



Classificação automática de crises epilépticas e crises não epilépticas psicogênicas utilizando aprendizado de máquina

Santos KR*, Pires R*

**Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, São Paulo, Brasil.*

Resumo. Este artigo aborda o estudo e aplicação do classificador do tipo Máquina de Vetores de Suporte (SVM) na diferenciação entre crises epilépticas e crises não epilépticas psicogênicas (CNEP). Um banco de dados com exames de eletroencefalograma (EEG) contendo 117 crises epilépticas e 42 crises não epilépticas psicogênicas foram coletados na Unidade de Videoeletroencefalografia do Instituto de Psiquiatria do Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo (IPq-HCFMUSP). Baseando-se nos registros dos 18 canais do EEG durante cada crise, foram gerados vetores de características com quatro atributos: média, desvio padrão, valor máximo e valor mínimo. Estes vetores de características foram utilizados na fase de treinamento e avaliação do classificador SVM em quatro configurações de *kernels* disponíveis: Linear, Polinomial, Função de Base Radial (RBF) e Sigmoides. Como resultado, o *kernel* Polinomial apresentou melhor desempenho com a taxa de acerto (acurácia) de 78,7%, sensibilidade de 100% e especificidade de 2,4%. Com base nos vetores de características utilizados, foi possível concluir que o classificador SVM é adequado para a detecção de crises epilépticas, sendo inadequado para os casos de CNEP. Estes resultados podem ser otimizados com a aplicação da Transformada de Fourier ou Transformada Wavelet no tratamento prévio dos sinais de EEG, além da geração de vetores de características com atributos distintos.

Palavras-chave. *crise epiléptica, CNEP, EEG, SVM.*

Introdução. Epilepsia é um distúrbio cerebral que afeta cerca de 1% da população mundial e, no Brasil, há aproximadamente 3 milhões de pacientes diagnosticados com este distúrbio. É caracterizada por atividades elétricas anormais dos neurônios no cérebro que podem levar a convulsões recorrentes e espontâneas (1,2).

Para a confirmação da epilepsia, é executada uma técnica não invasiva denominada Eletroencefalografia. Esta técnica faz uso de vários eletrodos no couro cabeludo para capturar a atividade eletrofisiológica que é originada no cérebro, sendo que cada eletrodo corresponde a um canal distinto. O produto destas medidas é o eletroencefalograma (EEG), que consiste no conjunto de sinais gravados em cada canal. O EEG tem sido uma ferramenta valiosa no diagnóstico e avaliação de distúrbios neurológicos, em particular para a epilepsia. Os pacientes que são suspeitos de apresentar essa condição estão sempre sujeitos a uma gravação de EEG (1).

A detecção de crises epiléticas é um componente importante no diagnóstico de epilepsia e para o controle de convulsões (3). Por um lado, esta detecção envolve a observação visual das gravações de EEG por médicos neurofisiologistas experientes na prática clínica. Com esta análise visual, é possível identificar e classificar a crise presente no sinal de EEG. Geralmente, os registros são multicanal, então sua investigação implica uma tarefa complexa e demorada (3-4). Por outro lado, um sistema auxiliar de detecção automática de crises poderia reduzir consideravelmente o volume de dados a serem observados pelos médicos (4).

Além disso, este sistema auxiliar também poderia ajudar na diferenciação entre crises epiléticas (CE) e crises não epiléticas psicogênicas (CNEP), ou seja, crises de origem psicológica. Cerca de 20% dos indivíduos encaminhados aos centros de estudos de epilepsia sofrem de CNEP (2).

Crise Epilética e Epilepsia. Crise epilética é conceituada como atividade elétrica anormal, excessiva e síncrona de grupos dos neurônios. Ocorrem transitoriamente sinais e / ou sintomas característicos que podem ser constatados tanto pelo paciente quanto por um observador, tais como: alterações na consciência, ou eventos motores, sensitivos/sensoriais, autonômicos ou psíquicos involuntários (5).

Epilepsia, segundo a Liga Internacional Contra a Epilepsia (ILAE), é definida como:

“Epilepsia é um transtorno do cérebro caracterizado por uma predisposição duradoura em gerar crises epiléticas, com consequências neurobiológicas, sociais, cognitivas e psicológicas. A definição de epilepsia requer a ocorrência de, pelo menos, uma crise epilética (5).”

Na figura 1, são apresentados os tipos de crises epiléticas. As crises generalizadas ocorrem em toda a região do cérebro. No caso das focais, apenas uma determinada região do cérebro é afetada (5).

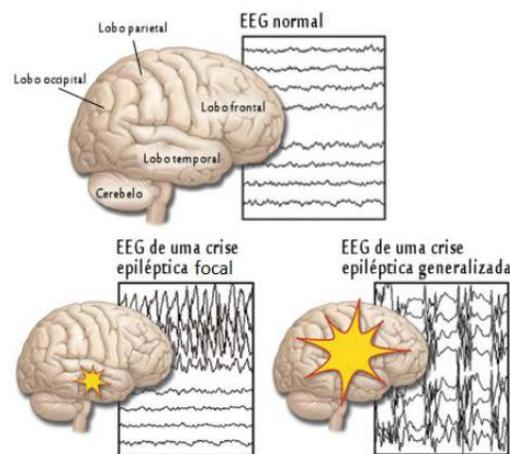


Figura 1. Tipos de crises epiléticas e regiões afetadas

Crise Não Epiléptica Psicogênica (CNEP). A Crise Não Epiléptica Psicogênica (CNEP), também designada *Psychogenic Non-Epileptic Seizures* (PNES), apesar de ter comportamento similar ao da crise epiléptica, diferencia-se desta por não ter origem nas descargas elétricas anormais características de crises epilépticas. Ao invés disso, sua origem é psicológica (6).

