



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Engenharia Elétrica



Trabalho de Conclusão de Curso

Análise de técnicas de extração de características de sinais cerebrais no âmbito do desenvolvimento de sistemas BCI/SSVEP

Weld Lucas Cunha

João Monlevade, MG
2016

Weld Lucas Cunha

**Análise de técnicas de extração de
características de sinais cerebrais no âmbito do
desenvolvimento de sistemas BCI/SSVEP**

Trabalho de Conclusão de curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica pelo Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto.

Orientadora: Prof.^a Sarah Negreiros de Carvalho Leite

**Universidade Federal de Ouro Preto
João Monlevade
2016**

C972a Cunha, Weld Lucas

Análise de técnicas de extração de características de sinais cerebrais no âmbito do desenvolvimento de sistemas BCI/SSVEP. [Manuscrito]./ Weld Lucas Cunha. - 2016.

38 f. : il.

Orientador: Profª Dra. Sarah Negreiros de Carvalho Leite.

Monografia (curso de graduação em Engenharia Elétrica) Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Departamento de Engenharia de Elétrica.

1. Engenharia Elétrica. 2. Interface cérebro-computador. 3. Processamento de sinais. 4. Eletroencefalografia. 5. Potencias evocados. I. Universidade Federal de Ouro Preto. II. Título.

CDU 004.5

Catálogo: bibjmv@sisbin.ufop.br



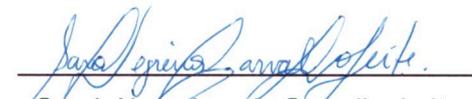
ANEXO IV - ATA DE DEFESA

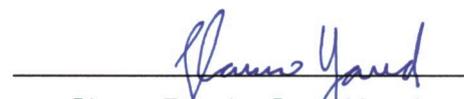
Aos **10** dias do mês de **março** de **2016**, às **14** horas, no bloco **H** deste instituto, foi realizada a defesa de monografia pelo formando **Weld Lucas Cunha**, sendo a comissão examinadora constituída pelos professores: **Matheus Wanderley Romão**, **Glauco Ferreira Gazel Yared** e **Sarah Negreiros de Carvalho Leite (orientadora)**. O candidato apresentou a monografia intitulada: **Análise de técnicas de extração de características de sinais cerebrais no âmbito do desenvolvimento de sistemas BCI/SSVEP**. A comissão examinadora deliberou, por unanimidade, pela APROVAÇÃO do candidato, com a nota média 9.5, de acordo com a Tabela 1. Na forma regulamentar foi lavrada a presente ata que é assinada pelos membros da comissão examinadora e pelo formando.

Tabela 1 – Notas de avaliação da banca examinadora

Banca Examinadora	Nota
Matheus Wanderley Romão	9.5
Glauco Ferreira Gazel Yared	9.5
Sarah Negreiros de Carvalho Leite	9.5
Média	9.5

João Monlevade, 10 de março de 2016.


Sarah Negreiros de Carvalho Leite
Professora Orientadora


Glauco Ferreira Gazel Yared
Professor Convidado


Matheus Wanderley Romão
Professor Convidado


Weld Lucas Cunha
Aluno



ANEXO X - TERMO DE RESPONSABILIDADE

O texto do trabalho de conclusão de curso intitulado “**Análise de técnicas de extração de características de sinais cerebrais no âmbito do desenvolvimento de sistemas BCI/SSVEP**” é de minha inteira responsabilidade. Declaro que não há utilização indevida de texto, material fotográfico ou qualquer outro material pertencente a terceiros sem a devida citação ou consentimento dos referidos autores.

João Monlevade, 10 de março de 2016.

Weld Lucas Cunha

Aluno

Agradecimentos

Agradeço primeiramente a Deus por ter me dado força e perseverança para jamais desistir perante os desafios que enfrentei em minha caminhada. Agradeço aos meus professores da Escola Estadual Antônio Mendes da Silva, que me motivaram e acreditaram em meu potencial nos meus primeiros passos rumo à este objetivo.

Agradeço a todos os professores do Instituto de Ciências Exatas e Aplicadas, os quais contribuíram grandemente para a minha formação, através dos ensinamentos passados nestes anos de graduação. Agradeço fortemente a todos os meus companheiros de jornada: os grandes amigos e colegas de curso que tive a oportunidade de conhecer na cidade de João Monlevade.

Agradeço de forma especial à professora Sarah Negreiros por ter aceitado ser minha orientadora neste Trabalho de Conclusão de Curso. Não há palavras para descrever a minha gratidão pela excelente experiência que tive como seu orientado.

Agradeço à toda a minha família, meus pais, irmão, primos, tios e avós que sempre me apoiaram e me deram força para seguir em frente na busca dos meus objetivos.

*"Conheça todas as teorias,
domine todas as técnicas,
mas ao tocar uma alma humana,
seja apenas outra alma humana."
– Carl Gustav Jung*

Resumo

Este trabalho tem como objetivo principal a implementação da etapa de processamento de sinais de uma interface cérebro-máquina ou BCI (do inglês: *Brain Computer Interfaces*) coletados sob o paradigma SSVEP (*Steady-State Visually Evoked Potentials*), visando:

1. Estabelecer a comparação entre dois métodos de extração de características: Método de Welch aplicado à extração espectral e o Método de Burg aplicado à modelagem de parâmetros autorregressivos;
2. Avaliar o efeito do janelamento sobre a taxa de acerto na etapa de classificação dos sinais coletados, com e sem *overlap*;
3. Determinar o comprimento de janela mais apropriado, para extração de características, em aplicações assistivas;
4. Analisar os efeitos da aplicação do método de filtragem espacial *Common Average Reference* (CAR) sobre a taxa de acerto obtida nas configurações testadas de extração temporal.

Foram utilizadas as seguintes técnicas nas etapas de pré-processamento, extração de características e classificação: CAR, Método de Welch e Método de Burg e discriminantes lineares (LDA) baseado no método dos mínimos quadrados, respectivamente. Durante a implementação do sistema houve preocupação com sua eficiência, além de se levar em consideração sua possível aplicabilidade em tecnologias assistivas. Dos resultados, constatou-se que é possível a implementação de um sistema BCI/SSVEP de dois comandos com taxas de acerto elevadas, próximas a 100%, utilizando-se opções de janelamento apropriadas para aplicações assistivas. Também foi possível constatar que a extração de características baseado no método de Welch proporcionou melhores resultados que o do método de Burg na etapa de classificação. Apresentando taxas de acerto mais elevadas, acima de 90%, utilizando-se de janelas apropriadas à aplicações assistivas, enquanto a técnica que utiliza parâmetros autorregressivos apresentou valores entre 60% e 80% para as mesmas configurações.

Palavras-chave: Interface Cérebro-Computador, BCI, SSVEP, Filtragem Espacial, Common Average Reference (CAR), Método de Welch, Método de Burg, Parâmetros autorregressivos, Discriminantes lineares, LDA.

Abstract

This work has as main objective the implementation of the signal processing stage of a BCI (Brain-Computer Interface) collected under the SSVEP (Steady-State Visually Evoked Potentials) paradigm, aiming to: 1. Compare two features extraction techniques: Welch's method applied to spectral extraction and Burg's method applied to the modeling of autoregressive parameters; 2. Evaluate the effect of windowing over accuracy rate in the classification stage of the collected signals, with and without overlap; 3. Determine the more appropriate window length, for feature extraction, considering assistive applications; 4. Analyse the effect of the spatial filtering technique Common Average Reference (CAR) over the accuracy rates obtained from the configurations tested in the temporal features extraction. The following techniques were used in the pre-processing, features extraction and classification stages: CAR, Welch's method and Burg's method and linear discriminant (LDA) based on the least squares method, respectively. During the system's implementation there was some concern with its efficiency, besides taking into consideration its possible applicability in assistive technologies. From the results, we was found that the implementation of a two-commandsm SSVEP-BCI system with high accuracy rates, close to 100%, using appropriate window lengths for assistive applications is possible. We also concluded that the features extraction based on Welch's method has a better performance then Burg's method in the classification stage. Presenting higher accuracy rates, over 90%, using appropriate window lengths for assistive applications, while the technique based on autoregressive parameters presented accuracy rates between 60% and 80% for the same settings.

Keywords: Brain Computer Interface, BCI, SSVEP, Spatial Filtering, Common Average Reference (CAR), Welch's method, Burg's method, Autoregressive parameters, Linear discriminants, LDA.

Lista de ilustrações

Figura 1 – Esquematização de uma BCI baseada no paradigma SSVEP.	3
Figura 2 – Estrutura dos módulos de uma BCI proposto por Schalk et al. (2004). .	4
Figura 3 – Exemplo de estímulo visual exposto aos voluntários.	8
Figura 4 – Disposição dos canais utilizados para leitura da atividade cerebral. . . .	9
Figura 5 – Efeito da aplicação da filtragem espacial CAR no tempo e na frequência. 10	
Figura 6 – Representação da segmentação dos dados no método de Welch.	12
Figura 7 – Desempenho do classificador - 6 Hz e 7.5 Hz - Método de Welch.	16
Figura 8 – Desempenho do classificador - 12 Hz e 15 Hz - Método de Welch.	17
Figura 9 – Desempenho do classificador - 20 Hz e 30 Hz - Método de Welch.	18
Figura 10 – Densidade espectral de potência em 12 Hz - Janela de 12 s.	19
Figura 11 – Densidade espectral de potência em 12 Hz - Janela de 6 s.	20
Figura 12 – Densidade espectral de potência em 12 Hz - Janela de 4 s.	20
Figura 13 – Densidade espectral de potência em 12 Hz - Janela de 3 s.	21
Figura 14 – Densidade espectral de potência em 12 Hz - Janela de 2 s.	21
Figura 15 – Densidade espectral de potência em 12 Hz - Janela de 1 s.	22
Figura 16 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 2 s.	23
Figura 17 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 3 s.	24
Figura 18 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 4 s.	24
Figura 19 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 6 s.	25
Figura 20 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 12 s.	25
Figura 21 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 2 s.	27
Figura 22 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 3 s.	27
Figura 23 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 4 s.	28
Figura 24 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 6 s.	28
Figura 25 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 12 s.	29
Figura 26 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 2 s.	30
Figura 27 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 3 s.	30
Figura 28 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 4 s.	31
Figura 29 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 6 s.	31
Figura 30 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 12 s.	32

Sumário

1	INTRODUÇÃO	1
1.1	Conceitos Fundamentais	1
1.2	Revisão Bibliográfica	3
1.3	Estado da Arte	6
1.4	Objetivos	7
1.5	Estrutura do Trabalho	7
2	METODOLOGIA	8
2.1	Pré-Processamento	9
2.2	Extração de Características	11
2.2.1	Análise Espectral: Método de Welch	11
2.2.2	Análise Temporal: Coeficientes Autorregressivos	13
2.3	Classificação	14
3	RESULTADOS E DISCUSSÃO	16
3.1	Análise Espectral: Método de Welch	16
3.2	Análise Temporal: Coeficientes Autorregressivos	23
3.2.1	Par de Frequências: 6 Hz e 7.5 Hz	23
3.2.2	Par de Frequências: 12 Hz e 15 Hz	27
3.2.3	Par de Frequências: 20 Hz e 30 Hz	30
4	CONCLUSÃO	34
4.1	Considerações Finais	34
4.2	Trabalhos Futuros	35
	REFERÊNCIAS	36

1 Introdução

A sociedade moderna tem apresentado um desenvolvimento científico/tecnológico bastante acelerado nos últimos anos. Como consequência disso, muitos paradigmas tidos como limites para o desenvolvimento até pouco tempo atrás foram ultrapassados, dando espaço para o surgimento de novos desafios e realimentando a necessidade de se evoluir ainda mais. Novas tecnologias tem surgido cada vez mais rapidamente, alterando a maneira como se vive e contribuindo para a evolução da sociedade. Este desenvolvimento é resultado do trabalho de inúmeros profissionais das mais diversas áreas do saber. Graças a eles, avanços tecnológicos foram possíveis, a cura de muitas doenças foram descobertas, novos tratamentos foram desenvolvidos e hoje muitas pessoas doentes tem esperança de uma vida melhor.

Neste trabalho é apresentada uma tecnologia que, apesar de ainda ser incipiente, tem mostrado resultados animadores e poderá trazer novidades impactantes nos próximos anos. O desenvolvimento de interfaces cérebro-computador ou BCI's (do inglês: *Brain Computer Interfaces*) tem desafiado cientistas e engenheiros do mundo todo. Estes se vislumbram com as possíveis aplicações desta tecnologia que poderá vir a revolucionar a forma como o homem interage com as máquinas, e consequentemente, com o mundo.

1.1 Conceitos Fundamentais

BCI's vem se desenvolvendo bastante, especialmente nos últimos anos. São muitas as possíveis aplicações desta tecnologia, sendo que, grande parte delas são voltadas à área médica. Muitos pacientes que sofrem de uma grande variedade de doenças como a esclerose lateral amiotrófica (ELA), paralisia, vítimas de acidente vascular cerebral, etc. acabam perdendo a capacidade de se locomover e muitas vezes até de se comunicar. A BCI, por ser um sistema que permite a comunicação direta entre o cérebro humano e dispositivos externos, se apresenta como um meio alternativo de comunicação que permite a melhoria da qualidade de vida dessas pessoas.

Em uma interface cérebro-computador, a atividade cerebral do indivíduo que a utiliza é registrada e o sinal adquirido é processado com a finalidade de se obter as informações relevantes à comunicação. Na sequência, esta informação é transmitida ao meio externo possibilitando a comunicação ou a tomada de decisão, gerando assim, um sinal de controle que pode ser enviado a uma determinada aplicação.

Levando em consideração a forma como são gerados os padrões fisiológicos cerebrais, há algumas estratégias que são comumente empregadas na implementação de BCI's. A imagética motora (GROSSE-WENTRUP, 2009), potenciais P300 (SELLERS et al., 2006) e SSVEP (*Steady-State Visually Evoked Potentials*) (MÜLLER-PUTZ; PFURTSCHEL-

LER, 2008) são estratégias que têm se destacado e vêm sendo amplamente utilizadas e desenvolvidas nos últimos anos. Na primeira técnica citada, imagética motora, o indivíduo deve imaginar que está realizando o movimento de determinada parte do corpo, e dessa forma a sua atividade cerebral é registrada. Esta técnica tem apresentado resultados de classificação satisfatórios segundo Kübler et al. (2005). As duas últimas técnicas citadas têm em comum o fato de utilizarem estímulos visuais com a finalidade de excitar zonas cerebrais específicas, podendo inclusive serem combinadas para a melhoria da performance do sistema, como mostram Amiri et al. (2013). A técnica P300 se baseia na leitura de um determinado potencial evocado que surge 300 ms após a estimulação da atividade cerebral, na região occipital do cérebro (MING et al., 2010). A estratégia de BCI que utiliza o paradigma SSVEP, tem como fundamento a leitura do potencial evocado na região do lobo occipital, o qual possui a mesma frequência de intermitência, ou suficientemente próxima, do sinal visual que o gerou, em regime permanente e suas harmônicas (VIALATTE et al., 2010). No desenvolvimento deste trabalho, os sinais utilizados foram coletados sob o paradigma SSVEP.

Há diversas técnicas utilizadas para se registrar a atividade cerebral de um indivíduo em aplicações relacionadas a BCI's. As técnicas mais utilizadas para essa atividade são baseadas na atividade elétrica ou magnética do cérebro, podendo ser classificadas como invasivas ou não invasivas (MILLÁN; CARMENA, 2010), conforme a necessidade ou não de métodos cirúrgicos para a sua implantação. As técnicas não invasivas, geralmente, apresentam menor custo e mais praticidade, além de serem mais seguras. Por outro lado, as técnicas invasivas apresentam melhor qualidade do sinal coletado, além de possibilitarem a coleta de sinais em regiões mais específicas do cérebro. Entretanto, são mais caras e apresentam mais riscos ao paciente.

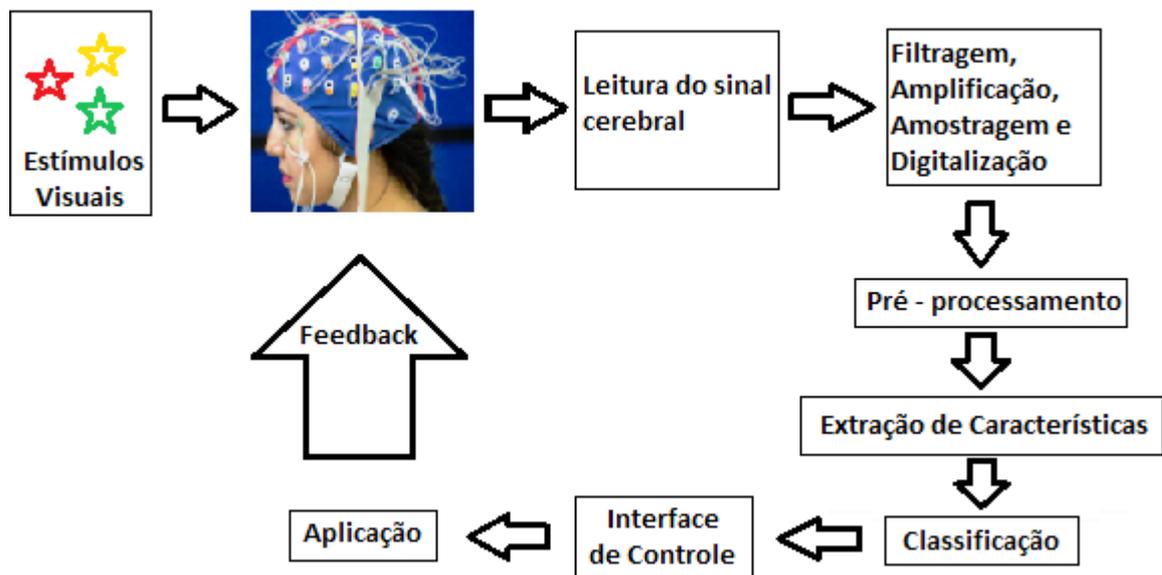
Destacam-se como técnicas de registro da atividade cerebral: eletroencefalografia (EEG) (NEUPER et al., 2003), magnetoencefalografia (MEG) e eletrocorticograma (ECoG), dentre outras. Utilizou-se neste trabalho a técnica EEG, a qual tem se destacado em aplicações com BCI's, por apresentar características apropriadas à este tipo de projeto: o fato de ser não invasiva, apresentar baixo custo e fácil portabilidade. Nesta abordagem, para que a atividade elétrica do cérebro possa ser registrada é necessário que eletrodos sejam posicionados sobre o couro cabeludo do paciente, utilizando-se uma touca especialmente projetada para tal atividade. A diferença de potencial elétrico gerado, devido a excitação visual, pode ser medida pela EEG juntamente com ruídos do ambiente e outras interferências externas.

