



REMOÇÃO DE ARTEFATOS EM EEG DE PACIENTES COM DOENÇA DE PARKINSON UTILIZANDO INFOMAX ESTENDIDO

Marcel Gomes do Nascimento¹, Jamana Barbosa de Paula³, Caroline Pires Alavez Moraes¹, Diogo Coutinho Soriano¹, Maria Sheila Guimarães Rocha³, André Kazuo Takahata^{1,2}

¹Universidade Federal do ABC, Santo André, Brasil (marcel.nascimento@ufabc.edu.br)

²Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Campinas, Brasil

³Hospital Santa Marcelina, São Paulo, Brasil

Resumo: Este trabalho avaliou o desempenho do algoritmo Infomax Estendido na remoção de artefatos em sinais de EEG de 15 pacientes com Doença de Parkinson utilizando análise de componentes independentes (ICA). Foram empregadas a classificação automática de componentes independentes, a inspeção temporal, a análise de mapas topográficos e a métrica *Mutual Information Reduction* (MIR). Os resultados indicaram melhoria na qualidade dos sinais e evidenciaram a robustez do método em diferentes pacientes.

Palavras-chave: Eletroencefalograma; Infomax Estendido; Doença de Parkinson; Análise de Componentes Independentes; Processamento Digital de Sinais

INTRODUÇÃO

A Doença de Parkinson (DP) é uma enfermidade neurodegenerativa progressiva caracterizada principalmente pela degeneração de neurônios dopaminérgicos da substância negra *pars compacta*, comprometendo circuitos córtico-subcorticais relacionados ao controle motor e cognitivo (Jankovic, 2008; Schapira, 2017). Entre os sinais clínicos mais frequentes destacam-se tremor de repouso, rigidez muscular, bradicinesia e instabilidade postural, podendo coexistir alterações cognitivas, emocionais e disfunções autonômicas (Jankovic, 2008).

A eletroencefalografia constitui ferramenta que tem recebido atenção para investigação funcional cerebral em pacientes com DP devido à elevada resolução temporal, caráter não invasivo e custo relativamente reduzido. Registros EEG vêm sendo utilizados na análise de conectividade cortical, biomarcadores neurofisiológicos e monitoramento funcional em distúrbios do movimento (Aljalal et al., 2022; Lee et al., 2021). Entretanto, sinais clínicos reais frequentemente apresentam contaminações por piscadas, movimentos oculares, atividade muscular, tremor e interferências ambientais, dificultando análises posteriores (Fatourechi et al., 2007; Uriguen e Garcia-Zapirain, 2015).

Nesse contexto, técnicas de Análise de Componentes Independentes (ICA, do inglês *Independent Component Analysis*) têm sido amplamente empregadas na separação cega de fontes para remoção de artefatos (Makeig et al., 1996; Hyvärinen e Oja, 2000). Entre os algoritmos disponíveis, o Infomax

Estendido destaca-se pela estabilidade de convergência e robustez computacional (Bell e Sejnowski, 1995; Delorme e Makeig, 2004). A ICA é amplamente utilizada em EEG por permitir a decomposição dos sinais adquiridos em componentes estatisticamente independentes, favorecendo a separação entre atividade cerebral e artefatos provenientes de piscadas, movimentos oculares e atividade muscular. A decomposição foi realizada por meio do algoritmo Infomax Estendido, que corresponde a uma variação do algoritmo Infomax, originalmente proposto em (Bell e Sejnowski 1995), o qual foi adaptado em (Lee et al., 1999) para lidar simultaneamente com fontes subgaussianas e supergaussianas, condição frequentemente observada em sinais biológicos como o EEG. Essa característica amplia a robustez do método empregado, permitindo melhor discriminação entre atividade neural e artefatos que possuem diferentes distribuições estatísticas (Delorme e Makeig, 2004).

Apesar do uso consolidado da ICA em EEG, permanecem relevantes estudos aplicados a bases clínicas reais contendo elevada heterogeneidade fisiológica, fator que pode influenciar a qualidade da decomposição e a separação de fontes independentes fora de padrão. Dessa forma, o presente trabalho teve como objetivo avaliar o desempenho do algoritmo Infomax Estendido na remoção de artefatos em sinais EEG de 15 pacientes com uso de métricas quantitativas, análise espacial e inspeção temporal.