Na figura 2, é apresentado um subconjunto de traçados de EEG típicos de crises epilépticas (A), ou do inglês, *generalized spike wave discharges* (GSW). Neste caso, há um surto de pico generalizado de 3-5 Hz e complexo de onda lenta com duração de aproximadamente 5 segundos. Os marcadores indicam o início e o fim da crise. Em (B), ocorre um fragmento de EEG durante um PNES. Nenhum correlato de EEG pode ser visto e a gravação é frequentemente prejudicada por artefatos musculares (7).

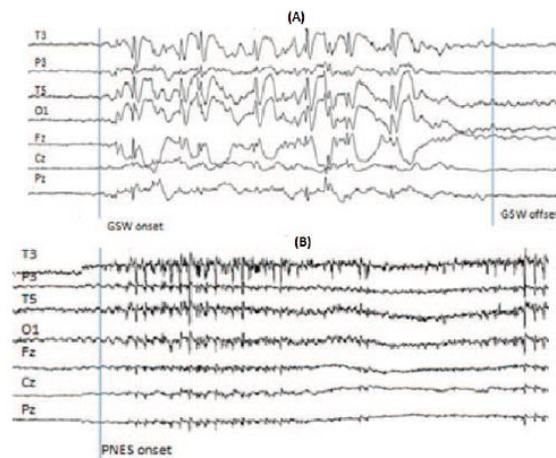


Figura 2. Diferentes tipos de crises a partir do EEG: (A) Crise epiléptica e (B) CNEP (7)

As CNEPs geram graves consequências sociais e psicológicas, como o desemprego, dificuldades interpessoais, baixa escolarização e exclusão social. Da mesma forma, sob o ponto de vista médico, os pacientes ficam expostos ao uso de doses elevadas de drogas antiepilépticas e outros procedimentos invasivos como a intubação endotraqueal (figura 3) (6).

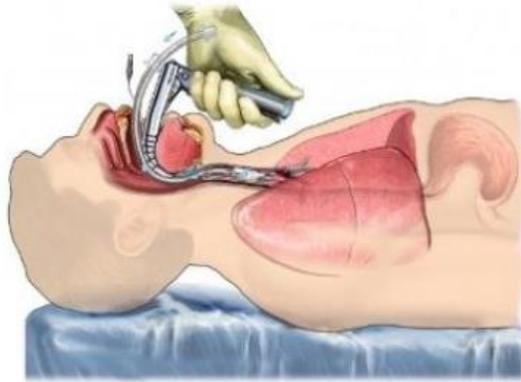


Figura 3. Intubação endotraqueal

Diagnóstico Clínico da Epilepsia. O diagnóstico clínico de uma crise epilética é obtido através de um histórico detalhado do paciente juntamente com um exame físico geral baseado nas áreas da Neurologia e Psiquiatria. Além disso, para uma descrição mais detalhada da crise, é de suma importância uma testemunha ocular, devido ao rebaixamento do nível de consciência do paciente. O diagnóstico complementar ocorre através do exame de eletroencefalograma (EEG) devidamente acompanhado pelo histórico e exame físico do paciente. Além disso, exames de neuroimagem e neuropsicológico também são necessários. Estes exames ajudam o médico a ter um diagnóstico mais preciso (8).

Diagnóstico da CNEP. Identificar e diagnosticar com precisão a CNEP é um desafio para psiquiatras e neurologistas. Atualmente, o diagnóstico da CNEP depende da exclusão da epilepsia. Logo, os pacientes são submetidos a diversos testes antes do diagnóstico final de CNEP. O padrão-ouro para excluir a epilepsia é a telemetria de vídeo-eletroencefalografia (vídeo-EEG) para analisar as convulsões típicas. Acredita-se que a observação de convulsões típicas, combinada com a atividade cerebral registrada, leve a um diagnóstico preciso em até 90% dos casos (9).

Interpretação dos resultados de exames. As principais características de desempenho dos exames diagnósticos com resultados numéricos são: Sensibilidade, Especificidade e Acurácia. Os cálculos dessas características se baseiam na figura 4 (10).

		DOENÇA	
		Presente	Ausente
TESTE	Positivo	Verdadeiro Positivo (VP)	Falso Positivo (FP)
	Negativo	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Figura 4. Teste de diagnóstico

Sensibilidade (equação 1): avalia, na presença da doença, o rendimento do teste em detectar a doença (Verdadeiro Positivo - VP), ou seja, calcula a probabilidade de o teste dar positivo.

$$\text{Sensibilidade} = \frac{VP}{VP+FN} \quad (1)$$

Especificidade (equação 2): avalia, na ausência da doença, o rendimento do teste em dispensar a doença (Verdadeiro Negativo - VN), ou seja, calcula a probabilidade de o teste dar negativo.

$$\text{Especificidade} = \frac{VN}{VN+FP} \quad (2)$$

Acurácia (equação 3): é a proporção de acertos, ou seja, o total de verdadeiramente positivos e verdadeiramente negativos, em relação a amostra estudada.

$$\text{Acurácia} = \frac{VP+VN}{VP+FN+VN+FP} \quad (3)$$

Eletroencefalograma (EEG). Os neurônios no córtex cerebral (camadas mais externas do cérebro humano) processam suas informações por meio de sinais elétricos e, assim, possibilitam o registro elétrico de sua atividade através do exame de eletroencefalograma (11).