Após o registro da atividade cerebral, esta informação é filtrada, amplificada, amostrada e digitalizada, para então, ser processada em tempo real pela BCI. O processamento do sinal é dividido em três etapas: pré-processamento, extração de características e classificação. A etapa de pré-processamento visa aprimorar a qualidade do sinal, melhorando a relação sinal-ruído do sinal cerebral. Na etapa da extração de características são calculados

os parâmetros que permitem identificar e distinguir qual comando o usuário pretende gerar. Após esta etapa, o classificador deve determinar a classe a qual as características extraídas na etapa anterior pertencem e gerar o sinal de controle.

O sinal de controle, por meio de uma interface, pode ser utilizado em diversas aplicações, comandadas pelo usuário através da BCI. O esquema completo de uma interface cérebro-máquina pode ser observado na Figura 1:

Figura 1 – Esquemática de uma BCI baseada no paradigma SSVEP.



Fonte: Do autor.

1.2 Revisão Bibliográfica

O desenvolvimento de interfaces cérebro-computador deve-se a fundamentos que surgiram desde os primórdios do século XX. Uma contribuição muito importante foi dada pelo cientista alemão Dr. Hans Berger no ano de 1929, que foi pioneiro no registro de sinais cerebrais de seres humanos utilizando a técnica EEG. Realizar este tipo de trabalho era uma atividade bastante desafiadora devido às muitas dificuldades existentes, principalmente devido ao baixo poder computacional e à limitada capacidade de processamento dos computadores da época.

Em 1964, outro episódio teve grande importância no desenvolvimento de BCI's. Neste ano, o Dr. Grey Walter implementou um sistema que pode ser considerado como uma das primeiras interfaces cérebro-máquina (GRAIMANN; ALLISON; PFURTSCHELLER, 2010). Eletrodos foram conectados diretamente à região do cérebro responsável pelos movimentos de um determinado paciente, o qual estava passando por um processo cirúrgico devido a outros motivos. Dr. Walter foi capaz de registrar a atividade cerebral de seu

paciente e utilizar esta informação, proveniente diretamente do cérebro, em um sistema no qual seu paciente era capaz de avançar os slides de um projetor por meio, apenas, da sua atividade cerebral. Infelizmente, não há muitos registros sobre seu trabalho, o qual não foi publicado.

Uma das contribuições mais importantes do século XX, para o desenvolvimento de BCI's foi dada por Jacques J. Vidal, em 1977 (VIDAL, 1977). Seu trabalho evidencia a possibilidade de detecção e classificação, em tempo real, de potenciais relacionados a eventos ou ERP's (do inglês: *Event Related Potentials*). Passando a tratar este problema como um problema de detecção de sinais, no qual um número determinado de classes são previamente estabelecidas de acordo com uma determinada regra de decisão e cabe ao computador utilizar esta regra para classificar os novos dados a serem lidos pelo sistema.

O estudo e desenvolvimento de BCI's avançou muito lentamente até o fim do século XX, devido a limitações computacionais e tecnológicas. Porém, a partir do ano 2000, este campo de estudo passou a se desenvolver mais rapidamente em diversos centros de pesquisa ao redor do mundo. Alguns cientistas fizeram trabalhos importantes visando a melhoria do desempenho e precisão das BCI's, utilização de EEG aplicada à leitura de sinais cerebrais em tempo real e processamento de sinais visando o controle, também em tempo real, de aplicações relacionadas ao desenvolvimento de interfaces controladas por sinais cerebrais (WOLPAW; MCFARLAND; VAUGHAN, 2000; WOLPAW et al., 2002). No primeiro encontro internacional sobre o tema, em 2000, foram obtidos avanços significativos, dentre estes, uma importante definição de BCI foi estabelecida: "Uma interface cérebro-computador é um sistema de comunicação que não depende das vias de saída normais do cérebro: nervos e músculos". Esta definição é muito importante por estar diretamente ligada aos interesses dessa área de estudo (WOLPAW et al., 2000).

Trabalhos seguintes foram realizados no intuito de incentivar o desenvolvimento sistemático de BCI's. Mason e Birch (2003) dissertaram sobre as vantagens dos centros de pesquisa envolvidos com projetos desse campo de estudo trabalharem em sintonia, de forma que seus projetos tivessem maior compatibilidade. Schalk et al. (2004) propõem um modelo comum, para descrever qualquer sistema BCI, com quatro módulos que se comunicam entre si: Fonte (aquisição e armazenamento dos dados), Processamento do sinal, Interface de Controle e Aplicação.

Figura 2 – Estrutura dos módulos de uma BCI proposto por Schalk et al. (2004).



Fonte: Do autor.

Com a criação deste modelo esperava-se que houvesse uma padronização do desen-

volvimento desta tecnologia, com maior independência entre os componentes fundamentais da BCI, de forma que cada módulo pudesse ser projetado individualmente, da maneira mais eficiente possível.

Lebedev e Nicolelis (2006) evidenciaram alguns dos maiores desafios existentes para o contínuo desenvolvimento de BCI's: desenvolvimento de um dispositivo de registro de dados implantável e biologicamente compatível, aprimoramento de algoritmos de processamento de dados em tempo real, introdução de um método para prover *feedback* ao usuário e desenvolvimento e construção de próteses que possam ser controladas por sinais derivados da atividade cerebral. Também projetaram as suas visões de desenvolvimento de BCI's para os próximos 10 a 20 anos, vislumbrando a evolução da tecnologia existente em um sistema de registro de informações totalmente implantável, com possibilidade de se comunicar de maneira *wireless*, transmitindo múltiplos fluxos de informação simultaneamente de maneira instantânea, para um sistema BCI capaz de decodificar espacialmente e temporalmente as informações referentes aos movimentos e aos períodos intermitentes de imobilidade.

Birbaumer, Murguialday e Cohen (2008) tiveram como foco de seu trabalho a reabilitação de pacientes com paralisia, os quais se encontravam severamente debilitados, condição conhecida como *locked-in syndrome*, onde o paciente é totalmente incapaz de se movimentar ou se comunicar com o meio externo. Apresentaram as descobertas recém-obtidas em testes com primatas, cujos resultados levaram à conclusão de que movimentos dos membros superiores podem ser reconstruídos e transmitidos para manipulação externa. Destacaram o avanço dos estudos na área e a utilização de micro-eletrodos no registro de padrões cerebrais. Também destacaram a necessidade de desenvolvimento de aplicações neurológicas desta tecnologia, e que ainda há dificuldades metodológicas no desenvolvimento de BCI's. A necessidade de realização de mais experimentos, principalmente com pacientes de esclerose lateral amiotrófica, para confirmação experimental dos resultados obtidos em laboratório. Por fim, reafirmaram a possibilidade de restauração dos movimentos em pacientes com derrame cerebral crônico usando técnicas não invasivas, porém, indicaram a necessidade de mais experimentos para que essa tecnologia possa então, ser aplicada na melhoria da qualidade de vida de pacientes em situações reais.

Mak e Wolpaw (2009) seguiram suas linhas de pesquisa no sentido de transformar o desenvolvimento de BCI's, de projetos de laboratório específicos em aplicações sistemáticas, que pudessem ser empregadas em situações do mundo real. Focando inicialmente na área clínica e, posteriormente, identificando novas perspectivas futuras de aplicações para esta tecnologia em outras áreas. Evidenciaram também a multidisciplinaridade envolvida no desenvolvimento desta tecnologia, que requer profissionais de diferentes áreas como neurocientistas, engenheiros, matemáticos, cientistas da computação, psicólogos, neurologistas e especialistas em reabilitação clínica, dentre outros. O envolvimento de profissionais de diferentes áreas é crítico para que essa tecnologia possa alcançar o patamar de pleno desenvolvimento.

1.3 Estado da Arte

Atualmente, o desenvolvimento de interfaces cérebro-computador é um campo de pesquisa bastante promissor, apresentando muitos avanços nos últimos anos e sendo foco de estudo em diversos centros de pesquisa e tecnologia ao redor do mundo. Além disso, é vasto o leque de possíveis aplicações desta tecnologia para a melhoria da qualidade de vida da população e para o desenvolvimento científico. Millán e Carmena (2010) tratou sobre o desenvolvimento de BCI's, focando em aplicações para o mundo real, visando atender a necessidades de pessoas com deficiência. Destacou como principais aplicações desta tecnologia: Comunicação e Controle, Substituição Motora, Entretenimento e Recuperação Motora.

Novas estratégias de implementação vem sendo desenvolvidas visando melhorar o desempenho de BCI's. Krusienski et al. (2011) realizaram uma análise sobre algumas questões críticas e estratégias para o desenvolvimento de BCI's: examinando a relação entre eletroencefalografia e eletrocorticografia, novas ferramentas para predição etc. Brunner et al. (2011) analisaram o sistema BCI, relacionando cada etapa do processo da interface cérebro-máquina com o hardware e o software envolvidos. Resumiram, do ponto de vista técnico, cada uma dessas etapas. Chegaram à conclusão de que a tecnologia BCI se encontrava em transição, de demonstrações isoladas em laboratório caminhando rumo a se tornar uma pesquisa sistemática.

Hasan e Gan (2012), em seu trabalho, desenvolveram uma arquitetura que combina detecção *onset* e classificadores adaptativos, esta estrutura foi utilizada em um sistema testado com voluntários saudáveis os quais o utilizaram para jogar o jogo da forca. Os resultados mostraram melhoria significativa na performance da BCI, devido à arquitetura utilizada. O sistema desenvolvido apresentou maior precisão se comparado à arquitetura com apenas uma estratégia. Li et al. (2013) apresentaram um sistema híbrido aplicado ao controle de uma cadeira de rodas, que utiliza sinais P300 em adição ao paradigma SSVEP. Este trabalho apresentou melhoria no desempenho em termos de precisão da detecção e tempo de resposta, se comparada à arquiteturas que utilizam cada um destes paradigmas individualmente. Yin et al. (2014) também obtiveram bons resultados em seu estudo, utilizando essa mesma estratégia, arquitetura híbrida de P300 e SSVEP, em um dispositivo de soletração, o qual apresentou maior velocidade de soletração quando comparado com as técnicas de SSVEP e P300 convencionais.

Holz et al. (2015) conduziram um estudo sobre a implantação de um sistema BCI em uma residência, visando atender a um paciente com severas deficiências motoras por um longo período de tempo. Este trabalho também visava monitorar a qualidade de vida do paciente e sua satisfação ao utilizar o sistema. Os resultados possibilitaram concluir que o uso independente de BCI's em residências pode levar a uma melhora significativa da qualidade de vida do paciente, com grande satisfação do usuário.

1.4 Objetivos

Considerando o contexto de desenvolvimento de BCI's, utilizando-se do paradigma SSVEP, os objetivos deste trabalho são: Desenvolver a etapa de processamento de sinais de uma BCI, utilizando uma base de dados de sinais cerebrais coletada sobre o paradigma SSVEP, implementando as etapas de pré-processamento, extração de características e classificação; Comparar duas técnicas de extração de características: Extração Espectral (Método de Welch) e Extração Temporal (Método de Burg aplicado à modelagem de parâmetros autorregressivos); Avaliar o efeito do janelamento de sinais, com e sem *overlap*, delineando o tamanho ideal para aplicações assistivas e Avaliar os efeitos da aplicação da filtragem CAR nos casos de extração de características temporais.

1.5 Estrutura do Trabalho

Para melhor entendimento do trabalho desenvolvido, este foi dividido em quatro capítulos. No Capítulo 2 é apresentada toda a metodologia de desenvolvimento utilizada, as técnicas empregadas, assim como uma detalhada descrição de todo o procedimento de pré-processamento, extração das características e classificação das informações.

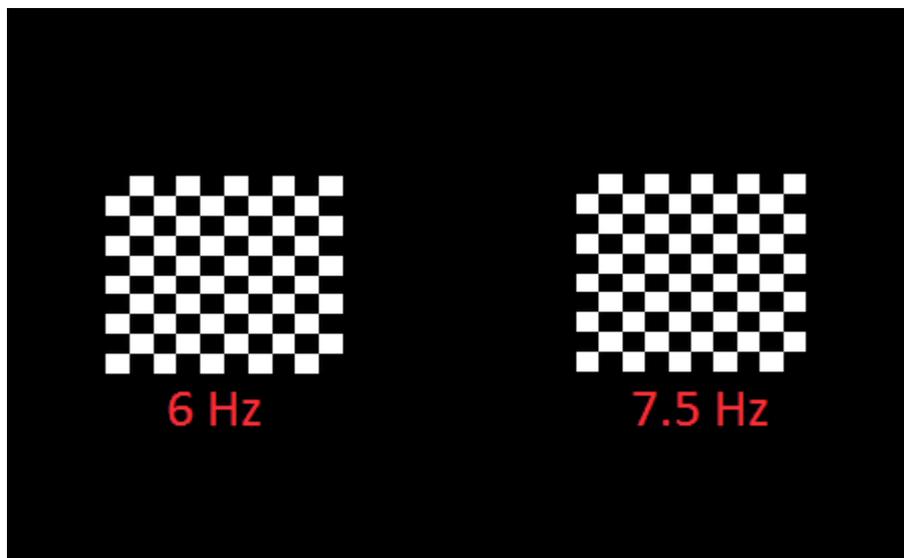
No Capítulo 3 são apresentados os resultados em diversos cenários de análise das técnicas de extração. Também é feita uma discussão crítica sobre os resultados e comentários sobre a performance apresentada pela BCI.

No Capítulo 4 é apresentada a conclusão do trabalho, levando em consideração os resultados apresentados no Capítulo 3. Também são feitas sugestões para trabalhos futuros.

2 Metodologia

A base de dados utilizada neste trabalho foi coletada na UNICAMP no âmbito do projeto DESTINE/FINEP (CARVALHO et al., 2015). A base conta com registro de sete voluntários, todos saudáveis, com idade média de 26.3 anos. Cada um destes voluntários foi exposto a três telas, onde haviam dois padrões visuais piscando com frequências diferentes conforme ilustra a Figura 3.

Figura 3 – Exemplo de estímulo visual exposto aos voluntários.

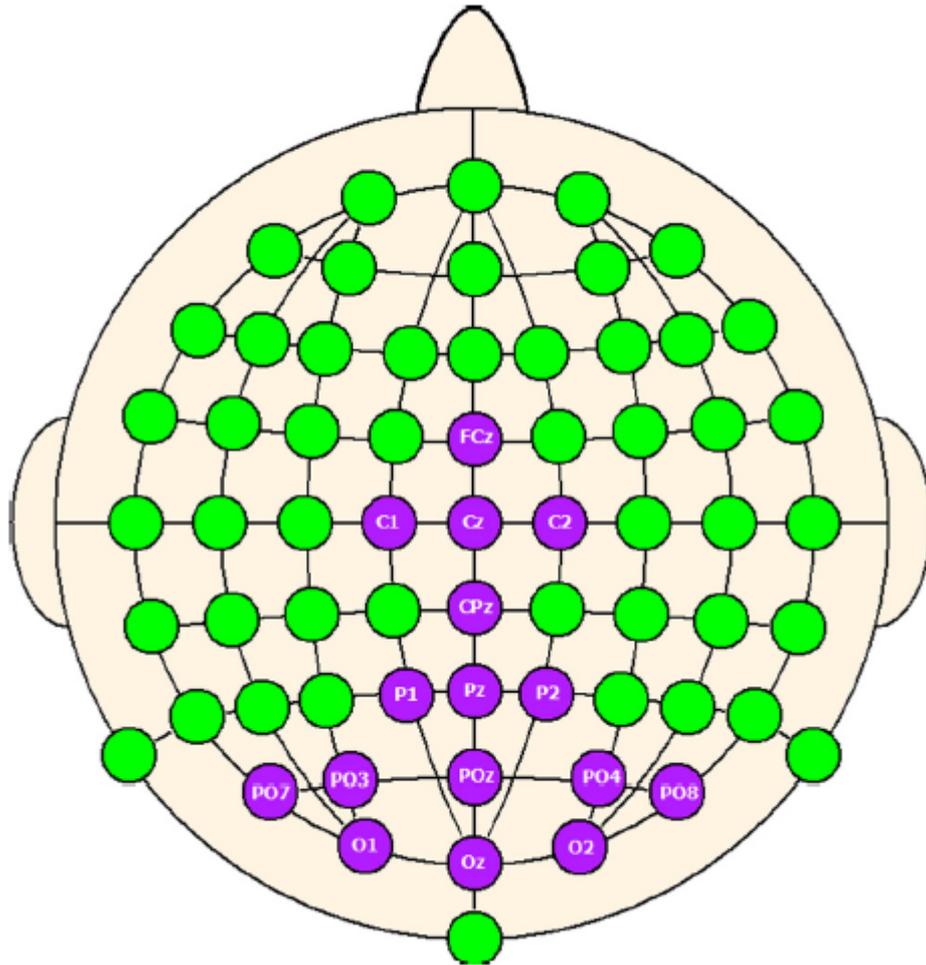


Fonte: Do autor.