MATERIAL E MÉTODOS

Foram analisados sinais de EEG de quinze pacientes com Doença de Parkinson (DP) acompanhados no Hospital Santa Marcelina (HSM), localizado em São Paulo, SP. A amostra contemplou diferentes perfis fisiológicos e clínicos, incluindo variações relacionadas ao sexo, idade, tempo de evolução da doença, estágio clínico, uso de medicação dopaminérgica e possíveis diferenças nos padrões neurofisiológicos corticais. A amostra foi composta por 9 homens e 6 mulheres, com idades entre 57 e 84 anos. Essa heterogeneidade é relevante, uma vez que tais fatores podem influenciar diretamente as características dos sinais de EEG, como atividade espectral, conectividade e presença de artefatos fisiológicos. O estudo foi conduzido em conformidade com os princípios éticos para pesquisa envolvendo seres humanos, com aprovação do Comitê de Ética em Pesquisa (CEP), CAAE nº 23885019.1.0000.0066.

As aquisições foram realizadas por sistema *BioSemi ActiveThree*, utilizando touca eletroencefalográfica de 64 canais distribuídos conforme o sistema internacional 10-20, mostrado na Figura 1, na qual foram utilizados eletrodos ativos de Ag/AgCl e gel condutor. Também foram registrados, para uso posterior, potenciais dos processos mastoideis, e sinais de eletrooculograma (EOG) por meio de eletrodos auxiliares.




Figura 1. Distribuição espacial dos eletrodos utilizados seguindo o sistema internacional 10-20. Adaptado de *BioSemi* (2026).

Os sinais foram importados para a *toolbox* EEGLAB, amplamente empregada em estudos de EEG para visualização, decomposição por ICA, inspeção de componentes independentes e reconstrução de sinais após remoção de artefatos (Delorme e Makeig, 2004).

A qualidade da decomposição ICA foi avaliada por meio da métrica *Mutual Information Reduction* (MIR) que tem como objetivo fornecer um modo de

quantificar a independência entre os componentes extraídos. Como os algoritmos de ICA buscam identificar componentes maximamente independentes, isto é, minimizando a informação mútua, espera-se que um bom desempenho desses métodos resulte em valores elevados de MIR, e, conseqüentemente, melhor desempenho da decomposição ICA. Estudos recentes têm utilizado MIR para comparar algoritmos de ICA e avaliar fatores que influenciam a qualidade da decomposição, como número de canais, quantidade de dados e características do pré-processamento (Frank et al., 2022; Frank et al., 2025; Coelli et al., 2024).

A decomposição foi realizada por meio do algoritmo Infomax Estendido, implementação do método *Infomax* disponível no EEGLAB. Esse método busca estimar componentes estatisticamente independentes a partir dos sinais observados nos eletrodos visando, assim, fontes cerebrais de fontes não cerebrais. Em processamento de EEG, essa abordagem é particularmente útil, pois piscadas, movimentos oculares, atividade muscular, ruídos de aquisição e interferência da rede elétrica tendem a apresentar padrões espaciais e estatísticos diferentes da atividade cerebral de interesse (Bell e Sejnowski, 1995; Hyvärinen e Oja, 2000).

Após a aplicação da ICA, os componentes independentes foram avaliados por inspeção visual e com auxílio do classificador automático *ICLabel*, o qual estima as probabilidades de uma dada componente pertencer às classes *Brain*, *Eye*, *Muscle*, *Heart*, *Line Noise*, *Channel Noise* e *Other*, como detalhado na Tabela 1, permitindo identificar componentes com maior probabilidade de estarem relacionados a artefatos (Pion-Tonachini et al., 2019).

Componentes associados principalmente às classes *Eye*, *Muscle*, *Line Noise*, *Channel Noise* e *Other* foram verificados manualmente considerando suas características espaciais, temporais e espectrais antes da reconstrução do sinal.

Tabela 1. Classes utilizadas pelo *ICLabel* para categorização dos componentes independentes.