Na figura 5, é representado o esquema de um EEG com seus respectivos eletrodos posicionados na superfície do couro cabeludo de um paciente.

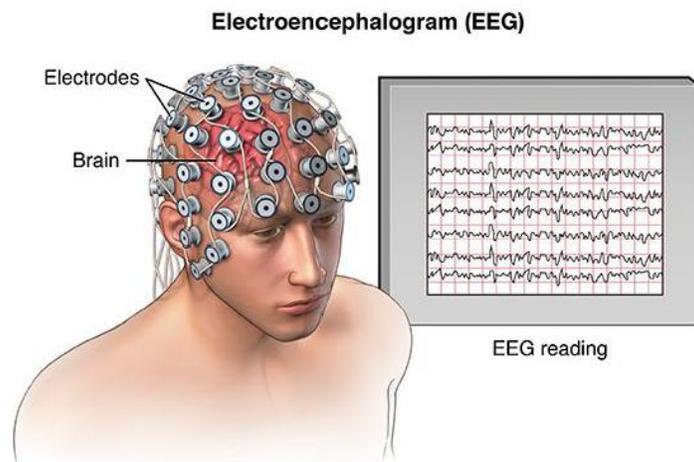


Figura 5. Exame de Eletroencefalograma (EEG)

O posicionamento dos eletrodos na superfície do couro cabeludo obedece ao sistema internacional 10-20, o qual faz relação em 10 e 20% de distâncias pré-determinadas. Os eletrodos de números pares se referem ao lado direito do cérebro e os ímpares ao esquerdo. A letra z (zero) indica os eletrodos localizados na linha média. (12).

Máquina de Vetores de Suporte (SVM). A Máquina de Vetores de Suporte (SVM), baseada na Teoria da Aprendizagem Estatística, foi proposta por Vladimir N. Vapnik, em 1963. Este algoritmo foi elaborado com o intuito de resolver problemas de classificações de padrões, especialmente para classificações binárias em que os dados são sempre classificados em apenas duas classes (13-15).

O aprendizado da SVM é considerado como um aprendizado supervisionado, pois, para o seu treinamento, necessita de um “professor” para indicar se um determinado dado de treinamento se enquadra em uma classe ou em outra. Depois deste treinamento, este classificador consegue prever (prever) a classe de novas entradas, excluindo-se as anteriormente utilizadas para o treinamento (13; 15).

Para dados linearmente separáveis, esta técnica busca a criação de um hiperplano ótimo como superfície de decisão, ou seja, uma fronteira linear com separação máxima para estes dados. Já para dados não-linearmente separáveis, utiliza-se uma função de *kernel* para tornar o conjunto mapeado em linearmente separável transformando num espaço com mais dimensões. Além disso, esta técnica é considerada altamente robusta, pelo fato de poder trabalhar com dados com muitas dimensões (13; 15).

Existem diversas funções de *kernel*, como a Linear, Polinomial, Função de Base Radial (RBF) e Sigmoides.

Funcionamento básico da SVM. Para dados linearmente separáveis, durante o processamento do algoritmo SVM, são geradas diversas retas (hiperplanos) que dividem as duas classes (círculos azuis e quadrados vermelhos), apresentadas na figura 6. O objetivo do algoritmo SVM é determinar qual reta é a melhor para se obter um hiperplano de separação com margem máxima (hiperplano ótimo).

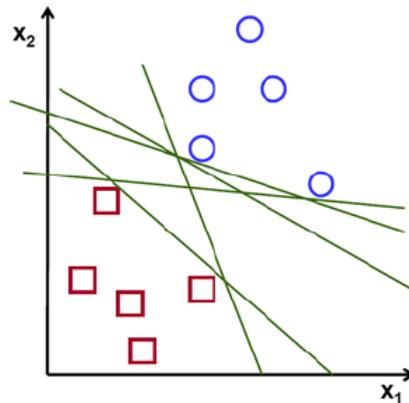


Figura 6. Diversos hiperplanos gerados pelo SVM

Durante o treinamento da SVM que, ocorre no seu processamento, são definidas duas retas paralelas com base nos vetores de suporte (figura 7). E, a partir destas duas retas paralelas, o hiperplano ótimo será definido distanciando-as com a mesma margem.

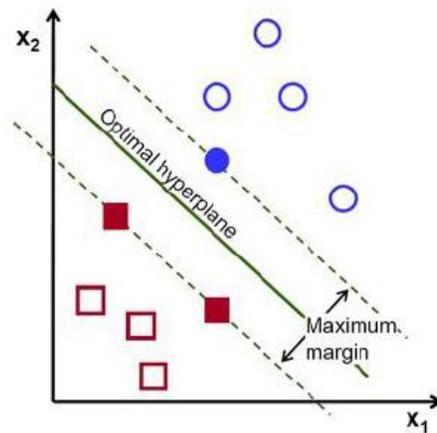


Figura 7. Vetores de suporte para a construção do hiperplano ótimo

Na figura 8, são apresentados hiperplanos dividindo dados linearmente separáveis em uma, duas e três dimensões.