Todos os voluntários foram orientados a focar sua visão em um estímulo visual de cada frequência por vez. Os pares de frequências utilizados foram: 6 Hz e 7.5 Hz, 12 Hz e 15 Hz, 20 Hz e 30 Hz. Para cada uma destas frequências foi feito um registro da atividade cerebral por meio de EEG. Cada voluntário realizou oito sessões de coleta para cada uma das frequências. Cada sessão teve duração de 12 segundos e a frequência de amostragem empregada foi de 256 Hz. Após a obtenção do sinal, este foi filtrado utilizando-se um filtro analógico passa-banda do tipo Butterworth na faixa de 5 a 60 Hz e um filtro notch na frequência de 60 Hz.

A disposição dos eletrodos respeitou o padrão internacional 10-20 (KLEM et al., 1999) que visa tornar mais eficiente a leitura da atividade cerebral, conforme a anatomia do cérebro (STEINMETZ; FÜRST; MEYER, 1989). Os 16 eletrodos utilizados foram posicionados nas posições O1, O2, Oz, POz, Pz, PO4, PO3, PO8, PO7, P2, P1, Cz, C1, C2, CPz e FCz, conforme mostra a Figura 4.

Figura 4 – Disposição dos canais utilizados para leitura da atividade cerebral.



Fonte: Do autor.

No desenvolvimento deste trabalho utilizou-se o software MATLAB® R2015a para a implementação da etapa de processamento de sinais da BCI onde foram realizados o pré-processamento, extração de características e classificação dos sinais.

2.1 Pré-Processamento

A técnica de pré-processamento utilizada neste trabalho foi a técnica CAR (do inglês: *Common Average Reference*) (LUDWIG et al., 2009; ALHADDAD, 2012). Trata-se de uma técnica de filtragem espacial (GARCIA-MOLINA; ZHU, 2011) bastante simples e eficiente, que visa melhorar a qualidade do sinal com a finalidade de facilitar a detecção dos potenciais evocados. Por ser simples, de fácil implementação e não demandar muito do sistema, esta técnica é promissora para aplicações em tempo real.

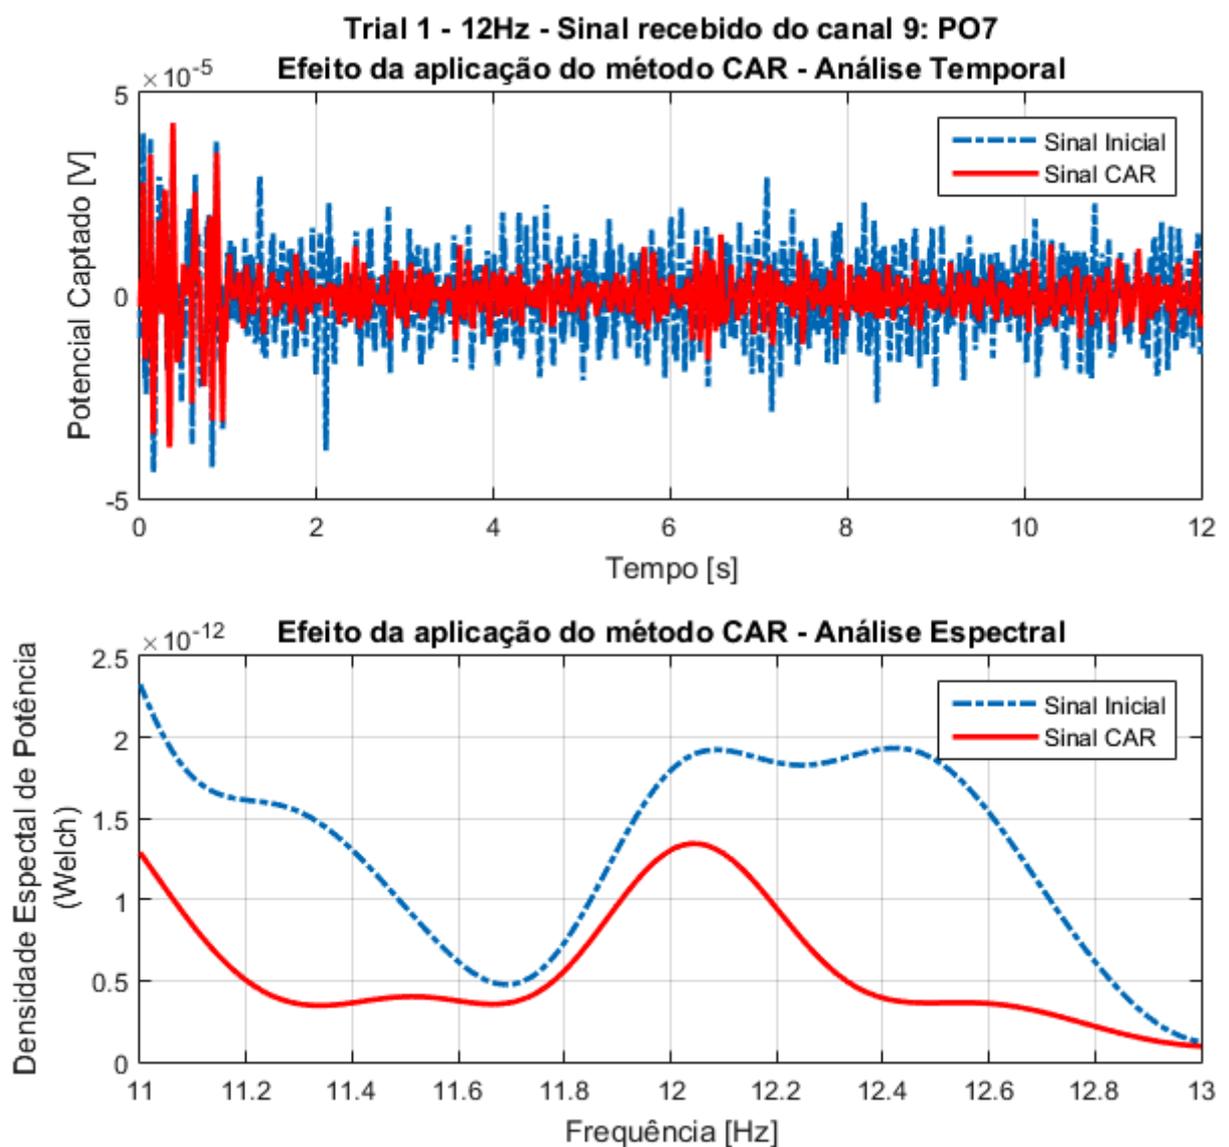
A técnica CAR baseia-se no cálculo do valor médio de todos os eletrodos em um determinado instante, em seguida, este valor médio é subtraído do valor obtido de cada eletrodos, conforme a Equação (2.1):

$$V_i^{CAR} = V_i^{eletrodo} - \frac{1}{n} \sum_{j=1}^n V_j^{eletrodo} \quad (2.1)$$

onde n é o número de eletrodos utilizados, neste caso: 16; $V_i^{eletrodo}$ é o potencial medido no eletrodo de número i ; e V_i^{CAR} é o potencial do eletrodo i após a aplicação da filtragem espacial CAR.

Esta técnica tem apresentado melhoria significativa na detecção de sinais de baixa amplitude em ambientes com presença de ruído, melhorando a qualidade do sinal coletado e auxiliando na remoção de ruído. Na Figura 5 pode-se observar o efeito da aplicação do método CAR em um sinal obtido com excitação visual em 12 Hz.

Figura 5 – Efeito da aplicação da filtragem espacial CAR no tempo e na frequência.



Fonte: Do autor.

Ao analisar a Figura 5, pode-se concluir por simples inspeção do sinal temporal, que este sinal sofreu atenuação, mas não é possível obter informações a respeito da frequência do estímulo visual, independente da aplicação da técnica CAR. Por outro lado, o gráfico do espectro do sinal indica informações relevantes ao estudo. Verifica-se que a densidade espectral de potência na frequência de interesse, 12 Hz, se tornou mais evidente que aquelas ao seu redor, quando comparado com o sinal antes da aplicação do método CAR. O pico próximo à frequência de 12 Hz se tornou mais nítido e a amplitude dos sinais nas frequências vizinhas foram reduzidas. Isto ocorreu devido à melhoria da relação sinal-ruído, retirando assim a informação que não é de interesse para a realização deste trabalho.

2.2 Extração de Características

A etapa de extração de características é de grande importância para a concepção de uma BCI. É nessa etapa que a informação de interesse é retirada dos sinais coletados e pré-processados. O paradigma SSVEP pode ser bem caracterizado por métricas extraídas da análise espectral ou temporal. Neste trabalho são empregadas análises nos seguintes contextos: o cálculo da densidade espectral de potência pelo método de Welch e por meio de coeficientes autorregressivos estimados pelo método de Burg.

2.2.1 Análise Espectral: Método de Welch

A técnica de análise espectral utilizada neste trabalho baseia-se no método proposto por Welch (1967). O método de Welch emprega a FFT (*Fast Fourier Transform*) (WALKER, 1996) para estimar a densidade de potência espectral. Durante o processo, os dados de cada leitura são seccionados em janelas temporais de um determinado comprimento, calcula-se os periodogramas modificados destas seções e o resultado é a média dos periodogramas de cada seção. O método de Welch apresenta algumas vantagens quando comparado com outras técnicas de análise espectral, por demandar menos cálculos. Além disso, devido à fragmentação dos dados é possível que sua implementação seja realizada em máquinas com menor capacidade de armazenamento de informação, visto que é realizada a aplicação do método em um segmento por vez.

O método de Welch se inicia com uma sequência de dados composta por N amostras, onde $X(j), j = 0, \dots, N - 1$ são amostras desta sequência. A amostra de dados inicial é seccionada em K segmentos de mesmo comprimento, com sobreposição ou não, onde cada um destes segmentos tem comprimento L . Os pontos iniciais de cada um destes segmentos estão afastados um dos outros por D pontos, conforme ilustrado na Figura 6. Tem-se:

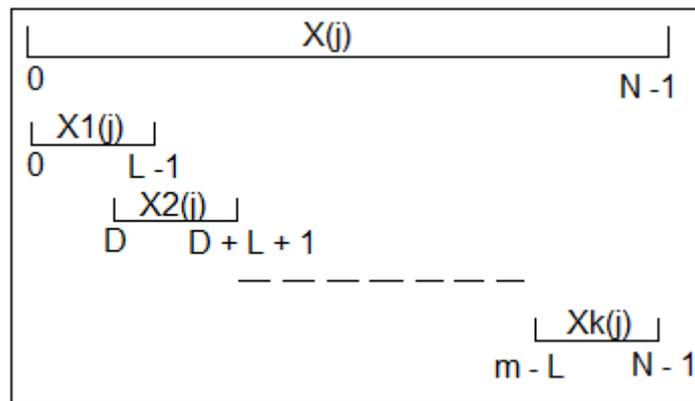
$$X_1(j) = X(j) \quad j = 0, \dots, L - 1 \quad (2.2)$$

$$X_2(j) = X(j + D) \quad j = 0, \dots, L - 1 \quad (2.3)$$

$$X_K(j) = X(j + (K - 1)D) \quad j = 0, \dots, L - 1 \quad (2.4)$$

Supõe-se que os K segmentos cubram todo o registro de dados, como mostra a Figura 6. Caso o comprimento dos segmentos não sejam divisores inteiros do comprimento total da janela, no caso deste trabalho: 12 s, a informação do último segmento é descartada do processo de extração. Para que não haja perda de informação, os comprimentos de janela utilizados na segmentação dos dados foram: 1 s, 2 s, 3 s, 4 s, 6 s e 12 s. De forma que toda a informação disponível seja utilizada.

Figura 6 – Representação da segmentação dos dados no método de Welch.



Fonte: Do autor.

Após realizada a fragmentação dos dados, é feita a estimação da densidade de potência espectral nas frequências de interesse. Para cada segmento de dados é calculado um periodograma modificado utilizando-se uma janela de dados $W(j), j = 0, \dots, L - 1$, formando as sequências $X_1W(j), \dots, X_KW(j)$. Calcula-se a FFT destas sequências:

$$A_k(n) = \frac{1}{L} \sum_{j=0}^{L-1} X_k(j)W(j)\exp(-2kijn/L) \quad (2.5)$$

$i = \sqrt{-1}$, e os periodogramas modificados podem ser obtidos por:

$$I_k(f_n) = \frac{L}{U} |A_k(n)|^2 \quad k = 1, 2, \dots, K \quad (2.6)$$

onde:

$$f_n = \frac{n}{L} \quad n = 0, \dots, \frac{L}{2} \quad (2.7)$$

e U é uma constante dada por:

$$U = \frac{1}{L} \sum_{j=0}^{L-1} W(n)^2 \quad (2.8)$$

A função de janela dada por W , deve ser escolhida de acordo com a aplicação de interesse, de forma a trazer resultados mais convenientes para o trabalho (GUPTA, 2013). Há diversos tipos de janelas: janela Retangular, janela de Bartlett, janela de Hamming, janela de Hanning, janela de Blackman, entre outras (OPPENHEIM, 2011). No desenvolvimento deste estudo utilizou-se a janela de Hamming com os seguintes valores de comprimento de janela: 1 s, 2 s, 3 s, 4 s, 6 s e 12 s, considerando dois casos: sem *overlap* e com *overlap* de 50%.

A densidade de potência espectral é dada pela média dos periodogramas calculados:

$$P(f_n) = \frac{1}{K} \sum_{k=1}^K I_k(f_n) \quad (2.9)$$

P é a estimativa da densidade espectral de potência do sinal.

2.2.2 Análise Temporal: Coeficientes Autorregressivos

A modelagem de sistemas por parâmetros autorregressivos (AR) foi inicialmente utilizada em aplicações envolvendo modelagem de ruído em engenharia nuclear em meados dos anos 70. Desde então, tem ganhado popularidade e hoje em dia é largamente utilizada em monitoramento e identificação de sistemas, detecção de falhas e diagnósticos. Se caracteriza por, entre outras vantagens, envolver algoritmos relativamente simples (HOON et al., 1996).

Há diversos métodos utilizados para se estimar os parâmetros AR, três desses métodos merecem destaque: o Método de Yule-Walker, Método de Covariância e o Método de Burg (BURG, 1967; BURG, 1968). A princípio, esses três métodos deveriam levar à aproximadamente os mesmo parâmetros, desde que, amostras de dados suficientemente grandes fossem utilizadas. Para amostras de dados menores, os resultados apresentados por estes três métodos diferem, os métodos de Yule-Walker e Covariância podem levar a estimativas de parâmetros indesejáveis, e nesses casos é preferível a utilização do Método de Burg. Este método possibilita o desenvolvimento de um modelo estável, além de alta resolução para amostras de dados menores (NASSAR et al., 2004).

As amostras y_t de um processo autorregressivo dependem linearmente das amostras que a precedem:

$$y_t + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} = \eta_t \quad (2.10)$$

onde a_t são os parâmetros autorregressivos, e as inovações η_t são um processo estacionário randômico de média zero. A função de covariância R_t está relacionada aos parâmetros autoregressivos a_t através da Equação (2.11), para atrasos de 0 a p .

$$\begin{pmatrix} R_0 & R_1 & \dots & R_{p-1} \\ R_1 & R_0 & \dots & R_{p-2} \\ | & | & \backslash & | \\ R_{p-1} & R_{p-2} & \dots & R_0 \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ | \\ a_p \end{pmatrix} = \begin{pmatrix} R_1 \\ R_2 \\ | \\ R_p \end{pmatrix} \quad (2.11)$$

Por sua vez, um modelo autorregressivo de mesma ordem pode ser escrito como:

$$y_t + \hat{a}_1 y_{t-1} + \hat{a}_2 y_{t-2} + \dots + \hat{a}_p y_{t-p} = \hat{\eta}_t \quad (2.12)$$

onde \hat{a}_t são os parâmetros autorregressivos estimados e $\hat{\eta}_t$ são as inovações estimadas. Da Equação (2.12), temos que cada nova amostra de dados pode ser estimada a partir de suas predecessoras:

$$\hat{y}_t = - \sum_{i=1}^p a_i y(t-i) \quad (2.13)$$

As amostras y_t não podem ser estimadas exatamente, logo, há a introdução de um resíduo, que é definido como a diferença entre o sinal original e o sinal estimado:

$$resíduo = y_t - \hat{y}_t = \hat{\eta}_t \quad (2.14)$$

observa-se que o resíduo é igual à inovação estimada: $\hat{\eta}_t$.

Diferente do método de Yule-Walker, que estima os parâmetros autorregressivos diretamente, o Método de Burg estima inicialmente os coeficientes de reflexão, que são definidos como o último parâmetro autorregressivo estimado para cada modelo de ordem p . A partir daí, os parâmetros AR são estimados utilizando-se o algoritmo de Levinson-Durbin (BROCKWELL; DAHLHAUS, 2004; CASTIGLIONI, 2005), o qual resulta em soluções rápidas para sistemas lineares.

2.3 Classificação

A utilização de discriminantes lineares como método de classificação traz algumas vantagens em relação a outros métodos. A simplicidade de implementação e o baixo custo computacional são os grandes diferenciais desta estratégia. Utilizou-se a técnica conhecida como Método dos Mínimos Quadrados (THEODORIDIS; KOUTROUMBAS, 2009) na implementação do classificador linear. Este método é simples e apresenta um desempenho bastante satisfatório. O critério da soma dos erros quadrados ou (simplesmente dos mínimos quadrados) pode ser definido por:

$$J(\omega) = \sum_{i=1}^N (y_i - x_i^T \omega)^2 = \sum_{i=1}^N e_i^2 \quad (2.15)$$

$$y = \begin{pmatrix} y_1 \\ y_2 \\ | \\ y_N \end{pmatrix} \quad (2.16)$$

x é um vetor de treinamento do classificador, y é um vetor de rótulos (± 1) e ω é o vetor de pesos que representa o classificador linear.