Classe	Descrição
<i>Brain</i>	Componentes associados predominantemente à atividade neural cortical de interesse.
<i>Eye</i>	Componentes relacionados a piscadas, movimentos oculares horizontais e verticais.
<i>Muscle</i>	Componentes associados à atividade mioelétrica, especialmente de musculatura facial e cervical.
<i>Heart</i>	Componentes relacionados à atividade cardíaca e interferências pulsáteis.



Classe	Descrição
<i>Line Noise</i>	Componentes associados a ruído de rede elétrica e interferências periódicas externas.
<i>Channel Noise</i>	Componentes relacionados a mau contato, eletrodos defeituosos ou ruído localizado de canal.
<i>Other</i>	Componentes sem classificação dominante clara ou padrões mistos não enquadrados nas demais classes.

Desse modo, além das métricas quantitativas, foram realizadas análises visuais por mapas topográficos e inspeção. Os mapas topográficos foram utilizados para analisar a distribuição espacial da potência após o processamento, permitindo identificar regiões do escalpo com maior contribuição artefactual. A inspeção das componentes independentes no domínio do tempo permitiu observar diretamente a atenuação de deflexões abruptas em canais frontais, especialmente relacionadas a piscadas e movimentos oculares (Fatourechi et al., 2007; Uriguen e Garcia-Zapirain, 2015).

Dessa forma, a metodologia combinou avaliação estatística, classificação automática e inspeção visual, buscando verificar não apenas o desempenho quantitativo da ICA, mas também a preservação morfológica e espacial dos registros EEG após o processamento por Infomax Estendido.

ICA e Infomax Estendido

Dentre as técnicas de problema de Separação Cega de Fontes (BSS, do inglês Blind Source Separation), os algoritmos de ICA são comumente aplicados em cenários nos quais se parte de fontes estatisticamente independentes (Hyvärinen e Oja, 2000; Bell e Sejnowski, 1995).

Ao utilizarmos a BSS no processamento de sinais de EEG, é assumido que os sinais observados são uma combinação linear instantânea das fontes correspondentes à atividade cerebral e aos artefatos, podendo ser descritos como:

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

em que $\mathbf{x}(t) \in \mathbb{R}^m$ representa o vetor de sinais medidos nos m eletrodos no instante t , $\mathbf{s}(t) \in \mathbb{R}^n$ representa o vetor, em que no máximo uma pode ser gaussiana, $\mathbb{R}^{m \times n}$ corresponde à matriz de mistura desconhecida.

Para a realização de BSS por meio da ICA, é estimada uma matriz de separação $\mathbf{W}$ tal que:

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

em que $\mathbf{y}(t)$ representa os componentes independentes, as quais correspondem de $\mathbf{s}(t)$ a menos

de ambiguidades de permutação e escala. No algoritmo Infomax Estendido, a matriz $\mathbf{W}$ é atualizada iterativamente segundo o critério Infomax, buscando levar em conta a estimativa da curtose das fontes, permitindo assim a separação de componentes independentes supergaussianos e subgaussianos (Lee et al., 1999).

Mutual Information Reduction (MIR)

A qualidade da separação foi avaliada por meio da MIR, relacionada à quantificação da independência das componentes estimadas.

A MIR é expressa por:


$$\begin{aligned} \text{MIR} &= I_{\text{EEG}} - I_{\text{ICs}} \\ &= \log|\det(\mathbf{W})| + [h(x_1) + \dots + h(x_N)] \\ &\quad - [h(y_1) + \dots + h(y_N)] \end{aligned} \quad (3)$$

em que I_{EEG} representa a informação mútua dos sinais de EEG medidos, I_{ICs} informação mútua das componentes extraídas, $\mathbf{W}$ corresponde à matriz de separação estimada pela ICA, e $h(\cdot)$ representa a entropia diferencial de cada variável aleatória (Hyvärinen e Oja, 2000; Bell e Sejnowski, 1995), estimada a partir da distribuição obtida via histograma. Assim, valores mais elevados de MIR indicam maior independência estatística entre componentes e melhor desempenho da decomposição ICA. Em termos práticos, a MIR atua como indicativo de eficiência de neural de interesse e os artefatos.