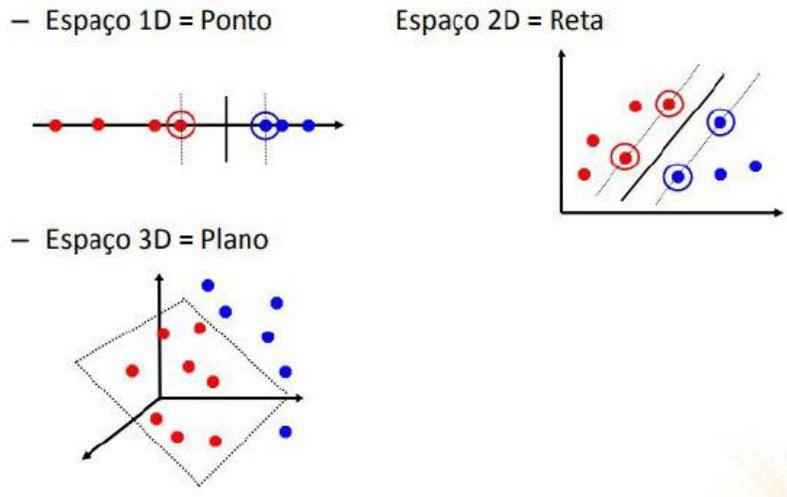


Figura 8. Hiperplano separando dados linearmente separáveis em 1D, 2D e 3D

No caso de dados de treinamento não linearmente separáveis, utiliza-se a função de *kernel*, a qual mapeará os dados iniciais para um espaço com mais dimensões, tornando-os linearmente separáveis (figura 9 e 10).

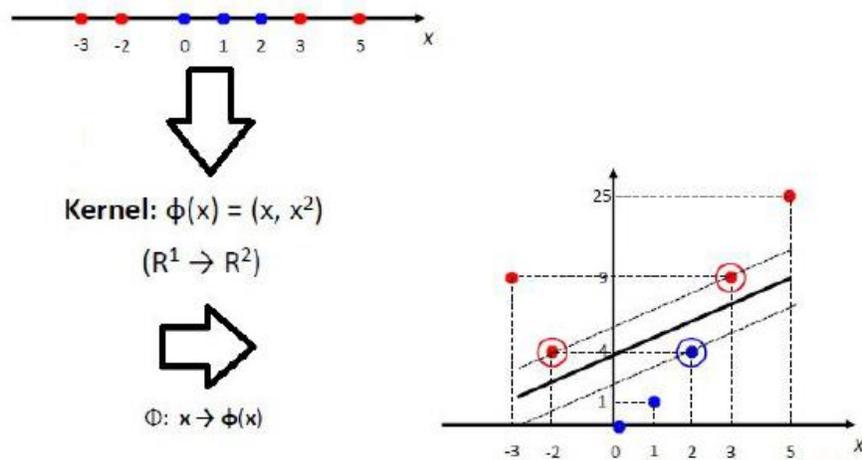


Figura 9. Função de *kernel* mapeando dados de 1 para 2 Dimensões

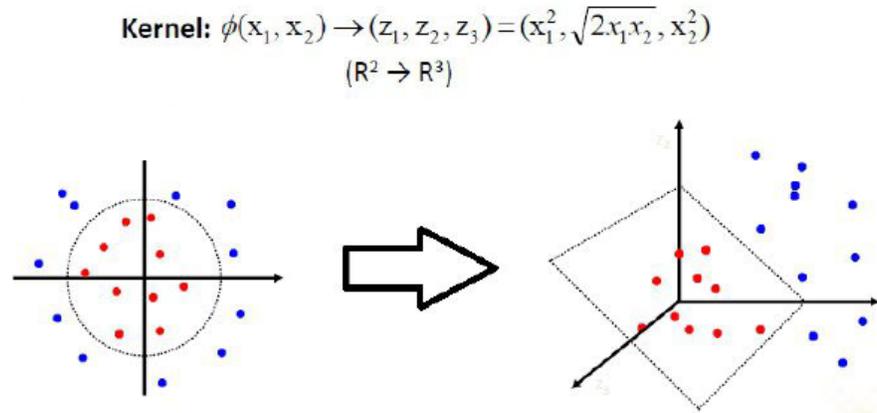


Figura 10. Função de *kernel* mapeando dados de 2 para 3 Dimensões

Metodologia.

Base de dados. Através da parceria do Laboratório de Controle Aplicado do Instituto Federal de São Paulo campus São Paulo (16) com a Unidade de Videoeletroencefalografia do Instituto de Psiquiatria do Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo (17), os arquivos (dados experimentais) de videoeletroencefalograma (VEEG) foram disponibilizados e coletados nesta unidade e, posteriormente, utilizados no experimento.