Como pode ser observado, os erros entre o valor desejado e o valor verdadeiro são somados para todos os vetores de características disponíveis para o treinamento. Minimizando a Equação (2.15) com relação a ω obtém-se:

$$\sum_{i=1}^N x_i (y_i - x_i^T \hat{\omega}) = 0 \Rightarrow \left(\sum_{i=1}^N x_i x_i^T \hat{\omega} \right) = \sum_{i=1}^N x_i y_i \quad (2.17)$$

$$X = \begin{pmatrix} x_1^T \\ x_2^T \\ | \\ x_N^T \end{pmatrix} = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1l} \\ x_{21} & x_{22} & \dots & x_{2l} \\ | & | & \backslash & | \\ x_{N1} & x_{N2} & \dots & x_{Nl} \end{pmatrix} \quad (2.18)$$

X é uma matriz $N \times l$, cujas linhas são os vetores de treinamento do classificador. N é o número de pontos a ser utilizado para o treinamento do classificador e l é o número de atributos levados em consideração para cada um destes pontos.

A partir das equações anteriores, observa-se que:

$$\sum_{i=1}^N x_i x_i^T = X^T X \quad (2.19)$$

$$\sum_{i=1}^N x_i y_i = X^T y \quad (2.20)$$

Logo, a equação 2.17 pode ser escrita como:

$$(X^T X) \hat{\omega} = X^T y \Rightarrow \hat{\omega} = (X^T X)^{-1} X^T y \quad (2.21)$$

a matriz $X^T X$ é a matriz de correlação de amostras, X^+ é a matriz pseudo-inversa de X , dada por $X^+ = (X^T X)^{-1} X^T$. Assim, o vetor de pesos $\hat{\omega}$, o qual define o classificador, é calculado como a solução da equação (2.21).

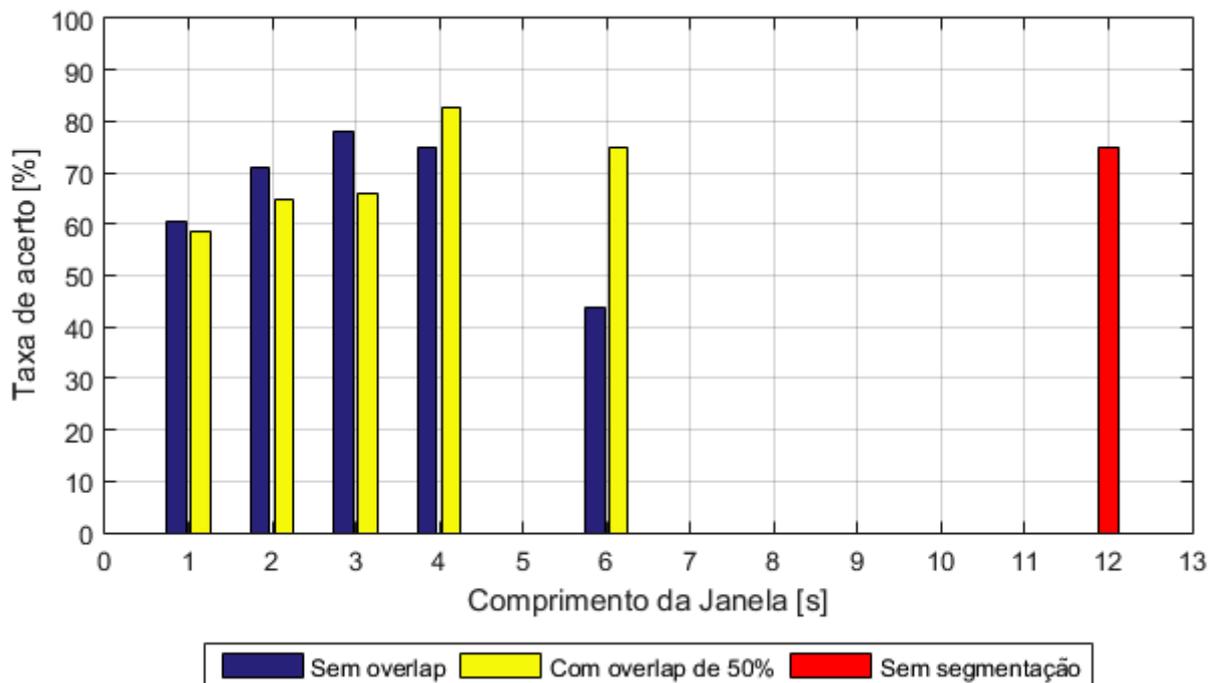
3 Resultados e Discussão

Neste capítulo são apresentados e discutidos os resultados das simulações realizadas aplicando-se duas técnicas de extração de características: método de Welch para estimação da densidade espectral de energia e coeficientes AR extraídos pelo método de Burg. Ambas as técnicas foram utilizadas para discriminar três pares de frequência: 6 Hz e 7.5 Hz, 12 Hz e 15 Hz e 20 Hz e 30 Hz. A taxa de acerto é definida como o valor médio obtido pela técnica *2-fold cross validation* (OLSON; DELEN, 2008). Para cada técnica de extração também foram testadas diferentes configurações de comprimento de janela de dados, além da aplicação de *overlap* ou não, em cada comprimento de janela. Na técnica de coeficientes autorregressivos também foi realizada a análise do efeito da filtragem espacial CAR sobre a taxa de acerto nas configurações previamente descritas.

3.1 Análise Espectral: Método de Welch

As taxas de acerto obtidas através da análise espectral dos sinais cerebrais são apresentadas nas Figuras 7, 8 e 9. Para cada par de frequência, foram testados os seguintes comprimentos de janela: 1 s, 2 s, 3 s, 4 s, 6 s (com e sem *overlap*) e 12 s (janela original sem segmentação).

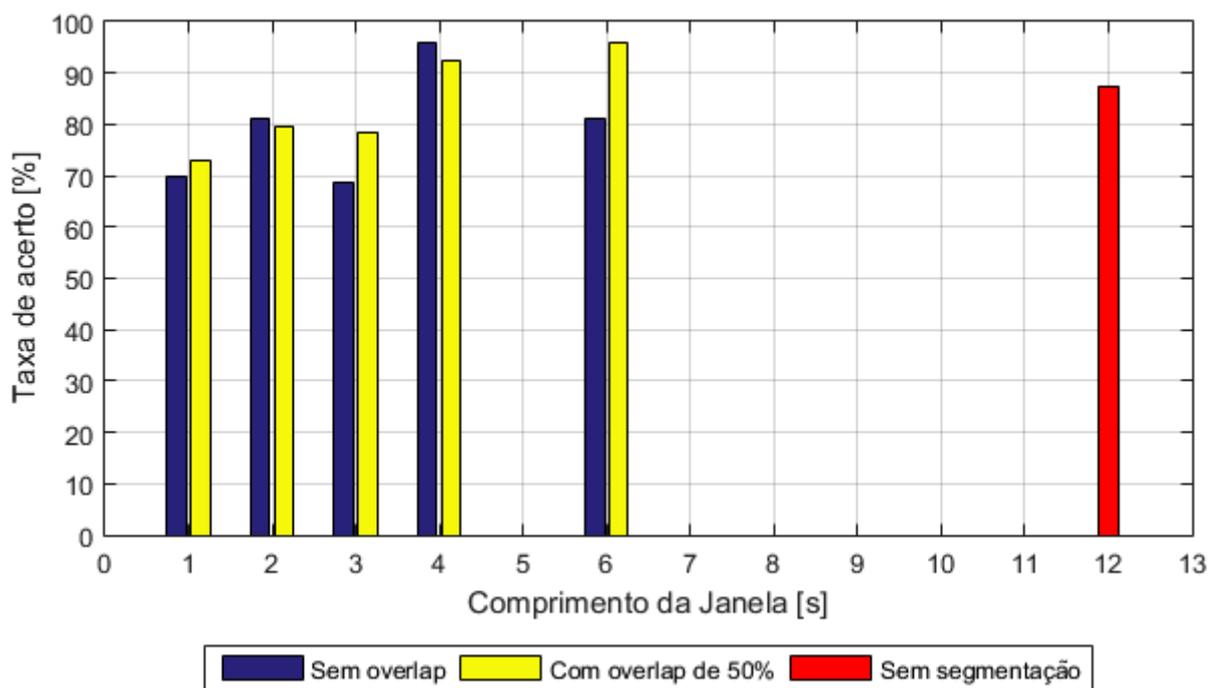
Figura 7 – Desempenho do classificador - 6 Hz e 7.5 Hz - Método de Welch.



Fonte: Do autor.

A Figura 7 apresenta os resultados das simulações feitas com o par de frequência de 6 Hz e 7.5 Hz. Pode-se observar que as janelas de menor comprimento apresentaram taxas de acerto menores, e que, a utilização de *overlap* praticamente não afetou o desempenho do classificador. À medida que se aumenta o comprimento da janela, de 1 s até 4 s, a taxa de acerto tende a aumentar. Porém, este padrão não se mantém nos comprimentos de 6 s e 12 s. A razão disto é que, nestas configurações, a janela original é segmentada em partes maiores (no caso de 6 s), e portanto há uma quantidade menor de segmentos de dados a serem testados. Desta forma, um único erro do classificador representa um percentual muito mais representativo em relação ao total de segmentos, visto que a quantidade de segmentos nestas configurações é menor que nas configurações anteriores. O melhor resultado apresentado para este par de frequências foi 82.5%, na janela de 4 s com *overlap*.

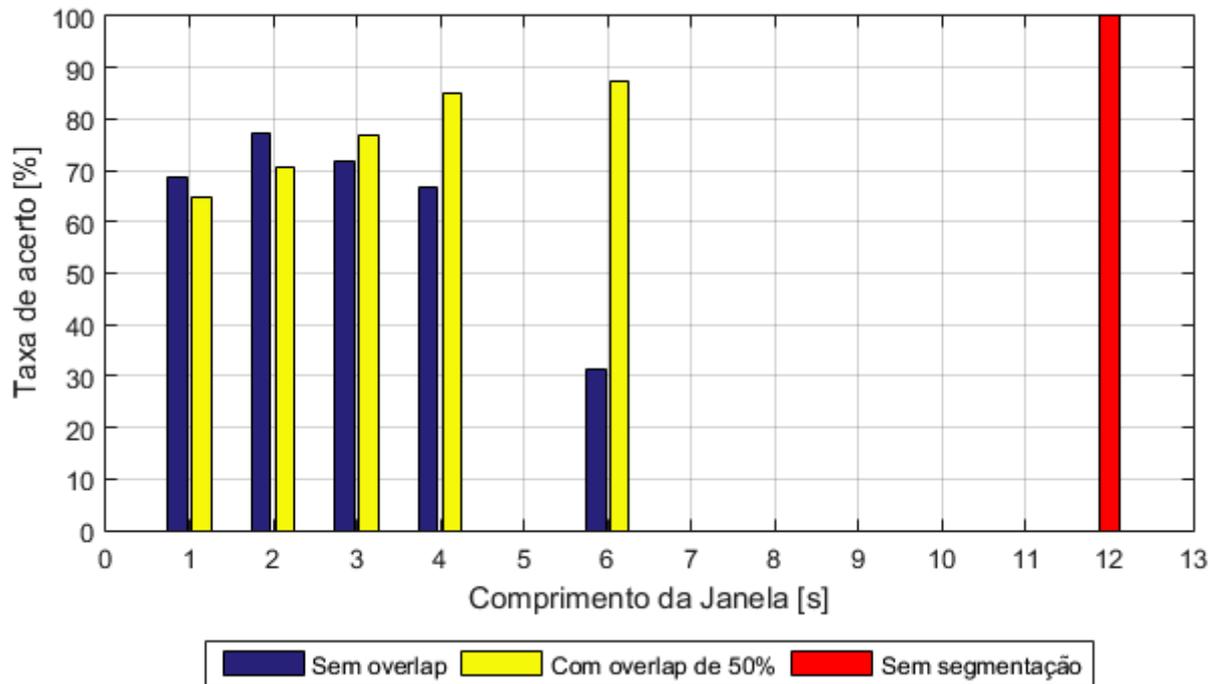
Figura 8 – Desempenho do classificador - 12 Hz e 15 Hz - Método de Welch.



Fonte: Do autor.

Analisando-se a Figura 8, pode-se observar que o par de frequências de 12 Hz e 15 Hz apresentou, em geral, melhores taxas de acerto que o par de frequência de 6 Hz e 7.5 Hz. Também foi possível observar o mesmo padrão descrito anteriormente, em que as janelas de menor comprimento apresentam menores taxas de acerto. A taxa de acerto tende a aumentar até a janela de 4 s, a partir daí, foi observada uma tendência a se estabilizar. As melhores taxas de acerto foram obtidas nas janelas de 4 s, com e sem sobreposição de dados, e 6 s com *overlap*, apresentando taxas de acerto acima de 90%. A janela de 12 s apresentou taxa de acerto de 87.5%.

Figura 9 – Desempenho do classificador - 20 Hz e 30 Hz - Método de Welch.



Fonte: Do autor.

A Figura 9 apresenta os resultados do par de frequência de 20 Hz e 30 Hz. Este par de frequências apresentou o mesmo padrão dos outros pares de frequência, com exceção da janela de 12 s, que obteve a maior taxa de acerto: 100%. Por utilizar toda a janela de dados, é esperado que este comprimento de janela apresente alto percentual de acerto, apesar da menor quantidade de segmentos a serem usados para treinamento e teste.

A Tabela 1 condensa as configurações que geraram os melhores resultados utilizando-se do método de Welch, considerando os três pares de frequência testados:

Tabela 1 – Taxas de Acerto do classificador - Método de Welch.

Par de Frequência	Janela [s]	Overlap [50%]	Taxa de Acerto [%]
6 Hz e 7.5 Hz	3	Não	78.13
6 Hz e 7.5 Hz	4	Sim	82.5
12 Hz e 15 Hz	2	Não	81.25
12 Hz e 15 Hz	4	Não	95.83
12 Hz e 15 Hz	4	Sim	92.5
12 Hz e 15 Hz	6	Sim	95.83
12 Hz e 15 Hz	12	Não	87.5
20 Hz e 30 Hz	4	Sim	85
20 Hz e 30 Hz	6	Sim	87.5
20 Hz e 30 Hz	12	Não	100

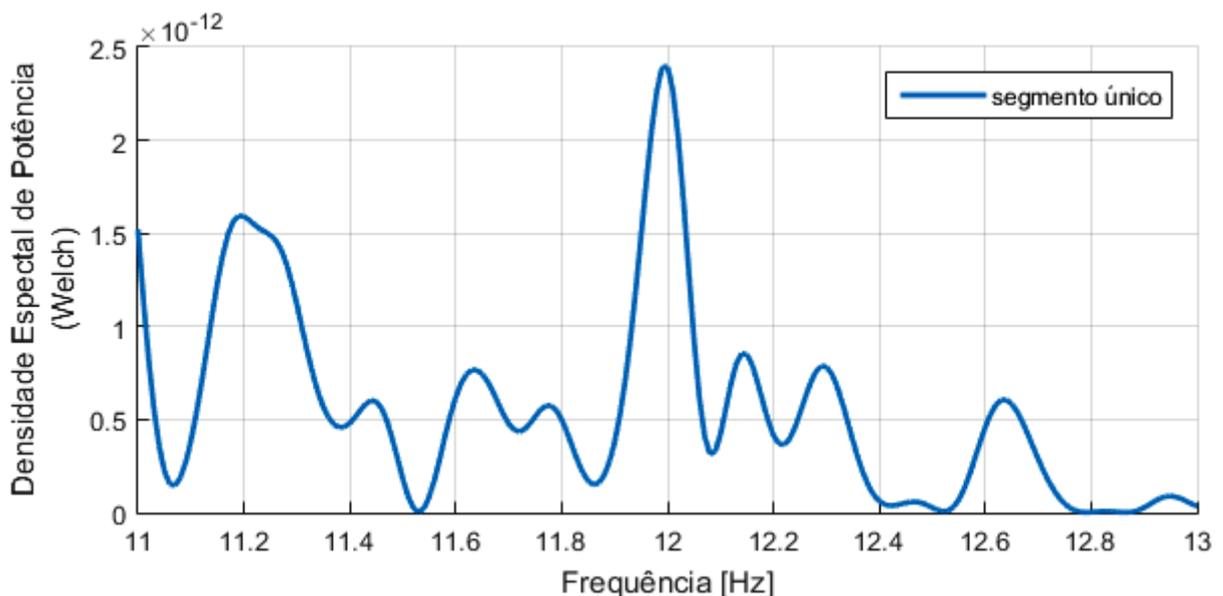
Fonte: Do autor.

Para que esse sistema possa ser empregado como uma interface BCI em aplicações assistivas, faz-se necessário possibilitar que o usuário entre com novos comandos em um determinado intervalo de tempo adequado a este tipo de aplicação. É desejável portanto, que o comprimento da janela não seja muito grande, de forma que o usuário não precise esperar muito tempo até que seja possível dar uma nova instrução à BCI. Por outro lado, também deve-se atentar à taxa de acerto desempenhada pelo sistema. Taxas de acerto muito baixas, assim como comprimentos de janela muito grandes, podem tornar este sistema inviável para determinadas aplicações. Pode-se observar nas Figuras 7 a 9 que, os menores comprimentos de janela testados, em geral, apresentaram taxas de acerto mais baixas. Por outro lado, as melhores taxas de acerto foram desempenhadas por comprimentos de janela superiores à 4 s, em sua maioria.

As Figuras 10 a 15 ilustram o efeito da segmentação dos dados originais em janelas menores, de um sinal cuja frequência de intermitência observada é de 12 Hz. Estes dados são referentes a uma coleta de dados realizada através do canal PO7 em um determinado indivíduo. Pode-se observar a densidade espectral de potência em cada segmento, de acordo com o comprimento de janela utilizado. Através desta análise pode-se obter uma melhor compreensão do desempenho apresentado pela BCI nas diferentes opções de janelamento empregadas.

A Figura 10 apresenta a densidade de potência do sinal original. Pode-se observar que há um pico de densidade de potência bastante nítido em torno da frequência de 12 Hz com picos menores nas frequências vizinhas. Observando as Figuras 11 à 15, nota-se que as janelas de maior comprimento apresentam picos mais nítidos na potência de interesse, facilitando a classificação dos sinais.

