology*, vol. 118, no. 3, pp. 480–494, 2007.
- [5] J. A. Urigüen and B. Garcia-Zapirain, “Eeg artifact removal—state-of-the-art and guidelines,” *Journal of Neural Engineering*, vol. 12, no. 3, p. 031001, 2015.
- [6] A. Hyvärinen and E. Oja, “Independent component analysis: algorithms and applications,” *Neural Networks*, vol. 13, no. 4–5, pp. 411–430, 2000.
- [7] J.-F. Cardoso, “Blind signal separation: statistical principles,” *Proceedings of the IEEE*, vol. 86, no. 10, pp. 2009–2025, 1998.
- [8] A. Delorme and S. Makeig, “Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis,” *Journal of Neuroscience Methods*, vol. 134, no. 1, pp. 9–21, 2004.
- [9] L. Pion-Tonachini, K. Kreutz-Delgado, and S. Makeig, “Iclabel: An automated electroencephalographic independent component classifier, dataset, and website,” *NeuroImage*, vol. 198, pp. 181–197, 2019.
- [10] S. Makeig, A. J. Bell, T.-P. Jung, and T. J. Sejnowski, “Independent component analysis of electroencephalographic data,” *Advances in Neural Information Processing Systems*, vol. 8, 1996.
- [11] A. Belouchrani, K. Abed-Meraim, J.-F. Cardoso, and E. Moulines, “A blind source separation technique using second-order statistics,” *IEEE Transactions on Signal Processing*, vol. 45, no. 2, pp. 434–444, 1997.
- [12] A. Hyvärinen, “Fast and robust fixed-point algorithms for independent component analysis,” *IEEE Transactions on Neural Networks*, vol. 10, no. 3, pp. 626–634, 1999.
- [13] A. J. Bell and T. J. Sejnowski, “An information-maximization approach to blind separation and blind deconvolution,” *Neural Computation*, vol. 7, no. 6, pp. 1129–1159, 1995.
- [14] T.-W. Lee, M. Girolami, and T. J. Sejnowski, “Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources,” *Neural Computation*, vol. 11, no. 2, pp. 417–441, 1999.
- [15] S.-H. Hsu *et al.*, “Modeling brain dynamic state changes with adaptive mixture independent component analysis,” *NeuroImage*, vol. 183, pp. 47–61, 2018.
- [16] T. M. Cover and J. A. Thomas, *Elements of Information Theory*, 2nd ed. Wiley, 2006.
- [17] A. Kraskov, H. Stögbauer, and P. Grassberger, “Estimating mutual information,” *Physical Review E*, vol. 69, no. 6, p. 066138, 2004.
- [18] H. H. Jasper, “The ten-twenty electrode system of the international federation,” *Electroencephalography and Clinical Neurophysiology*, vol. 10, pp. 371–375, 1958.
- [19] B. Blankertz *et al.*, “Optimizing spatial filters for robust eeg single-trial analysis,” *IEEE Signal Processing Magazine*, vol. 25, no. 1, pp. 41–56, 2008.
- [20] F. Lotte *et al.*, “A review of classification algorithms for eeg-based brain-computer interfaces: a 10 year update,” *Journal of Neural Engineering*, vol. 15, no. 3, p. 031005, 2018.