No total, foram utilizados os dados de 30 pacientes, conforme a tabela 1:

Tabela 1. Pacientes - Crise Não Epiléptica Psicogênica (CNEP) e Crise Epiléptica (CE)

CNEP				CE			
Paciente	Sexo	Idade	Quant. de CNEP	Paciente	Sexo	Idade	Quant. de CE
1	F	38	17	12	F	28	3
2	M	54	1	13	F	20	29
3	F	50	7	14	F	45	2
4	F	23	3	15	F	9	23
5	F	15	3	16	F	49	1
6	M	39	3	17	F	43	13
7	M	36	1	18	M	26	2
8*	F	15	1	19	M	32	2
8*	F	17	2	20	M	28	1
9	F	23	2	21	F	15	2

10**	F	35	1	22	F	52	5
11***	F	32	1	23	M	52	1
---	---	---	---	24	M	16	3
---	---	---	---	25	F	6	3
---	---	---	---	26	M	57	5
---	---	---	---	27	M	41	2
---	---	---	---	28	M	56	1
---	---	---	---	29	M	34	7
---	---	---	---	30	F	15	5
---	---	---	---	10**	F	35	6
---	---	---	---	11***	F	32	1
Total			42	Total			117

Nota: * mesma paciente, porém os exames ocorreram em períodos distintos, ** e *** pacientes apresentaram CNEP e CE

Na etapa de treinamento e avaliação da SVM, foram utilizados quatro tipos de kernel: Linear, Polinomial, RBF e Sigmoide. Esses kernels foram utilizados com os vetores de características gerados pela extração direta do sinal EEG que contém os registros dos 18 canais. As amostras utilizadas para treinamento e avaliação foram selecionadas de forma que sempre fossem de pacientes distintos.

Características do aparelho de Videoeletroencefalografia. Os arquivos contendo as crises epiléticas e crises não epiléticas psicogênicas foram gerados pelo aparelho de videoeletroencefalografia (VEEG) das figuras 11 e 12. O tipo de montagem utilizado foi a “Montagem Bipolar Longitudinal” ou “Montagem Dupla Banana” (figura 13).



Figura 11. Aparelho de videoeletroencefalografia



Figura 12. Neurofax EEG-1200 (JE-921A)

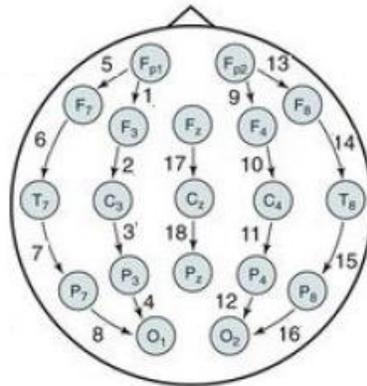


Figura 13. Montagem bipolar longitudinal ou “montagem dupla banana”

Em seguida, são apresentadas as suas características no quadro 1:

Quadro 1. Características do aparelho de Videoeletroencefalografia

Características	Descrição
Fabricante	Nihon Kohden
Modelo	Neurofax EEG-1200 (JE-921A)
Software	NeuroWorkbench - EEG-1200 - Ver.08-10
Frequência de amostragem (Fs)	200 Hz (200 amostras por segundo)
Filtro passa-faixa	0,3 a 35 Hz
Sensibilidade	7 μ V/mm
Formato do arquivo de saída	EDF (18)
Quantidade de canais utilizados	18
Canal 1	Fp1-F3
Canal 2	F3-C3
Canal 3	C3-P3
Canal 4	P3-O1
Canal 5	Fp1-F7
Canal 6	F7-T7
Canal 7	T7-P7
Canal 8	P7-O1
Canal 9	Fp2-F4
Canal 10	F4-C4
Canal 11	C4-P4
Canal 12	P4-O2
Canal 13	Fp2-F8
Canal 14	F8-T8
Canal 15	T8-P8
Canal 16	P8-O2
Canal 17	Fz-Cz
Canal 18	Cz-Pz

Filtragem do sinal. Através do software NeuroWorkbench, os sinais em cada um dos 18 canais foram filtrados por um filtro passa-faixas permitindo a passagem de frequências entre 0,3 e 35 Hz. Este procedimento ocorreu antes da geração dos arquivos de EEG do tipo EDF.

Além disso, este procedimento também ocorre, pois as manifestações das crises registradas em EEG geralmente variam entre 0,5 a 30 Hz (19).

Etapas do experimento. De acordo com a figura 14, foram realizadas as seguintes etapas:

- 1) Leitura do arquivo do tipo EDF no software MATLAB (20) contendo toda a gravação e, em seguida, a seleção dos trechos com as crises, previamente identificadas por uma médica especialista na área;
- 2) Consideração do tempo total de cada crise;
- 3) Em cada crise, foi gerado um vetor de características com quatro atributos entre os 18 canais (média, desvio padrão, valor máximo e valor mínimo);
- 4) Utilização dos vetores de características para o treinamento e avaliação do classificador SVM. Após o treinamento, o classificador irá rotular uma nova amostra (vetor de características) do EEG em CNEP [-1] ou CE [+1]. Foram utilizados os *kernels* Linear, Polinomial, Função de Base Radial e Sigmoide.