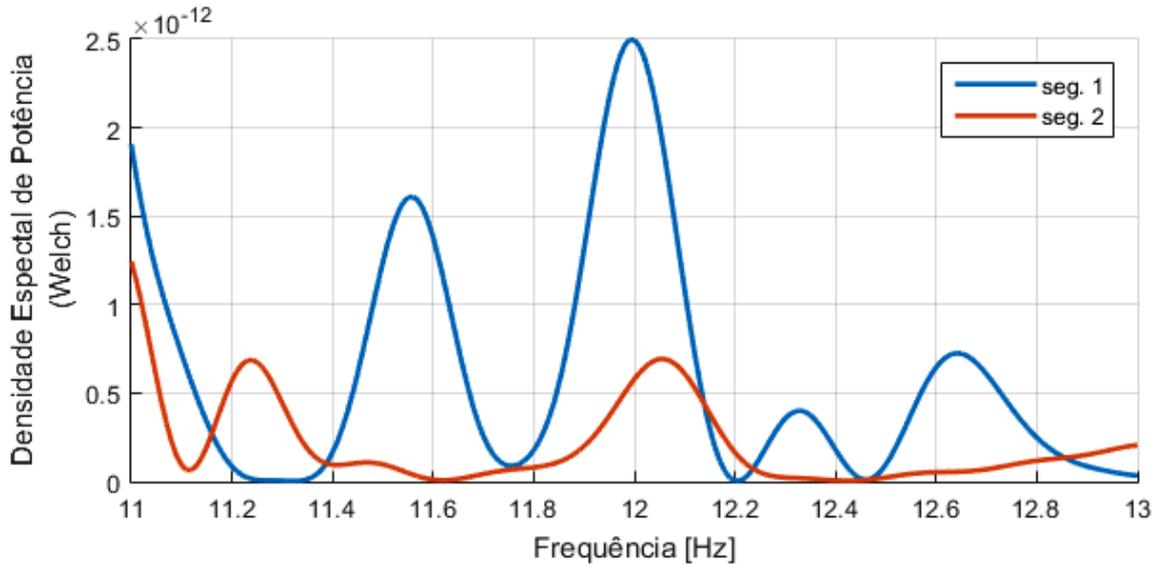
Figura 10 – Densidade espectral de potência em 12 Hz - Janela de 12 s.



Fonte: Do autor.

Observando-se a Figura 11, é possível notar que o segmento 1 apresenta consideravelmente maior potência espectral que o segmento 2, indicando que os dados coletados durante os primeiros segundos de coleta, possuem mais informação relevante à classificação, quando comparados com as informações coletadas ao fim da etapa de aquisição de dados.

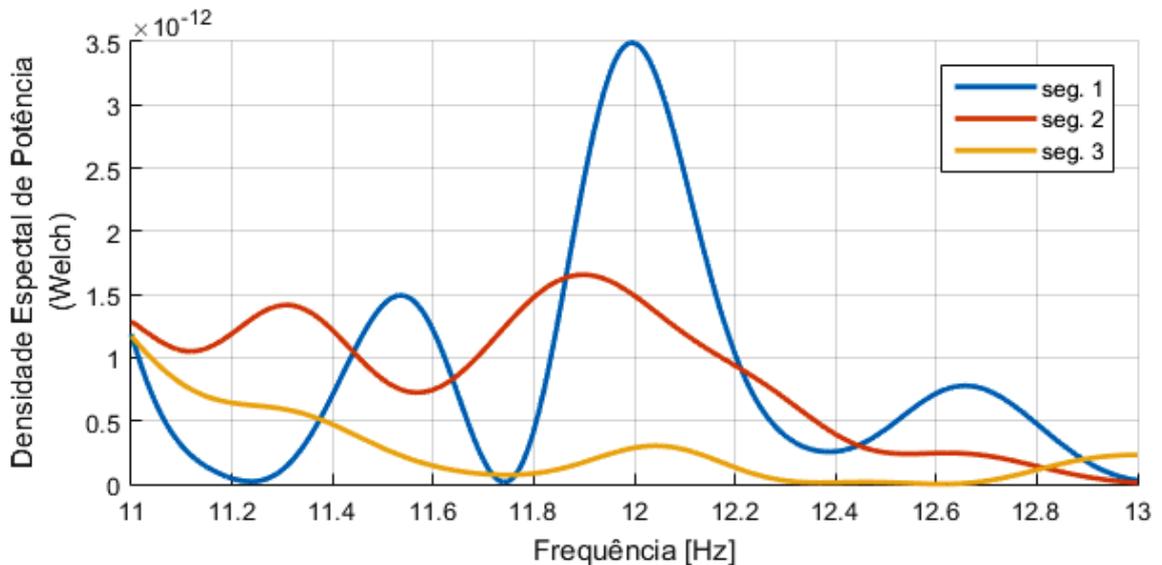
Figura 11 – Densidade espectral de potência em 12 Hz - Janela de 6 s.



Fonte: Do autor.

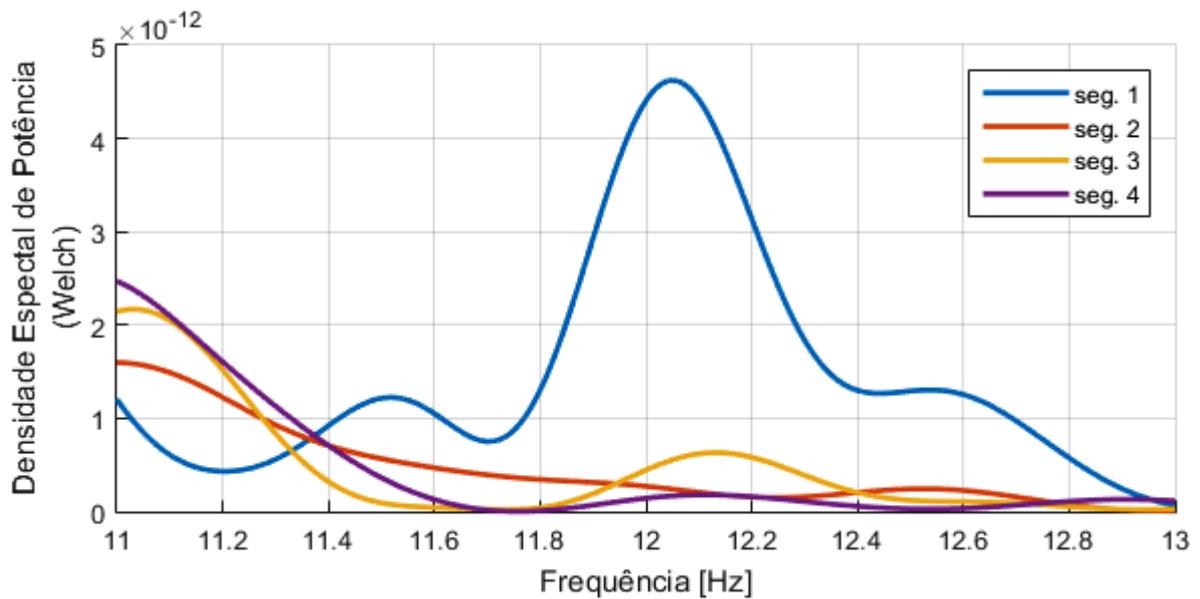
À medida que o número de segmentos cresce, torna-se ainda mais evidente que os segmentos iniciais apresentam maior densidade espectral na frequência de interesse, seguidos de segmentos com densidade espectral menor na frequência de 12 Hz, conforme pode-se observar nas Figuras 11 à 15.

Figura 12 – Densidade espectral de potência em 12 Hz - Janela de 4 s.



Fonte: Do autor.

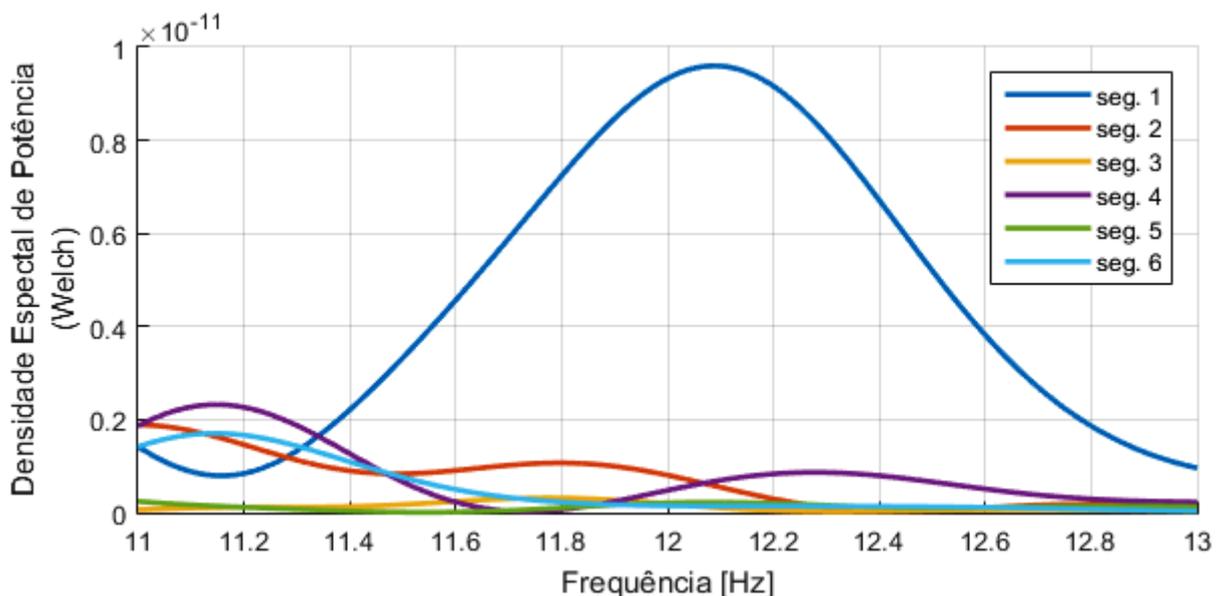
Figura 13 – Densidade espectral de potência em 12 Hz - Janela de 3 s.



Fonte: Do autor.

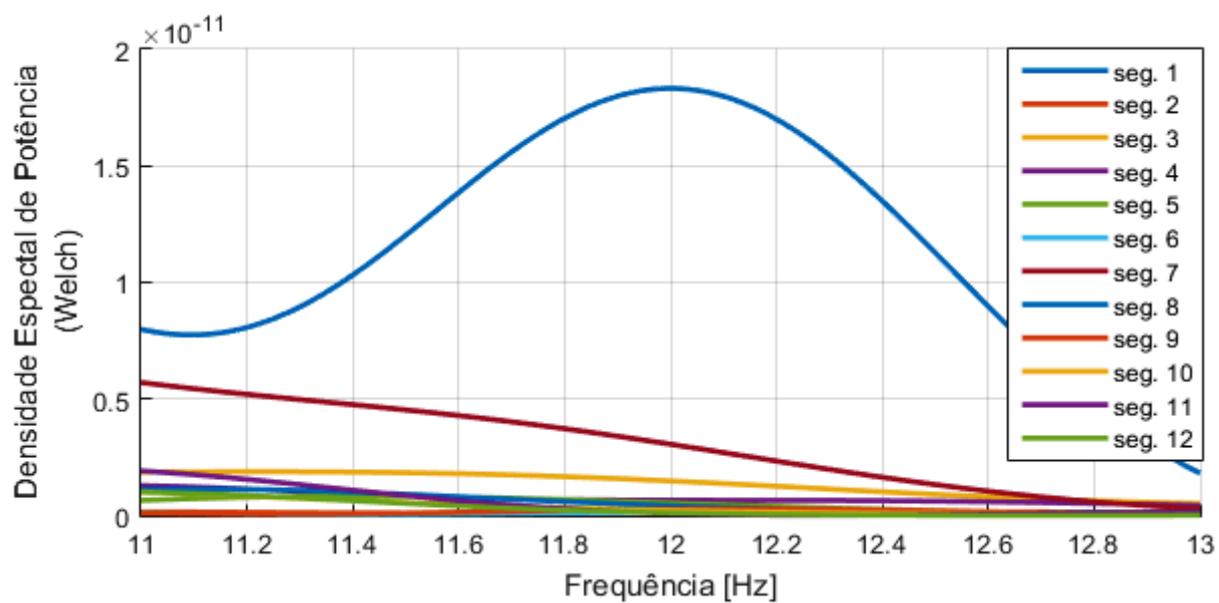
Pode-se observar que, à medida que os dados iniciais são segmentados, o pico em torno da frequência de 12 Hz se torna menos nítido. Dando a impressão de que a potência espectral esteja mais dispersa em torno da frequência de 12 Hz para segmentos menores de informação. Esta configuração observada em um sinal baseado no paradigma SSVEP indica que este sinal, apesar de caracterizado por ser de regime permanente, apresenta variações significativas em seu comportamento em uma janela de 12 s.

Figura 14 – Densidade espectral de potência em 12 Hz - Janela de 2 s.



Fonte: Do autor.

Figura 15 – Densidade espectral de potência em 12 Hz - Janela de 1 s.



Fonte: Do autor.

3.2 Análise Temporal: Coeficientes Autorregressivos

Os coeficientes autorregressivos foram extraídos pelo método de Burg para os seguintes comprimentos de janela: 2 s, 3 s, 4 s, 6 s (com e sem *overlap*) e 12 s (utilizando-se a janela original sem segmentação). Para cada um dos comprimentos de janela testados foi feita a variação da ordem do modelo AR, de 2 até 40. Também foram observados os efeitos da aplicação da filtragem CAR. Para cada par de frequência foram realizados testes nos seguintes cenários:

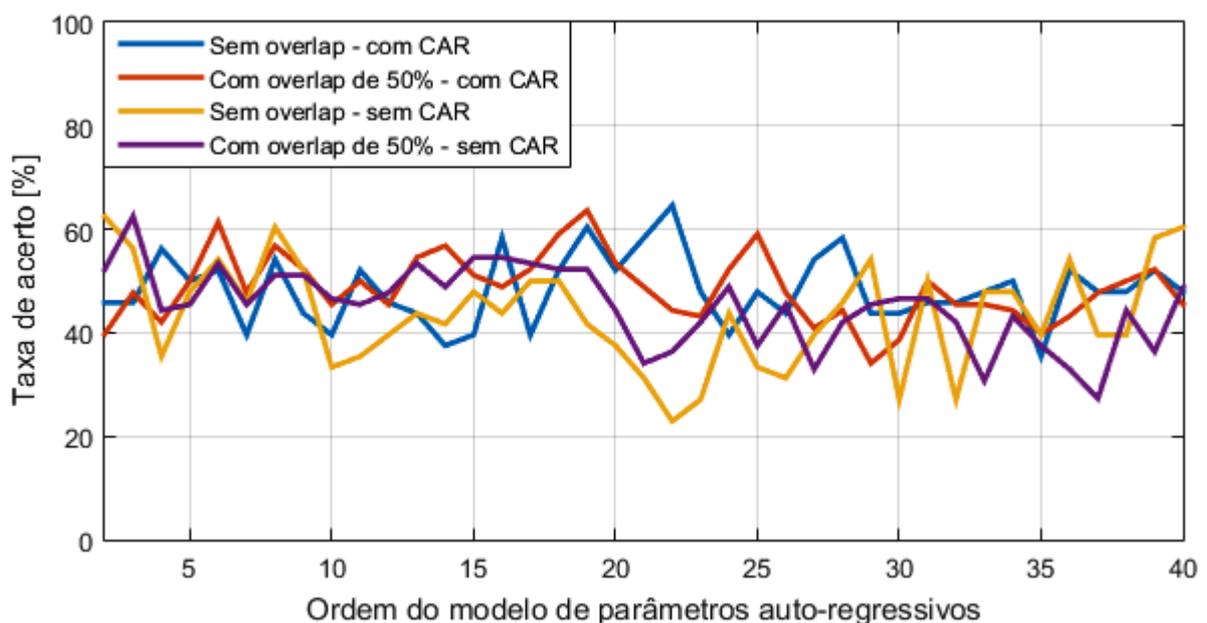
- Com *overlap* e com CAR
- Sem *overlap* e com CAR
- Com *overlap* e sem CAR
- Sem *overlap* e sem CAR

As Figuras 16 a 30 apresentam os resultados das simulações considerando a taxa de acerto como o valor médio obtido pela técnica *2-fold cross validation*, obtida pelo classificador para cada par de frequência, para todas configurações descritas.

3.2.1 Par de Frequências: 6 Hz e 7.5 Hz

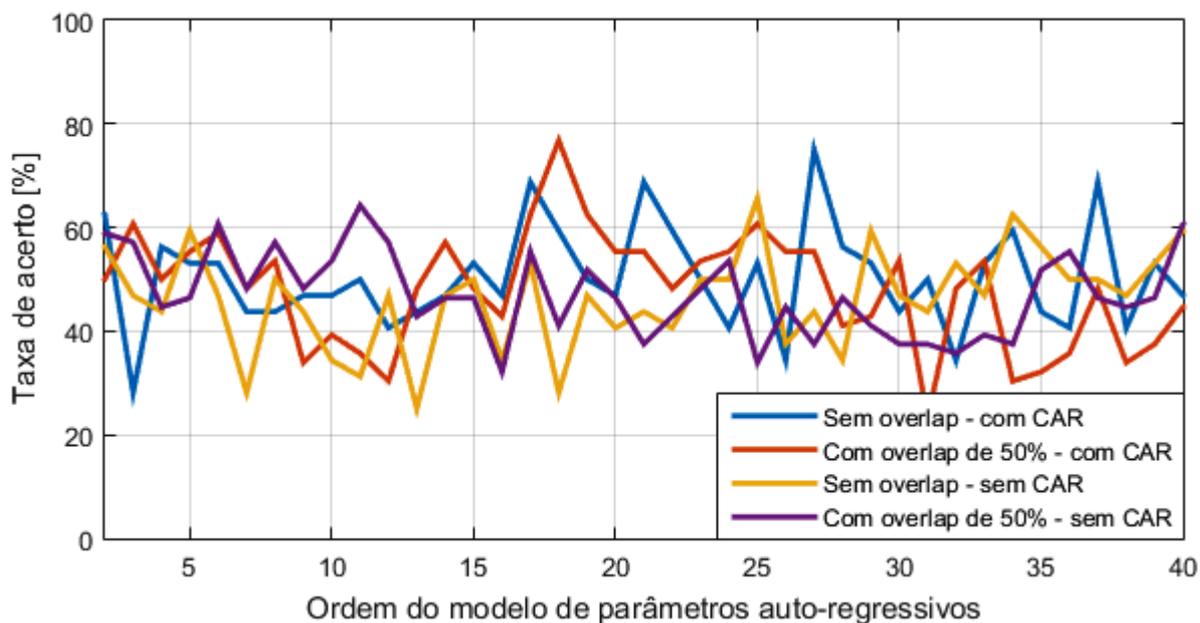
Os resultados apresentados nesta seção são referentes ao par de frequência de 6 Hz e 7.5 Hz, para as diferentes configurações testadas:

Figura 16 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 2 s.