RESULTADOS E DISCUSSÃO

Os resultados mostrados na Figura 1 evidenciaram desempenho consistente do algoritmo Infomax Estendido no conjunto de quinze pacientes avaliados, indicando capacidade de separação entre componentes neurais e artefatuais mesmo diante da heterogeneidade clínica observada, incluindo ampla faixa etária, diferentes manifestações motoras da Doença de Parkinson, níveis variáveis de tremor e rigidez muscular, bem como distintas cargas artefatuais presentes nos registros EEG. Os valores positivos de MIR em todos os pacientes indicam que o Infomax Estendido promoveu o aumento consistente da independência estatística entre os sinais, favorecendo a separação entre componentes cerebrais e artefatos. A distribuição da MIR evidencia desempenho estável do método, mesmo diante da variabilidade entre pacientes. O intervalo de valores observados (0,126 a 0,154) pode estar associado a diferenças na intensidade de artefatos e na complexidade dos sinais medidos. Os maiores valores, observados em S07 e S13, sugerem maior ganho de separação nesses casos, possivelmente devido a maior presença inicial de artefatos ou maior independência entre as fontes, apontando para a robustez do Infomax Estendido em cenários clínicos heterogêneos.

Tabela 2. Valores de MIR por paciente após o processamento por Infomax Estendido.



A variabilidade entre pacientes de DP é esperada em bases clínicas, influenciada por tremor, piscadas, rigidez muscular e instabilidade postural. A inspeção visual no domínio temporal complementou os resultados quantitativos. Para exemplificação na Figura 2, selecionou-se automaticamente uma janela representativa de 5 segundos do paciente S15, contemplando os eletrodos frontais Fp1, Fp2, Fpz, AF7, AF3, AFz, AF4 e AF8. A seleção automática priorizou o trecho com maior energia global e maior discrepância entre os sinais antes e após o processamento, favorecendo a visualização dos efeitos da remoção de artefatos.

Na Figura observa-se, redução de deflexões, compatíveis com piscadas, movimentos oculares e interferências mioelétricas frontais. Após o processamento, os sinais resultantes tornam-se visualmente mais estáveis, com redução de artefatos correspondentes a oscilações de alta amplitude, preservando simultaneamente a dinâmica temporal dos sinais neurais subjacentes.




Figura 2. Comparação entre os sinais antes e após o processamento no domínio do tempo.

Esse comportamento sugere que o Infomax Estendido atuou predominantemente sobre componentes artefatuais, sem comprometer de forma relevante a estrutura temporal do EEG de interesse. Para complementar a descrição da análise visual dos componentes independentes, foi selecionado, como

exemplo, o componente IC1 de S15, correspondente ao mesmo registro utilizado na Figura 2, antes da remoção dos artefatos. Esse componente apresentou forte associação com a classe *Eye* pelo classificador *ICLabel*, com probabilidade de 99,3%, indicando predominância de atividade ocular.




Figura 3. Caracterização do componente independente IC1 da paciente S15, classificado como *Eye* pelo *ICLabel*, com probabilidade de 99,3%.

Na Figura 3, observa-se padrão topográfico com maior concentração frontal, compatível com artefatos oculares, como piscadas e movimentos dos olhos. A série temporal do componente apresenta deflexões abruptas de maior amplitude, comportamento típico de eventos oculares transientes. Além disso, o espectro de potência evidencia predominância em baixas frequências, característica frequentemente associada a artefatos de origem ocular em sinais EEG. Essas evidências reforçam a importância da inspeção conjunta entre mapa topográfico, atividade temporal, espectro de potência e classificação automática por *ICLabel*. A identificação desse componente como artefato justificou sua remoção antes da reconstrução do sinal, contribuindo para a redução de contaminações frontais e para a melhoria da qualidade dos registros após o processamento por Infomax Estendido. Observou-se, na análise qualitativa individual, redução de artefatos frontais, diminuição de ruído muscular periférico e melhor organização temporal dos registros em diferentes perfis de sinal. A classificação automática por *ICLabel* mostrou predominância das classes *Eye*, *Muscle* e *Other*, coerente com de pacientes com DP. Em conjunto, esses achados demonstram que o Infomax Estendido constitui alternativa robusta para o pré-processamento de sinais de EEG em pacientes de DP com potencial aplicação em protocolos de monitoramento funcional, estudos de biomarcadores e futuras interfaces cérebro-computador.