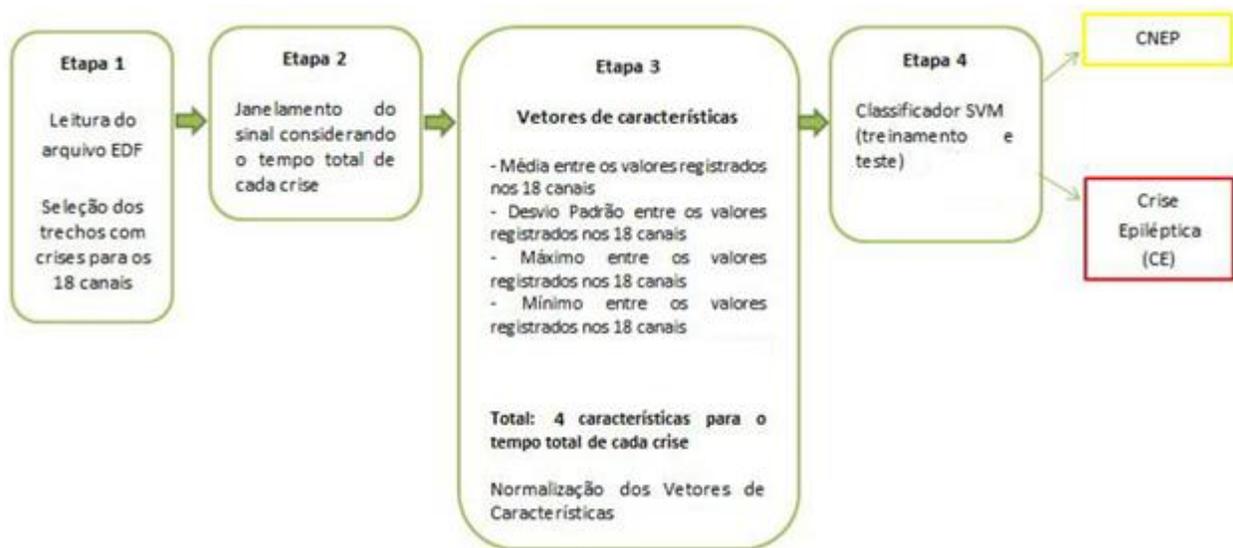


Figura 14. Etapas do experimento

Finalmente, através de análise estatística, foram realizadas as conclusões com base nos resultados fornecidos pelo MATLAB (20). Foram calculadas a Acurácia (precisão), Sensibilidade e Especificidade.

Resultados e Discussões. As amostras utilizadas para treinamento e avaliação foram selecionadas de forma que sempre fossem de pacientes distintos, conforme apresentado na tabela 1. Do item 1 ao 9 das tabelas abaixo, o número de amostras de treinamento (T) irá evoluir de forma decrescente e de avaliação (A) de forma crescente.



Baseando-se nas tabelas 2, 3, 4 e 5, foram gerados os gráficos da figura 15 que representam as médias do item 1 ao 9 da Acurácia, Sensibilidade e Especificidade de acordo com os vetores de características gerados pela extração direta do sinal EEG. “T” foi a etapa de treinamento e “A” a etapa de avaliação.

Tabela 2. Resultados das Previsões: SVM *kernel* Linear

Item	Pacientes CNEP		Pacientes CE		Acurácia (%)	Sensibilidade (%)	Especificidade (%)
	T	A	T	A			
1	1 a 9	10 a 11	12 a 29	30, 10 a 11	85,71	100,00	0,00
2	1 a 8	9 a 11	12 a 27	28 a 30, 10 a 11	83,33	100,00	0,00
3	1 a 7	8 a 11	12 a 25	26 a 30, 10 a 11	79,41	100,00	0,00
4	1 a 6	7 a 11	12 a 23	24 a 30, 10 a 11	80,49	100,00	0,00
5	1 a 5	6 a 11	12 a 21	22 a 30, 10 a 11	80,00	100,00	9,09
6	1 a 4	5 a 11	12 a 19	20 a 30, 10 a 11	76,79	100,00	7,14
7	1 a 3	4 a 11	12 a 17	18 a 30, 10 a 11	73,02	100,00	0,00
8	1 a 2	3 a 11	12 a 15	16 a 30, 10 a 11	71,43	100,00	0,00
9	1	2 a 11	12 a 13	14 a 30, 10 a 11	77,27	100,00	0,00

Tabela 3. Resultados das Previsões: SVM *kernel* Polinomial

Item	Pacientes CNEP		Pacientes CE		Acurácia (%)	Sensibilidade (%)	Especificidade (%)
	T	A	T	A			
1	1 a 9	10 a 11	12 a 29	30, 10 a 11	85,71	100,00	0,00
2	1 a 8	9 a 11	12 a 27	28 a 30, 10 a 11	83,33	100,00	0,00
3	1 a 7	8 a 11	12 a 25	26 a 30, 10 a 11	79,41	100,00	0,00
4	1 a 6	7 a 11	12 a 23	24 a 30, 10 a 11	82,93	100,00	12,50
5	1 a 5	6 a 11	12 a 21	22 a 30, 10 a 11	80,00	100,00	9,09
6	1 a 4	5 a 11	12 a 19	20 a 30, 10 a 11	75,00	100,00	0,00
7	1 a 3	4 a 11	12 a 17	18 a 30, 10 a 11	73,02	100,00	0,00
8	1 a 2	3 a 11	12 a 15	16 a 30, 10 a 11	71,43	100,00	0,00
9	1	2 a 11	12 a 13	14 a 30, 10 a 11	77,27	100,00	0,00