Fonte: Do autor.

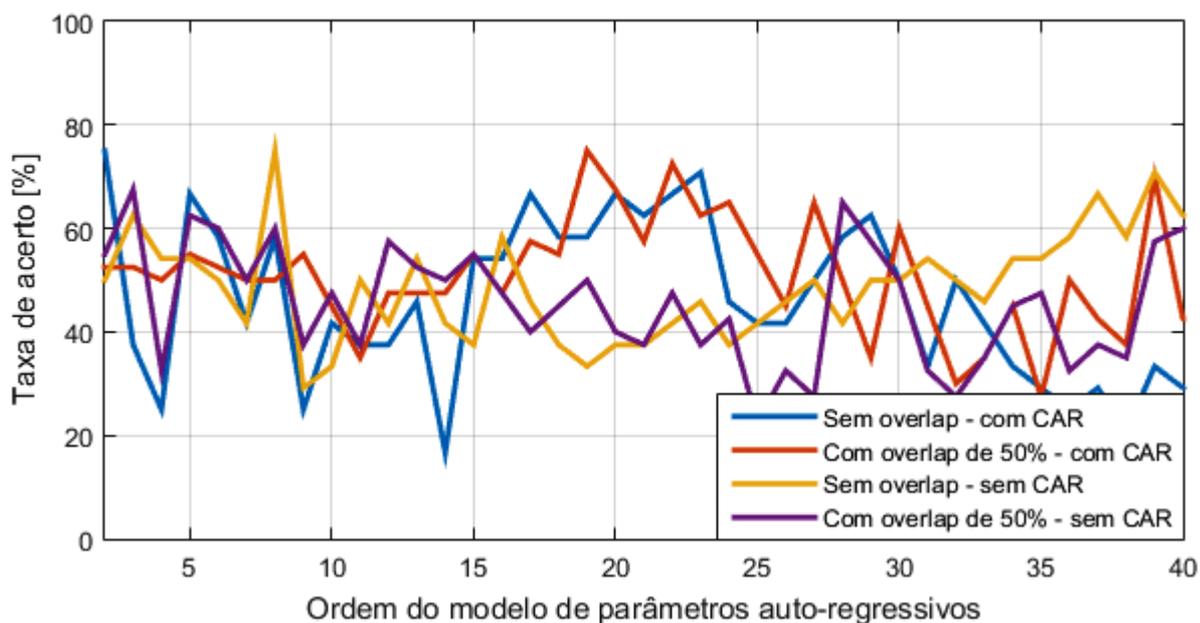
Figura 17 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 3 s.



Fonte: Do autor.

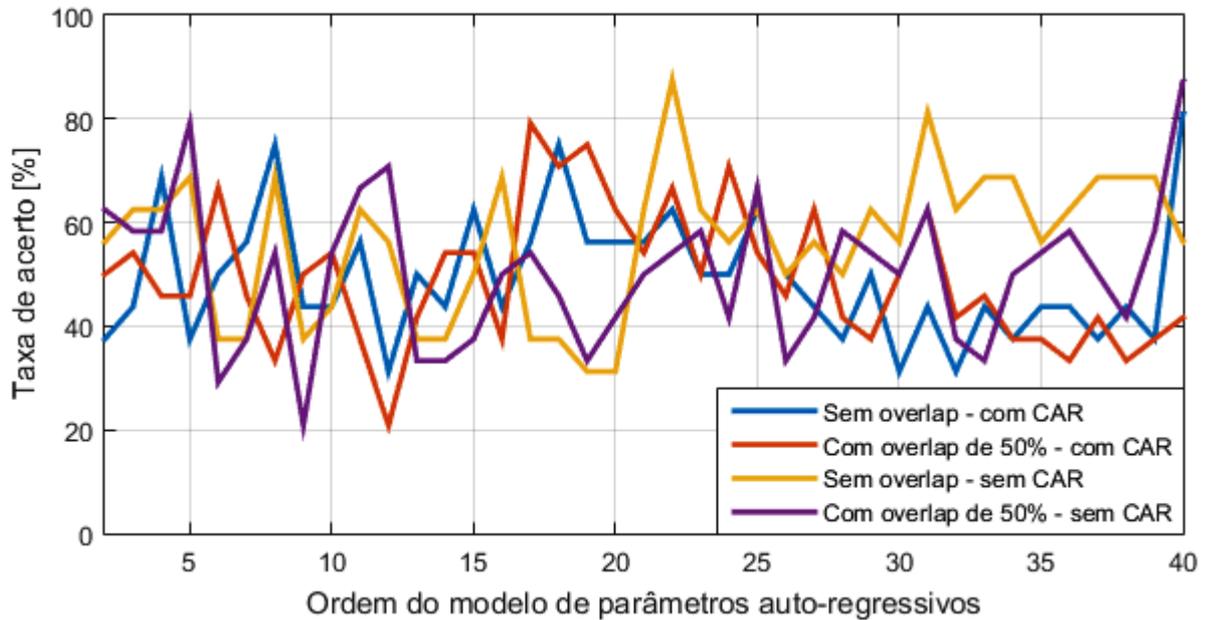
Pode-se observar que houve uma melhoria da taxa de acerto à medida que o comprimento de janela utilizado aumentou de 2 s até 4 s, semelhante ao que ocorreu anteriormente na análise espectral. Porém, até a janela de 4 s não foram observadas taxas de acerto superiores a 80%.

Figura 18 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 4 s.



Fonte: Do autor.

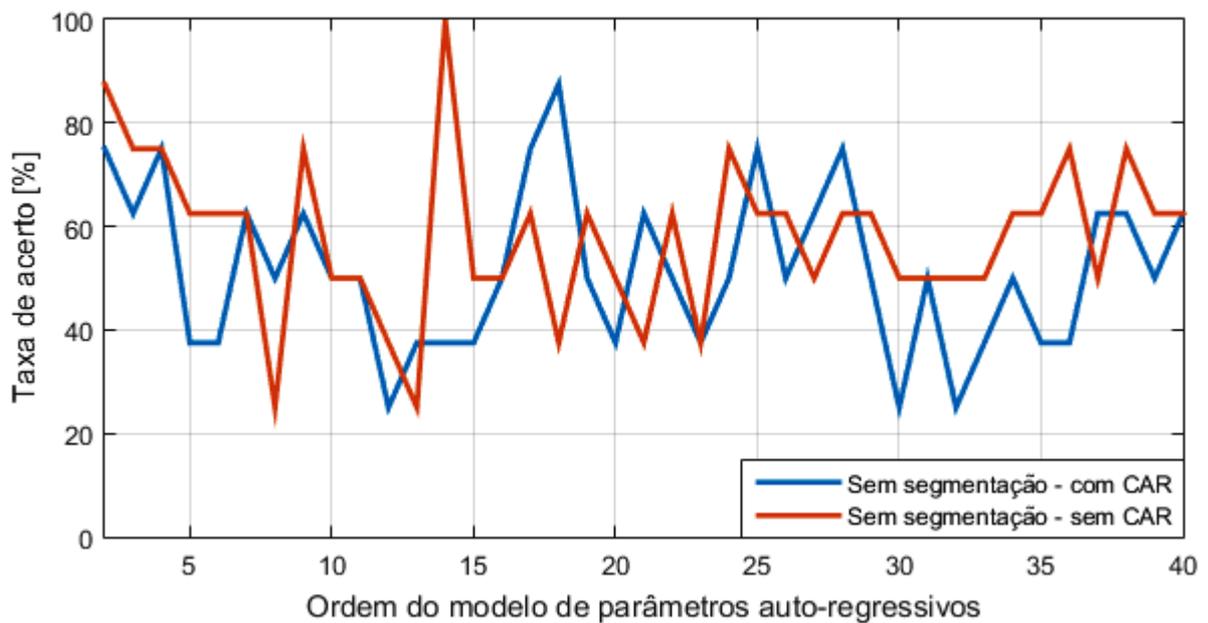
Figura 19 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 6 s.



Fonte: Do autor.

As janelas de 6 s e 12 s apresentaram as melhores taxas de acerto, chegando a atingir 100% para a janela de 12 s sem CAR. Importante notar que o melhor resultado desempenhado pela janela de 6 s foi apresentado na seguinte situação: sem *overlap* e sem CAR, com taxa de acerto de 87.5%.

Figura 20 – Desempenho do classificador - 6 Hz e 7.5 Hz - Janela de 12 s.



Fonte: Do autor.

A Tabela 2 resume os melhores resultados apresentados pelo uso de coeficientes autorregressivos extraídos pelo método de Burg para o par de frequência de 6 Hz e 7.5 Hz.

Tabela 2 – Melhores taxas de acerto - Coeficientes AR - 6 Hz e 7.5 Hz.

Janela [s]	Overlap [50%]	Ordem	CAR	Taxa de Acerto [%]
2	Não	22	Sim	64.58
2	Sim	19	Sim	63.64
3	Não	27	Sim	75
3	Sim	18	Sim	76.79
3	Não	25	Não	65.63
3	Sim	11	Não	64.29
4	Não	23	Sim	70.83
4	Sim	19	Sim	75
4	Não	8	Não	75
4	Sim	28	Não	65
6	Não	18	Sim	75
6	Sim	17	Sim	79.17
6	Não	22	Não	87.5
6	Sim	5	Não	79.17
12	Não	18	Sim	87.5
12	Não	14	Não	100

Fonte: Do autor.

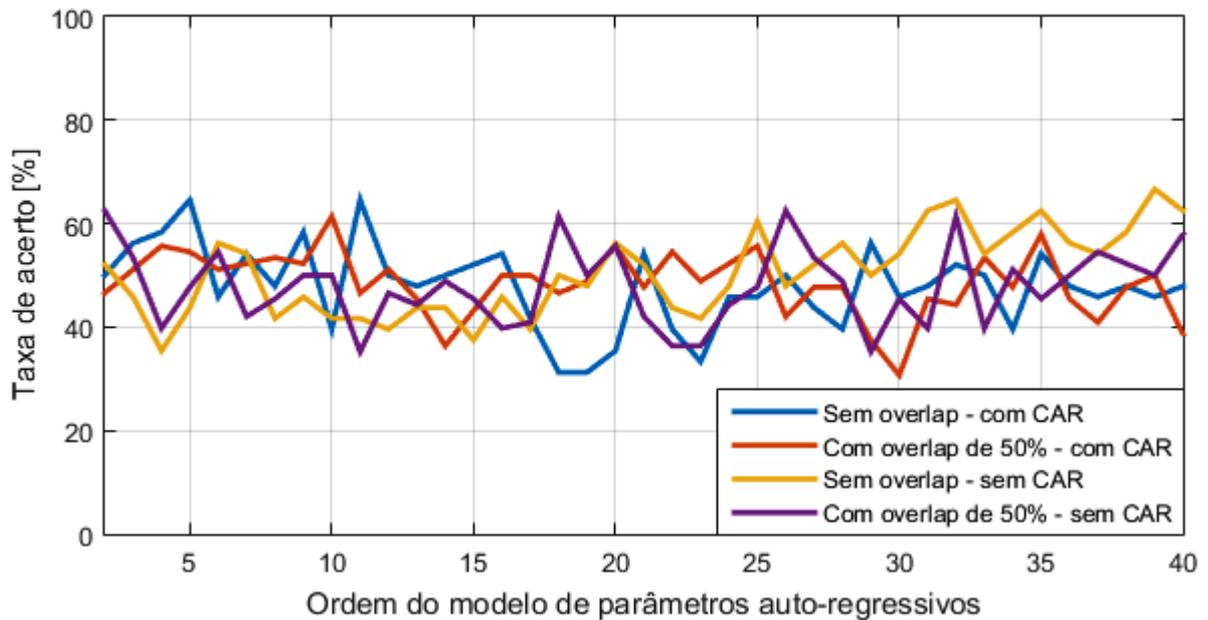
Pode-se observar que as taxas de acerto apresentadas por essa técnica seguem basicamente o mesmo padrão apresentado pelo método de Welch. Os segmentos de menor comprimento, em geral, apresentam taxas de acerto inferior às taxas apresentadas pelas configurações de janela que proporcionam segmentos de informação maiores. O par de frequências de 6 Hz e 7.5 Hz, especificamente, apresenta seus melhores resultados entre 60% e 100%. Porém, taxas de acerto acima de 80% apenas foram alcançadas nos testes com janelas cujos comprimento eram de 6 s ou 12 s.

Este método se mostrou bastante sensível à variação de ordem, havendo grande variações da taxa de acerto para pequenas variações da ordem do modelo autorregressivo. Também é possível notar que a aplicação da filtragem espacial CAR proporcionou melhores resultados para os menores comprimentos de janela testados, por outro lado, os maiores comprimentos de janela apresentaram melhores resultados sem a aplicação da técnica de filtragem espacial.

3.2.2 Par de Frequências: 12 Hz e 15 Hz

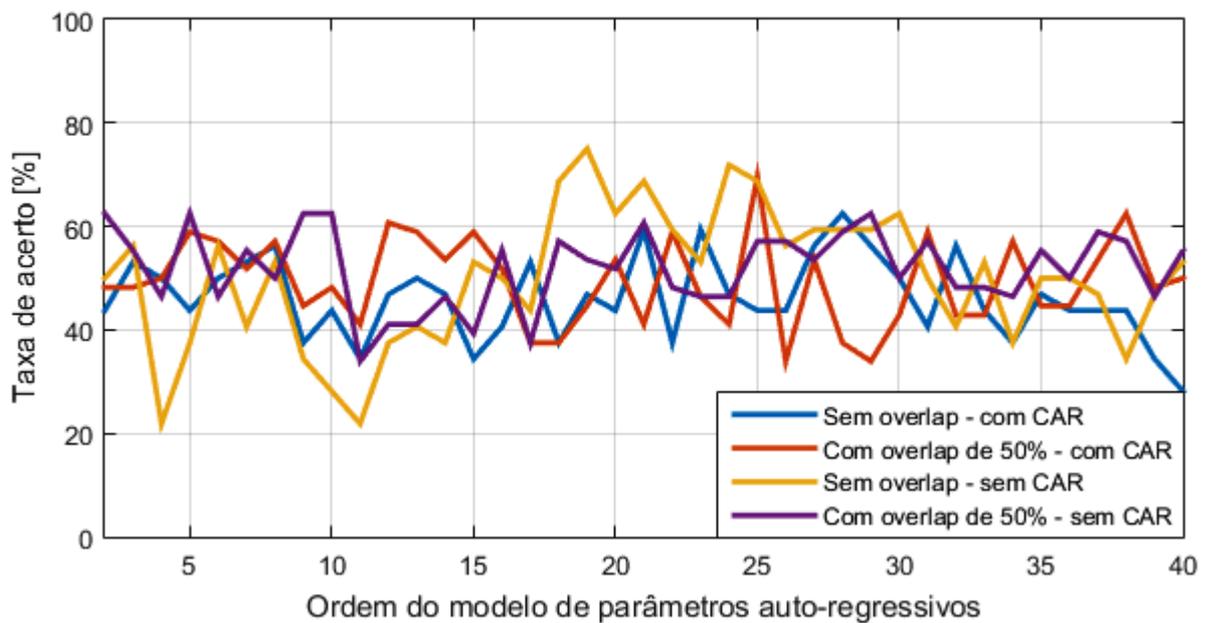
Os resultados apresentados nesta seção são referentes ao par de frequência de 12 Hz e 15 Hz, para as diferentes configurações testadas:

Figura 21 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 2 s.



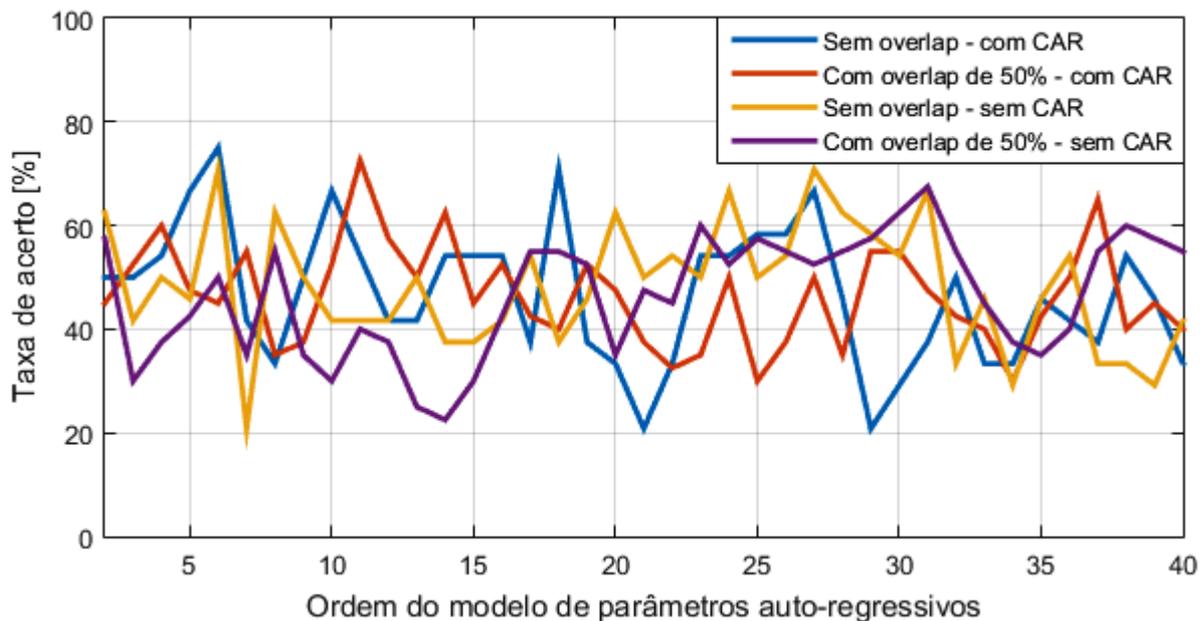
Fonte: Do autor.