CONCLUSÃO

Este trabalho avaliou o algoritmo Infomax Estendido no pré-processamento de sinais EEG de quinze pacientes com Doença de Parkinson, em registros clínicos reais com 64 canais. Os valores positivos de MIR em todos os pacientes evidenciaram o aumento



da independência estatística entre canais e eficiência na separação cega de fontes. As análises qualitativas confirmaram atenuação de artefatos oculares e musculares, maior estabilidade temporal e preservação da morfologia dos sinais neurais. Conclui-se que o Infomax Estendido constitui ferramenta eficaz para o processamento de EEG em pacientes com Doença de Parkinson, especialmente em bases clínicas reais. Como perspectivas futuras, sugerem-se comparações com outros algoritmos de ICA e integração com métodos para identificação de biomarcadores neurofisiológicos e interfaces cérebro-computador.

AGRADECIMENTOS

Os autores agradecem à CAPES, à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Processo nº 2022/03243-0, à Universidade Federal do ABC e ao Hospital Santa Marcelina pelo apoio institucional e disponibilização dos dados utilizados nesta pesquisa.

REFERÊNCIAS

ALJALAL, M.; ALDOSARI, S. A.; ALSHARABI, K.; ABDURRAQUEEB, A. M.; ALTURKI, F. A. Parkinson's disease detection from resting-state EEG signals using common spatial pattern, entropy, and machine learning techniques. *Diagnostics*, v. 12, n. 5, p. 1033, 2022.

BELL, A.; SEJNOWSKI, T. J. An information-maximization approach to blind separation and blind deconvolution. *Neural Computation*, v. 7, n. 6, p. 1129–1159, 1995.

BIOSEMI. 64-channel electrode cap layout. Disponível em: https://www.biosemi.com/pics/cap_64_layout_medium.jpg

. Acesso em: 30 abr. 2026.

BLANKERTZ, B. et al. The Berlin brain-computer interface: progress beyond communication and control. *Frontiers in Neuroscience*, v. 2, n. 3, p. 1–13, 2008.

COELLI, S. et al. Selecting methods for a modular EEG pre-processing pipeline: a quantitative evaluation framework. *Biomedical Signal Processing and Control*, v. 92, p. 106104, 2024.

DELORME, A.; MAKEIG, S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics. *Journal of Neuroscience Methods*, v. 134, n. 1, p. 9–21, 2004.

FATOURECHI, M. et al. EMG and EOG artifacts in brain computer interface systems: a survey. *Clinical Neurophysiology*, v. 118, n. 3, p. 480–494, 2007.

HYVÄRINEN, A.; OJA, E. Independent component analysis: algorithms and applications. *Neural Networks*, v. 13, n. 4–5, p. 411–430, 2000.

JANKOVIC, J. Parkinson's disease: clinical features and diagnosis. *Journal of Neurology, Neurosurgery & Psychiatry*, v. 79, n. 4, p. 368–376, 2008.

KLUG, M.; GRAMANN, K. Identifying key factors for improving ICA-based decomposition of EEG data. *European Journal of Neuroscience*, v. 51, n. 10, p. 1978–1994, 2020.

LEE, S.; HUSSEIN, R.; WARD, R.; WANG, Z. J.; MCKEOWN, M. J. A convolutional-recurrent neural network approach to resting-state EEG classification in Parkinson's disease. *Journal of Neuroscience Methods*, v. 361, p. 109282, 2021.

LEE, T. W.; GIROLAMI, M.; SEJNOWSKI, T. J. Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources. *Neural Computation*, v. 11, n. 2, p. 417–441, 1999.

LOTTE, F. et al. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of Neural Engineering*, v. 15, n. 3, p. 031005, 2018.

MAKEIG, S. et al. Independent component analysis of EEG data. *Advances in Neural Information Processing Systems*, p. 145–151, 1996.

PION-TONACHINI, L.; KREUTZ-DELGADO, K.; MAKEIG, S. ICLabel: an automated electroencephalographic independent component classifier. *NeuroImage*, v. 198, p. 181–197, 2019.

URIGUEN, J.; GARCIA-ZAPIRAIN, B. EEG artifact removal: state-of-the-art and guidelines. *Journal of Neural Engineering*, v. 12, n. 3, p. 031001, 2015.