Tabela 4. Resultados das Previsões: SVM *kernel* RBF

Item	Pacientes CNEP		Pacientes CE		Acurácia (%)	Sensibilidade (%)	Especificidade (%)
	T	A	T	A			
1	1 a 9	10 a 11	12 a 29	30, 10 a 11	85,71	100,00	0,00
2	1 a 8	9 a 11	12 a 27	28 a 30, 10 a 11	66,67	80,00	0,00
3	1 a 7	8 a 11	12 a 25	26 a 30, 10 a 11	82,35	100,00	14,29
4	1 a 6	7 a 11	12 a 23	24 a 30, 10 a 11	82,93	100,00	12,50
5	1 a 5	6 a 11	12 a 21	22 a 30, 10 a 11	74,00	92,31	9,09
6	1 a 4	5 a 11	12 a 19	20 a 30, 10 a 11	69,64	90,48	7,14
7	1 a 3	4 a 11	12 a 17	18 a 30, 10 a 11	73,02	97,83	5,88
8	1 a 2	3 a 11	12 a 15	16 a 30, 10 a 11	71,43	98,33	4,17
9	1	2 a 11	12 a 13	14 a 30, 10 a 11	77,27	100,00	0,00

Tabela 5. Resultados das Previsões: SVM *kernel* Sigmoide

Item	Pacientes CNEP		Pacientes CE		Acurácia (%)	Sensibilidade (%)	Especificidade (%)
	T	A	T	A			
1	1 a 9	10 a 11	12 a 29	30, 10 a 11	64,29	75,00	0,00
2	1 a 8	9 a 11	12 a 27	28 a 30, 10 a 11	70,83	85,00	0,00
3	1 a 7	8 a 11	12 a 25	26 a 30, 10 a 11	70,59	85,19	14,29
4	1 a 6	7 a 11	12 a 23	24 a 30, 10 a 11	68,29	81,82	12,50
5	1 a 5	6 a 11	12 a 21	22 a 30, 10 a 11	64,00	76,92	18,18
6	1 a 4	5 a 11	12 a 19	20 a 30, 10 a 11	75,00	100,00	0,00
7	1 a 3	4 a 11	12 a 17	18 a 30, 10 a 11	65,08	89,13	0,00
8	1 a 2	3 a 11	12 a 15	16 a 30, 10 a 11	71,43	100,00	0,00
9	1	2 a 11	12 a 13	14 a 30, 10 a 11	77,27	100,00	0,00

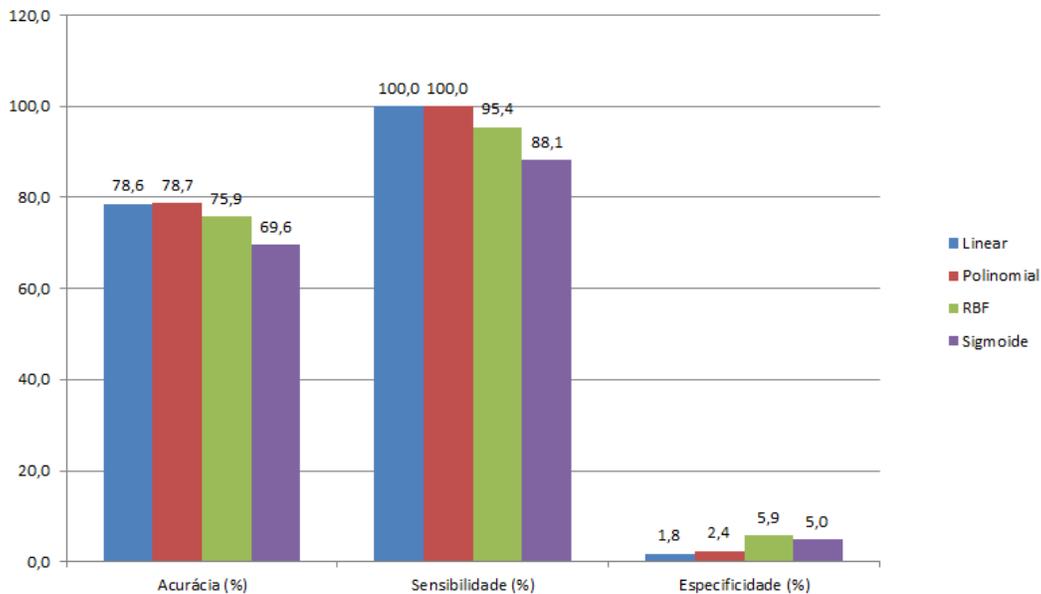


Figura 15. Média das previsões - SVM



No gráfico da figura 15, a acurácia (taxa de acerto de CE e CNEP) apresentou melhores resultados para os *kernels* Polinomial e Linear. Em seguida, com uma redução próxima de 3%, o RBF. Por último, o *kernel* Sigmoide com 69,6%.

A sensibilidade, relacionada à CE, ou seja, a chance de a SVM classificar uma amostra como verdadeiro positivo (+1) na presença da doença, apresentou resultado de 100% para os *kernels* Linear e Polinomial.

A especificidade, relacionada à CNEP, ou seja, a chance de a SVM classificar uma amostra como verdadeiro negativo (-1) na ausência da doença, para todos os *kernels*, apresentou os menores resultados ultrapassando 6% de acerto. Praticamente todos os *kernels* não conseguiram identificar as CNEPs.