Figura 22 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 3 s.



Fonte: Do autor.

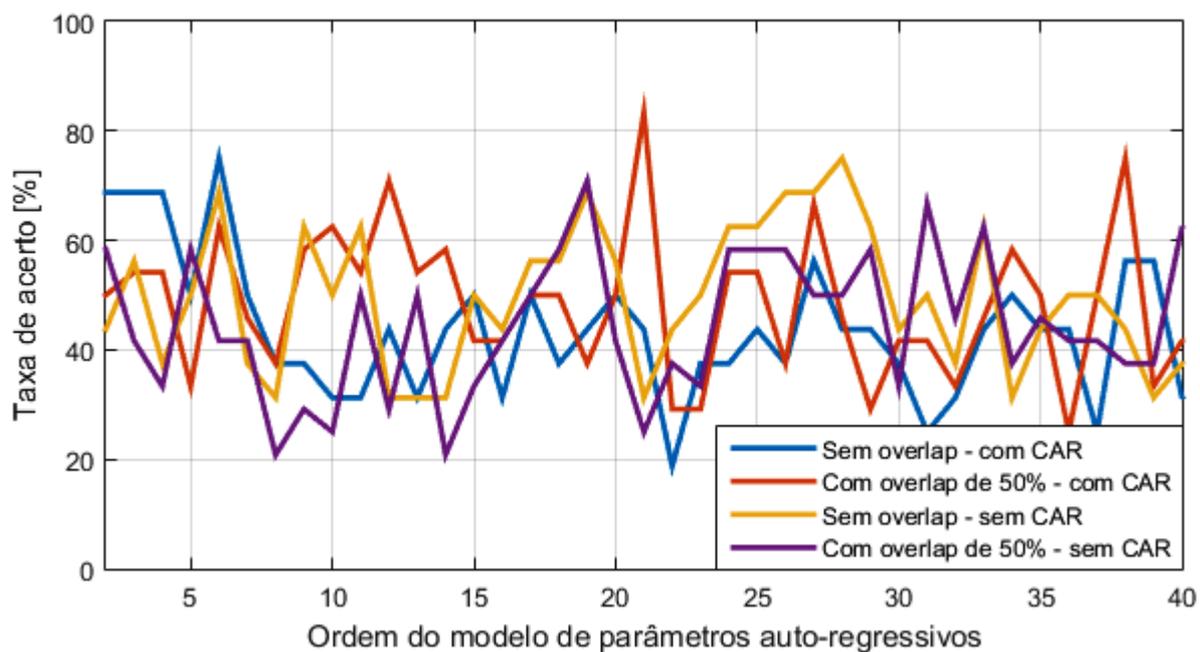
Figura 23 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 4 s.



Fonte: Do autor.

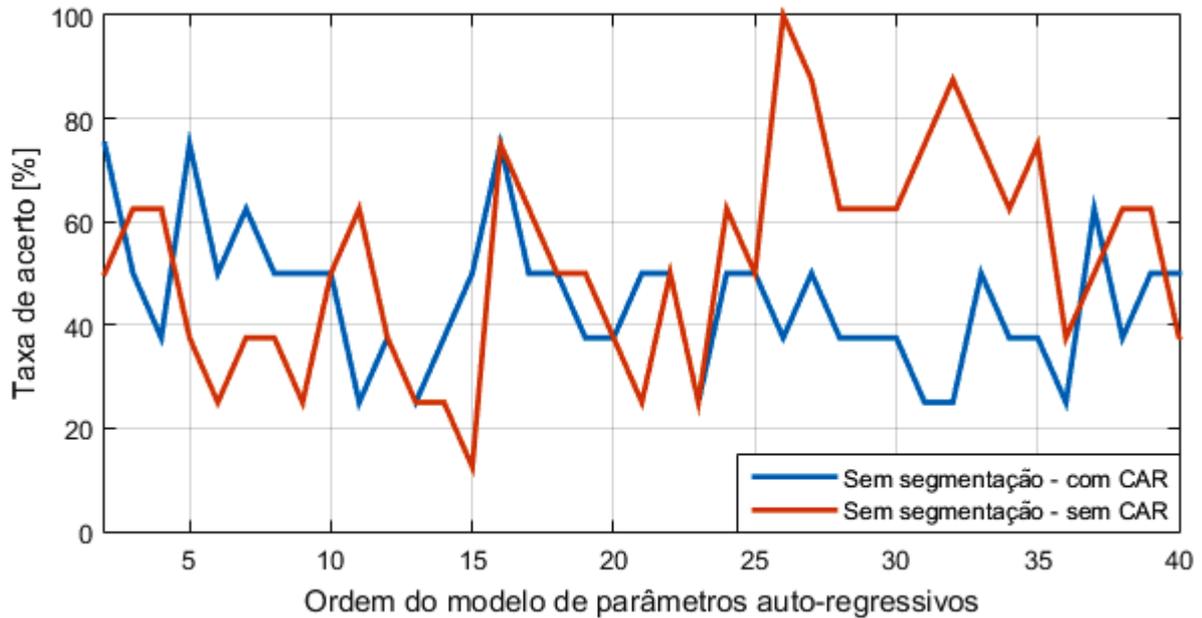
Pode-se notar que, para todas as configurações testadas, não houve taxa de acerto superior a 80% nas janelas cujos comprimentos são de 2 s, 3 s e 4 s. As melhores taxas de acerto apresentadas pela janela de 2 s são inferiores a 70%, enquanto as janelas de 3 s e 4 s obtiveram 75% como suas melhores performances.

Figura 24 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 6 s.



Fonte: Do autor.

Figura 25 – Desempenho do classificador - 12 Hz e 15 Hz - Janela de 12 s.



Fonte: Do autor.

A Tabela 3 resume os melhores resultados apresentados pelo uso de coeficientes autorregressivos extraídos pelo método de Burg para o par de frequência de 12 Hz e 15 Hz:

Tabela 3 – Melhores taxas de acerto - Coeficientes AR - 12 Hz e 15 Hz.

Janela [s]	Overlap [50%]	Ordem	CAR	Taxa de Acerto [%]
2	Não	11	Sim	64.58
2	Não	32	Não	64.58
2	Sim	26	Não	62.5
3	Sim	25	Sim	68.75
3	Não	19	Não	75
3	Sim	10	Não	62.5
4	Não	6	Sim	75
4	Sim	11	Sim	72.5
4	Sim	6	Não	70.83
6	Não	6	Sim	75
6	Sim	21	Sim	83.33
6	Não	28	Não	75
6	Sim	19	Não	70.83
12	Não	16	Sim	75
12	Não	26	Não	100

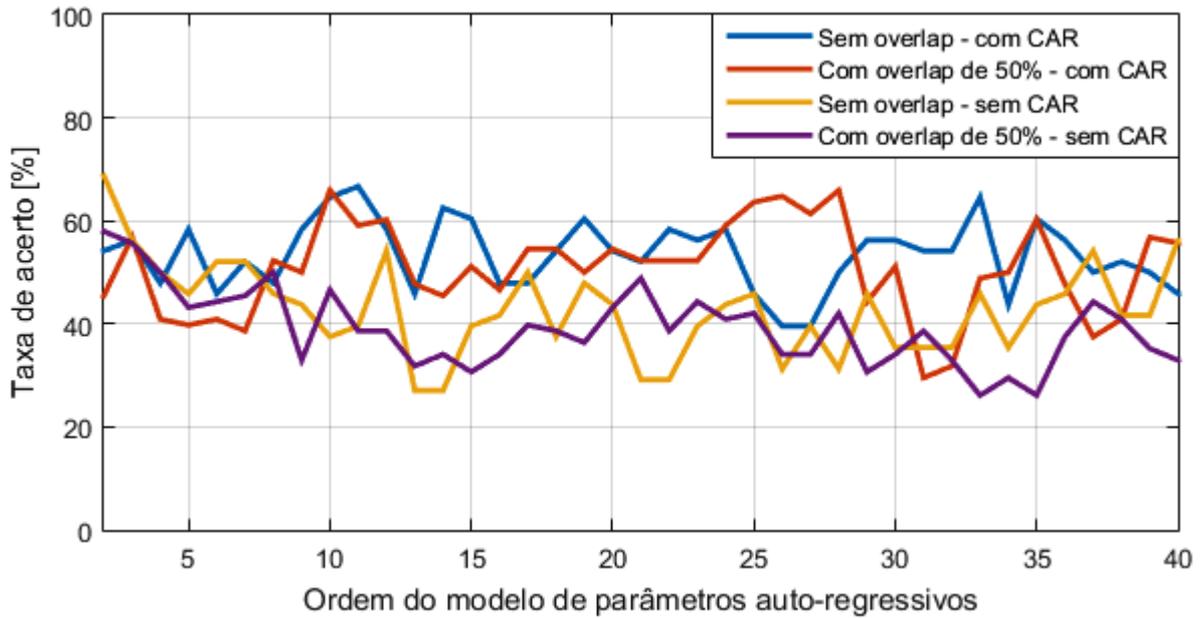
Fonte: Do autor.

Os resultados obtidos em simulação para o par de frequência de 12 Hz e 15 Hz são bastante semelhantes aos resultados apresentados pelo par de frequência de 6 Hz e 7.5 Hz. Novamente, a maior taxa de acerto foi apresentada pela janela de 12 s sem a aplicação da técnica de filtragem espacial CAR.

3.2.3 Par de Frequências: 20 Hz e 30 Hz

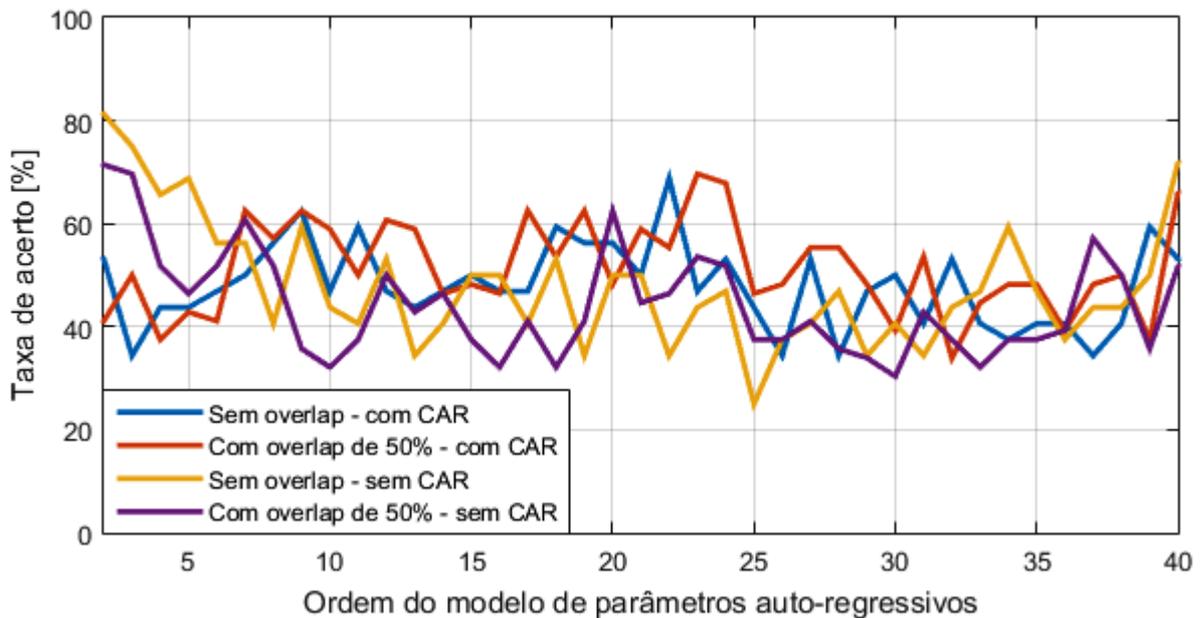
Os resultados apresentados nesta seção são referentes ao par de frequência de 20 Hz e 30 Hz, para as diferentes configurações testadas:

Figura 26 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 2 s.



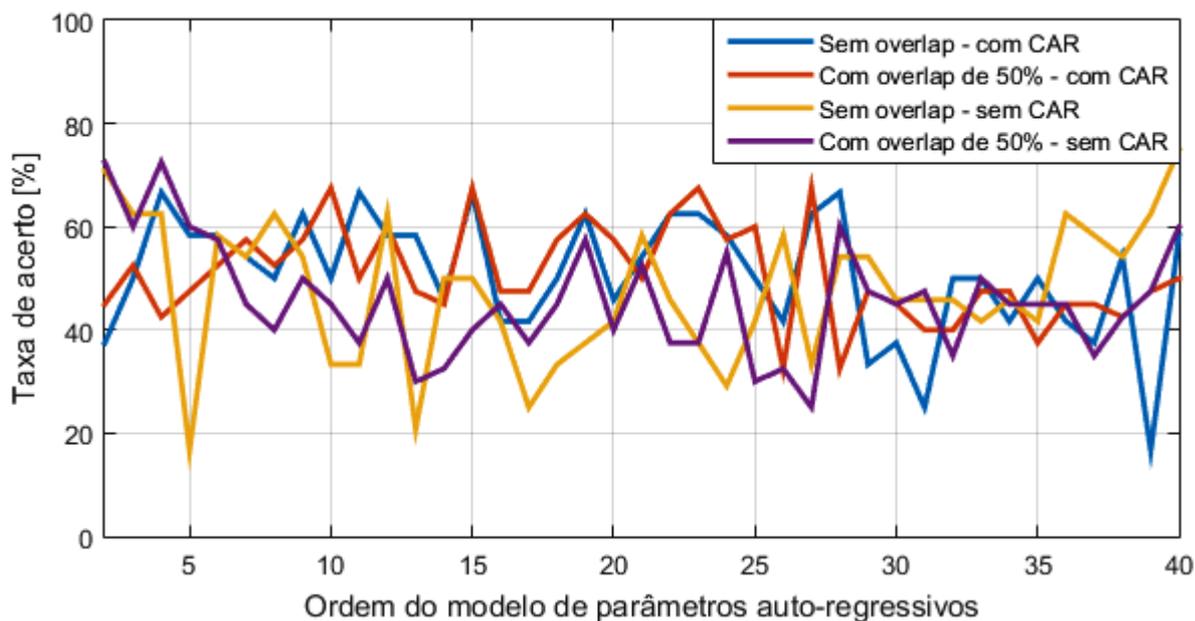
Fonte: Do autor.

Figura 27 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 3 s.



Fonte: Do autor.

Figura 28 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 4 s.

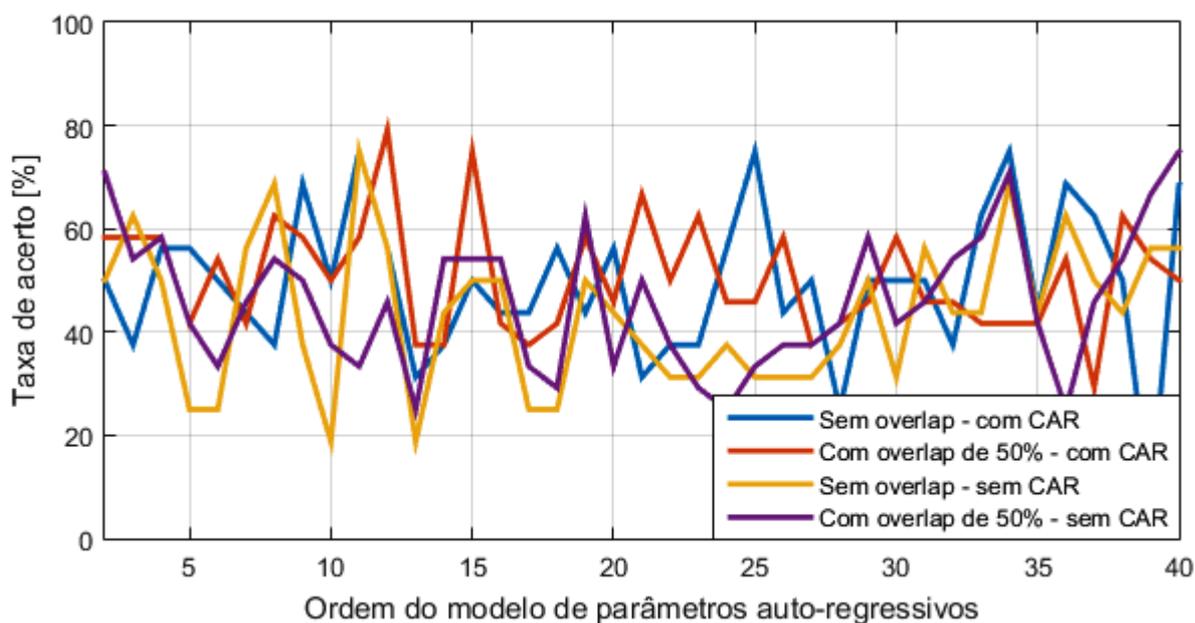


Fonte: Do autor.

Observando-se as Figuras 28 e 29 nota-se que, para uma mesma configuração, pode-se obter taxas de acerto semelhante utilizando-se ordens do modelo autorregressivo diferentes. É de interesse que a ordem do modelo seja a menor possível, desde que mantenha uma alta taxa de acerto, contribuindo para que haja maior agilidade do sistema.