No geral, os resultados da acurácia da extração direta do sinal para todos os *kernels* não ultrapassaram os 79%. A sensibilidade apresentou resultados satisfatórios, porém a especificidade obteve os menores resultados.

Conclusões. Baseando-se nos resultados obtidos, foi possível concluir que o classificador SVM com os *kernels* utilizados não são adequados para a diferenciação entre CE e CNEP, a partir da configuração dos vetores de características gerados pela extração direta do sinal de EEG.

Além disso, constatou-se que o classificador SVM é adequado para a detecção de crises epilépticas, porém sendo inadequado para os casos de CNEP.

Estes resultados podem ser otimizados com a aplicação da Transformada de Fourier ou Transformada Wavelet no tratamento prévio dos sinais de EEG e na geração de vetores de características com atributos distintos.

Agradecimentos. Agradeço a Dra. Maria Sigrilde Thomé de Souza e toda a sua equipe da Unidade de Videoeletroencefalografia (VEEG) do Instituto de Psiquiatria do Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo (IPq-HCFMUSP) por disponibilizarem os dados que foram fundamentais na elaboração desta pesquisa. Agradeço também o meu orientador Prof. Dr. Ricardo Pires pelo auxílio em todas as etapas deste trabalho.

Divulgação. O autor relata não haver conflitos de interesse neste trabalho.



Referências.

- (1) ROSADO, A.; ROSA, A. C. Automatic detection of epileptiform discharges in the eeg. arXiv preprint arXiv:1605.06708, 2016.
- (2) OLIVEIRA, G. N. M. de et al. Crises não-epilépticas: clínica e terapêutica. J Bras Psiquiatr, SciELO Brasil, v. 57, n. 1, p. 52–56, 2008.
- (3) BAJAJ, V.; PACHORI, R. B. Epileptic seizure detection based on the instantaneous area of analytic intrinsic mode functions of eeg signals. Biomedical Engineering Letters, Springer, v. 3, n. 1, p. 17–21, 2013.
- (4) OROSCO, L. et al. Patient non-specific algorithm for seizures detection in scalp eeg. Computers in biology and medicine, Elsevier, v. 71, p. 128–134, 2016.
- (5) FISHER, R. S. et al. A practical clinical definition of epilepsy. Epilepsia, v. 55, n. 4, p. 475–482, 2014.
- (6) KURCGANT, D.; AYRES, J. R. de C. M. Crise não epiléptica psicogênica: história e crítica de um conceito. História, Ciências, Saúde-Manguinhos, Fundação Oswaldo Cruz, v. 18, n. 3, 2011.
- (7) PIPPA, E. et al. Improving classification of epileptic and non-epileptic eeg events by feature selection. Neurocomputing, Elsevier, v. 171, p. 576–585, 2016.
- (8) BRASIL. Ministério da Saúde. Protocolo Clínico e Diretrizes Terapêuticas da Epilepsia. Portaria No 1.319, de 25 de Novembro de 2013. Brasília, DF, 2013.
- (9) DICKINSON, P.; LOOPER, K. J. Psychogenic nonepileptic seizures: a current overview. Epilepsia, Wiley Online Library, v. 53, n. 10, p.1679–1689, 2012.
- (10) GARCÍA-NIETO, J. et al. Sensitivity and specificity based multiobjective approach for feature selection: Application to cancer diagnosis. Information Processing Letters, Elsevier, v. 109, n. 16, p. 887–896, 2009.
- (11) KIRSCHSTEIN, T.; KÖHLING, R. What is the source of the eeg? Clinical EEG and neuroscience, SAGE Publications Sage CA: Los Angeles, CA, v. 40, n. 3, p. 146–149, 2009.
- (12) SEECK, M. et al. The standardized eeg electrode array of the ifcn. Clinical Neurophysiology, Elsevier, v. 128, n. 10, p. 2070–2077, 2017.
- (13) CORTES, C.; VAPNIK, V. Support-vector networks. Machine learning, Springer, v. 20, n. 3, p. 273–297, 1995.
- (14) HAYKIN, S. Neural Networks: A Comprehensive Foundation. 2nd. ed. Upper Saddle River, NJ, USA: Prentice Hall PTR, 1998.
- (15) KOWALCZYK, A. Support Vector Machine Succinctly. 1. ed. Morrisville: Syncfusion, 2017.



(16) LCA-IFSP. Laboratório de Controle Aplicado. Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - campus São Paulo. 2018. Disponível em: <<https://spo.ifsp.edu.br/lca>>. Acesso em: jun. 2018.

(17) IPQ-HCFMUSP. Unidade de Videoeletroencefalografia. 2018. Disponível em: <http://www.ipqhc.org.br/pag_detalhe.php?categ=Hospital%20&id=321>. Acesso em: jun. 2018.

(18) EUROPEAN DATA FORMAT. European Data Format. 2017. Disponível em: <<https://www.edfplus.info/>>. Acesso em: 17 set. 2017.

(19) PARREIRA, F. J. Detecção de crises epiléticas a partir de sinais eletroencefalográficos. Tese (Doutorado) — Universidade Federal de Uberlândia, 2006.

(20) MATLAB. Versão 7.10.0.499 (R2010a). Natick, Massachusetts: The MathWorks Inc., 2010.