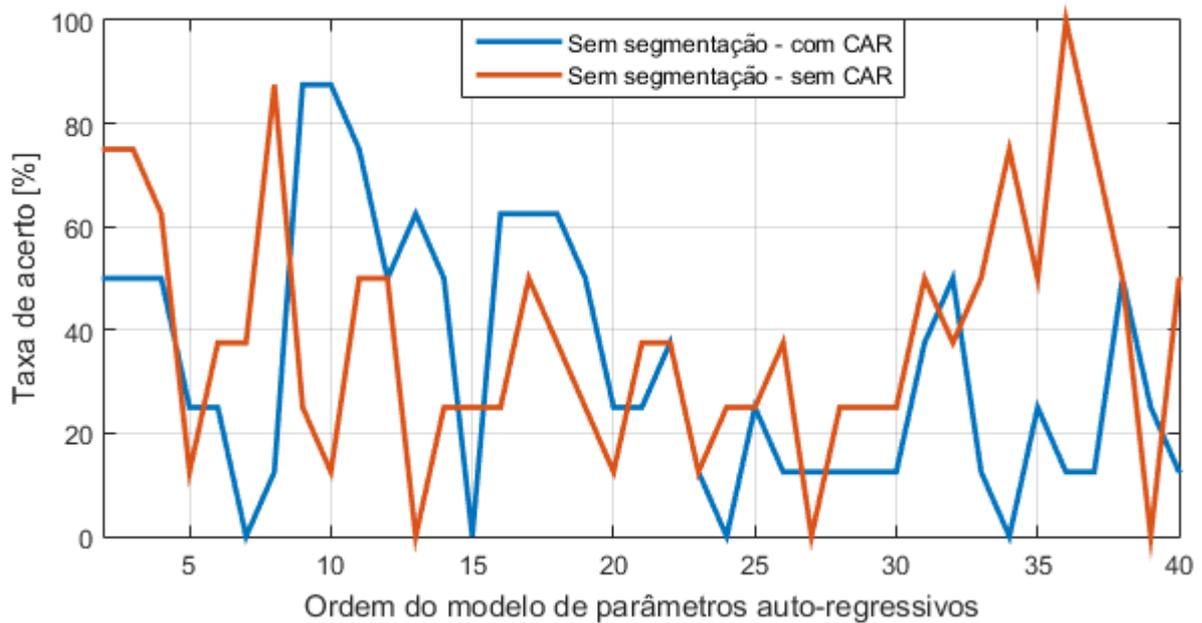
É esperado que, para segmentos maiores, melhores resultados sejam obtidos com modelos autorregressivos de maior ordem, visto que o sinal será de maior comprimento.

Figura 29 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 6 s.



Fonte: Do autor.

Figura 30 – Desempenho do classificador - 20 Hz e 30 Hz - Janela de 12 s.



A Tabela 4 resume os melhores resultados apresentados pelo uso de coeficientes autorregressivos extraídos pelo método de Burg para o par de frequência de 20 Hz e 30 Hz:

Tabela 4 – Melhores taxas de acerto - Coeficientes AR - 20 Hz e 30 Hz.

Janela [s]	Overlap [50%]	Ordem	CAR	Taxa de Acerto [%]
2	Não	11	Sim	66.67
2	Sim	10	Sim	65.91
3	Não	22	Sim	68.75
3	Sim	23	Sim	69.64
3	Sim	20	Não	62.5
4	Não	15	Sim	67.5
4	Sim	15	Sim	67.5
4	Sim	4	Não	72.5
6	Não	11	Sim	75
6	Sim	12	Sim	79.17
6	Não	11	Não	75
6	Sim	34	Não	70.83
12	Não	9	Sim	87.5
12	Não	10	Sim	87.5
12	Não	8	Não	87.5
12	Não	36	Não	100

Fonte: Do autor.

Analisando os resultados apresentados pelas Tabelas 2, 3 e 4, nota-se que as taxas de acerto apresentadas pelos três pares de frequência, utilizando-se do método de coeficientes autorregressivos, são bastantes semelhantes para todas as configurações testada. Apresentando as melhores taxas de acerto entre 60% e 80% para as janelas de 2 s, 3 s e 4 s. Taxas de acerto acima de 80% foram apresentados apenas para os comprimentos de janela de 6 s e 12 s, destaca-se que para o comprimento de 12 s foi possível obter taxas de acerto de 100 % para todos os pares de frequência testados. Nesta técnica de extração, foi mantida a tendência de melhoria da taxa de acerto com o aumento do comprimento da janela, para todas as configurações testadas. Importante notar também que, em geral, as melhores taxas de acerto foram obtidas pelos modelos de parâmetros autorregressivos cujas ordens se encontram no intervalo que vai da ordem 10 até a ordem 30 em sua maioria.

Através dos testes realizados, pode-se observar que a aplicação do método de filtragem espacial CAR tende a melhorar o desempenho do classificador em janelas de menor comprimento (1 s, 2 s e 3 s). As janelas maiores, principalmente a janela de 12 s, apresentaram melhores taxas de acerto sem a aplicação da filtragem espacial, apresentando 100% de precisão na classificação quando não se utilizou o CAR. As janelas de 4 s e 6 s apresentaram resultados praticamente indiferentes à aplicação da técnica CAR.

Comparando os resultados apresentados pela aplicação de coeficientes AR com as informações da Tabela 1, pode-se observar que as taxas de acerto apresentadas pelo método de Welch são mais altas para janelas menor comprimento, em geral. Por outro lado, em janelas de maior comprimento, 6 s e 12 s, ambas as técnicas apresentaram bom desempenho, com taxas de acerto semelhantes.

4 Conclusão

4.1 Considerações Finais

Neste trabalho foi desenvolvida a etapa de processamento de sinais de uma BCI, utilizando uma base de dados de sinais cerebrais coletada sobre o paradigma SSVEP. Foi possível realizar a comparação entre duas técnicas de extração de características, ambas foram utilizadas para se determinar a melhor configuração a ser utilizada em uma aplicação de BCI. É importante ressaltar que, além da taxa de acerto, também deve-se levar em consideração o comprimento de janela, o qual deve ser adequado para aplicações BCI com latência mecânica.

Dentre as duas técnicas empregadas, a avaliação espectral pelo método de Welch apresentou melhor desempenho, atingindo taxas de acerto superiores a 90% para algumas configurações. A extração de características pelo método de Burg também forneceu bons resultados com suas melhores taxas de acerto entre 70% e 100%, porém, valores acima de 90% só foram obtidos com janelas de 6 s e 12 s, enquanto o Método de Welch apresentou taxas de acerto melhores utilizando-se de janelas de menor comprimento. A Tabela 5 condensa os melhores resultados apresentados pelas configurações que satisfazem os critérios de aplicação requeridos.

Tabela 5 – Melhores configurações para aplicações assistivas

Método	Frequências [Hz]	Janela [s]	<i>Overlap</i>	Acerto [%]
AR	20 e 30	4	Não	72.5
AR	12 e 15	4	Não	75
AR	6 e 7.5	4	Sim	75
Welch	20 e 30	4	Sim	85
Welch	12 e 15	4	Sim	92.5
AR	20 e 30	6	Não	79.17
AR	12 e 15	6	Sim	83.33
AR	6 e 7.5	6	Não	87.5
Welch	20 e 30	6	Sim	87.5
Welch	12 e 15	6	Sim	95.83

Fonte: Do autor.

Entre os três pares de frequências testados pelo Método de Welch, de acordo com os dados da Tabela 1, o par de frequências de 12 Hz e 15 Hz apresentou os melhores resultados, com taxas de acerto de 92,5%, 95,83% e 95,83% para as janelas de 4 s com e sem *overlap* e para a janela de 6 s com *overlap*, respectivamente. Destes, a opção de janelamento mais apropriada para ser utilizada em uma aplicação BCI, que permita a

entrada de novos comandos após intervalos de tempo não tão longos, é a janela de 4 s com *overlap*. Apesar de apresentar a menor taxa de acerto entre as três citadas, após preenchido o *buffer* de 4 s ao ser dada a primeira instrução, esta permite a entrada de um novo comando a cada 2 s, tempo considerado como aceitável para uma aplicação assistiva com latência mecânica na operação.

4.2 Trabalhos Futuros

O desenvolvimento deste trabalho possibilitou o melhor entendimento de interfaces cérebro-computador, além de apresentar resultados que mostram a possibilidade de desenvolvimento de aplicações para esta tecnologia. Todavia, ainda é necessário que muito trabalho seja realizado para que esta tecnologia seja utilizada, com cada vez mais confiabilidade e segurança no futuro. Algumas sugestões para trabalhos futuros:

- Implementação de uma interface cérebro-computador em uma aplicação que possa ser utilizada por um usuário deficiente, utilizando o projeto desenvolvido neste trabalho.
- Desenvolver a etapa de seleção de atributos, a qual não foi implementada neste trabalho.
- Utilização de outras técnicas de pré-processamento como a filtragem espaço-temporal, ou aplicação de técnicas de separação cega de fontes.
- Implementação de outras técnicas de extração de características no domínio temporal, como modelos adaptativos.
- Teste de técnicas de classificação não lineares como Fuzzy e redes neurais, por exemplo, em busca de possíveis melhores resultados.
- Aplicação destes métodos em outros paradigmas de BCI, como a Imagética Motora e P300.
- Análise de correlação dos sinais através da aplicação de técnicas como PCA (Análise de componentes principais).

Referências

- ALHADDAD, M. J. Common Average Reference (CAR) improves P300 speller. *International Journal of Engineering and Technology*, Citeseer, v. 2, n. 3, p. 21, 2012. 9
- AMIRI, S. et al. A review of P300, SSVEP, and hybrid P300/SSVEP Brain-Computer Interface systems. *Brain-Computer Interface Systems—Recent Progress and Future Prospects*, InTech Rijeka, Coratia, 2013. 2
- BIRBAUMER, N.; MURGUIALDAY, A. R.; COHEN, L. Brain-Computer Interface in paralysis. *Current opinion in neurology*, LWW, v. 21, n. 6, p. 634–638, 2008. 5
- BROCKWELL, P.; DAHLHAUS, R. Generalized Levinson–Durbin and Burg algorithms. *Journal of Econometrics*, Elsevier, v. 118, n. 1, p. 129–149, 2004. 14
- BRUNNER, P. et al. Current trends in hardware and software for Brain-Computer Interfaces (BCIs). *Journal of neural engineering*, IOP Publishing, v. 8, n. 2, p. 025001, 2011. 6
- BURG, J. P. Maximum entropy spectral analysis. In: SOCIETY OF EXPLORATION GEOPHYSICS. *37th Annual International Meeting*. [S.l.], 1967. 13
- BURG, J. P. A new analysis technique for time series data. *Advanced Study Institute on Signal Processing with Emphasis on Underwater Acoustics*, New York, NY, USA: IEEE, v. 1, 1968. 13
- CARVALHO, S. N. et al. Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. *Biomedical Signal Processing and Control*, Elsevier, v. 21, p. 34–42, 2015. 8
- CASTIGLIONI, P. Levinson–Durbin Algorithm. *Encyclopedia of Biostatistics*, Wiley Online Library, 2005. 14
- GARCIA-MOLINA, G.; ZHU, D. Optimal spatial filtering for the Steady State Visual Evoked Potential: BCI application. In: IEEE. *Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference on*. [S.l.], 2011. p. 156–160. 9
- GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. Brain-Computer Interfaces: A gentle introduction. In: *Brain-Computer Interfaces*. [S.l.]: Springer, 2010. p. 1–27. 3
- GROSSE-WENTRUP, M. Understanding Brain Connectivity Patterns during Motor Imagery for Brain-Computer Interfacing. In: KOLLER, D. et al. (Ed.). *Advances in Neural Information Processing Systems 21*. [S.l.]: Curran Associates, Inc., 2009. p. 561–568. 1
- GUPTA, H. R. Power spectrum estimation using Welch’s method for various windows. *Techniques*, v. 2, n. 6, p. 389–392, 2013. 13
- HASAN, B. A. S.; GAN, J. Q. Hangman BCI: An unsupervised adaptive self-paced Brain-Computer Interface for playing games. *Computers in biology and medicine*, Elsevier, v. 42, n. 5, p. 598–606, 2012. 6

- HOLZ, E. M. et al. Long-term independent Brain-Computer Interface home use improves quality of life of a patient in the locked-in state: a case study. *Archives of physical medicine and rehabilitation*, Elsevier, v. 96, n. 3, p. S16–S26, 2015. 6
- HOON, M. D. et al. Why Yule-Walker should not be used for autoregressive modelling. *Annals of Nuclear Energy*, Elsevier, v. 23, n. 15, p. 1219–1228, 1996. 13
- KLEM, G. H. et al. The ten-twenty electrode system of the International Federation. *Electroencephalogr Clin Neurophysiol*, v. 52, n. suppl., p. 3, 1999. 8
- KRUSIENSKI, D. J. et al. Critical issues in state-of-the-art Brain-Computer Interface signal processing. *Journal of neural engineering*, IOP Publishing, v. 8, n. 2, p. 025002, 2011. 6
- KÜBLER, A. et al. Patients with ALS can use sensorimotor rhythms to operate a Brain-Computer Interface. *Neurology*, AAN Enterprises, v. 64, n. 10, p. 1775–1777, 2005. 2
- LEBEDEV, M. A.; NICOLELIS, M. A. Brain-Machine Interfaces: past, present and future. *TRENDS in Neurosciences*, Elsevier, v. 29, n. 9, p. 536–546, 2006. 5
- LI, Y. et al. A hybrid BCI system combining P300 and SSVEP and its application to wheelchair control. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 60, n. 11, p. 3156–3166, 2013. 6
- LUDWIG, K. A. et al. Using a Common Average Reference to improve cortical neuron recordings from microelectrode arrays. *Journal of neurophysiology*, Am Physiological Soc, v. 101, n. 3, p. 1679–1689, 2009. 9
- MAK, J. N.; WOLPAW, J. R. Clinical applications of Brain-Computer Interfaces: current state and future prospects. *Biomedical Engineering, IEEE Reviews in*, IEEE, v. 2, p. 187–199, 2009. 5
- MASON, S. G.; BIRCH, G. E. A general framework for Brain-Computer Interface design. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, IEEE, v. 11, n. 1, p. 70–85, 2003. 4
- MILLÁN, J. d. R.; CARMENA, J. Invasive or Noninvasive: understanding Brain-Machine Interface technology. *IEEE Engineering in Medicine and Biology Magazine*, Institute of Electrical and Electronics Engineers, v. 29, n. EPFL-ARTICLE-150426, p. 16–22, 2010. 2, 6
- MING, D. et al. Time-locked and phase-locked features of P300 event-related potentials (ERPs) for brain-computer interface speller. *Biomedical Signal Processing and Control*, Elsevier, v. 5, n. 4, p. 243–251, 2010. 2
- MÜLLER-PUTZ, G. R.; PFURTSCHELLER, G. Control of an electrical prosthesis with an SSVEP-based BCI. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 55, n. 1, p. 361–364, 2008. 2
- NASSAR, S. et al. Modeling inertial sensor errors using autoregressive (AR) models. *Navigation*, Wiley Online Library, v. 51, n. 4, p. 259–268, 2004. 13

- NEUPER, C. et al. Clinical application of an EEG-based Brain–Computer Interface: a case study in a patient with severe motor impairment. *Clinical neurophysiology*, Elsevier, v. 114, n. 3, p. 399–409, 2003. 2
- OLSON, D. L.; DELEN, D. *Advanced data mining techniques*. [S.l.]: Springer Science & Business Media, 2008. 16
- OPPENHEIM, A. V. *Discrete-Time Signal Processing*. [S.l.]: Pearson Education, 2011. 13
- SCHALK, G. et al. BCI2000: a general-purpose Brain-Computer Interface (BCI) system. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 51, n. 6, p. 1034–1043, 2004. 6, 4
- SELLERS, E. W. et al. A P300 event-related potential Brain–Computer Interface (BCI): the effects of matrix size and inter stimulus interval on performance. *Biological psychology*, Elsevier, v. 73, n. 3, p. 242–252, 2006. 1
- STEINMETZ, H.; FÜRST, G.; MEYER, B.-U. Craniocerebral topography within the international 10–20 system. *Electroencephalography and clinical neurophysiology*, Elsevier, v. 72, n. 6, p. 499–506, 1989. 8
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. [S.l.]: Elsevier, 2009. 14
- VIALATTE, F.-B. et al. Steady-State Visually Evoked Potentials: focus on essential paradigms and future perspectives. *Progress in neurobiology*, Elsevier, v. 90, n. 4, p. 418–438, 2010. 2
- VIDAL, J. J. Real-time detection of brain events in EEG. *Proceedings of the IEEE*, IEEE, v. 65, n. 5, p. 633–641, 1977. 4
- WALKER, J. S. *Fast Fourier Transforms*. [S.l.]: CRC press, 1996. v. 24. 11
- WELCH, P. D. The use of Fast Fourier Transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms. *IEEE Transactions on audio and electroacoustics*, v. 15, n. 2, p. 70–73, 1967. 11
- WOLPAW, J. R. et al. Brain-Computer Interface technology: a review of the first international meeting. *IEEE transactions on rehabilitation engineering*, Citeseer, v. 8, n. 2, p. 164–173, 2000. 4
- WOLPAW, J. R. et al. Brain–computer Interfaces for communication and control. *Clinical neurophysiology*, Elsevier, v. 113, n. 6, p. 767–791, 2002. 4
- WOLPAW, J. R.; MCFARLAND, D. J.; VAUGHAN, T. M. Brain-Computer Interface research at the Wadsworth Center. *Rehabilitation Engineering, IEEE Transactions on*, IEEE, v. 8, n. 2, p. 222–226, 2000. 4
- YIN, E. et al. A speedy hybrid BCI spelling approach combining P300 and SSVEP. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 61, n. 2, p. 473–483, 2014. 6