





ARTÍCULO ORIGINAL

Estrategia para la toma de decisiones en el reconocimiento automático de estados de sedación anestésica

Decision-making strategy for automatic recognition of sedation states

Estratégia de tomada de decisão para reconhecimento automático de estados de sedação

Tahimy González-Rubio^{I*} , Yissel Rodríguez-Aldana^{II} , Enrique J. Marañón-Reyes^{II} , Arquímedes Montoya-Pedron^{III} 

^I Universidad de Oriente. Facultad de Ingeniería en Telecomunicaciones, Informática y Biomédica. Santiago de Cuba, Cuba.

^{II} Universidad de Oriente. Centro de Estudios de Neurociencias, Procesamiento de Imágenes y Señales. Santiago de Cuba, Cuba.

^{III} Hospital General Docente "Dr. Juan Bruno Zayas Alfonso". Santiago de Cuba, Cuba.

*Autora para la correspondencia: ylebeque@uo.edu.cu

Recibido: 14 de enero de 2022
Aprobado: 8 de marzo de 2022

RESUMEN

Introducción: la Anestesiología es la especialidad médica dedicada a la atención específica de los pacientes durante procedimientos quirúrgicos y en cuidados intensivos. Esta especialidad basada en los avances científicos y tecnológicos, ha incorporado el uso del monitoreo electroencefalográfico, facilitando el control continuo de estados de sedación anestésica durante las cirugías, con una adecuada concentración de fármacos. **Objetivo:** proponer una estrategia de clasificación para el reconocimiento automático de tres estados de sedación anestésica en señales electroencefalográficas. **Método:** se utilizaron con consentimiento informado escrito los registros electroencefalográficos de 27 pacientes sometidos a cirugía abdominal, excluyendo aquellos con antecedentes de epilepsia, enfermedades cerebrovasculares y otras afecciones neurológicas. Se aplicaron en total 12 fármacos anestésicos y dos relajantes musculares con montaje de 19 electrodos según el Sistema Internacional 10-20. Se eliminaron

artefactos en los registros y se aplicaron técnicas de Inteligencia artificial para realizar el reconocimiento automático de los estados de sedación. **Resultados:** se propuso una estrategia basada en el uso de máquinas de soporte vectorial con algoritmo multiclase Uno-Contra-Resto y la métrica Similitud Coseno, para realizar el reconocimiento automático de tres estados de sedación: profundo, moderado y ligero, en señales registradas por el canal frontal F4 y los occipitales O1 y O2. Se realizó una comparación de la propuesta con otros métodos de clasificación. **Conclusiones:** se computa una exactitud balanceada del 92,67 % en el reconocimiento de los tres estados de sedación en las señales registradas por el canal electroencefalográfico F4, lo cual favorece el desarrollo de la monitorización anestésica.

Palabras clave: señales electroencefalográficas; estados de sedación anestésica; reconocimiento automático; máquinas de soporte vectorial



ABSTRACT

Introduction: Anesthesiology is the medical specialty concerned with the specific care of patients during surgical and intensive care procedures. This specialty, based on scientific and technological advances, has incorporated the use of electroencephalographic monitoring, facilitating the continuous control in the use of anesthesia for patient's sedation states during surgeries, with an adequate concentration of drugs. **Objective:** proposal for a classification strategy for automatic recognition of three sedation states in electroencephalographic signals. **Methods:** we used, with written informed consent, the electroencephalographic records of 27 patients undergoing abdominal surgery, excluding those with a history of epilepsy, cerebrovascular disease and other neurological conditions. A total of 12 drugs to produce anesthesia and two muscle relaxants with 19 electrodes, mounted according to the International System 10 -20, were applied. Artifacts in the records were eliminated and artificial intelligence techniques were applied to perform automatic recognition of sedation states. **Results:** a strategy based on the use of support vector machines with a multiclass algorithm One-against-Rest and the Cosine Similarity metric was proposed to perform the automatic recognition of three sedation states: deep, moderate and light, in signals recorded by the frontal channel F4 and the occipital channels O1 and O2. A comparison was carried out between the proposal showed and other classification methods. **Conclusions:** a balanced accuracy of 92.67% is computed about the recognition of the three states of sedation in the signals recorded by the electroencephalographic channel F4, which helps in a better anesthetic monitoring process.

Keywords: electroencephalographic signals; anesthetic sedation states; automatic recognition; support vector machines

RESUMO

Introdução: a Anestesiologia é a especialidade médica dedicada ao atendimento específico de pacientes durante procedimentos cirúrgicos e em terapia intensiva. Essa especialidade, baseada nos avanços científicos e tecnológicos, incorporou o uso da monitorização eletroencefalográfica, facilitando o controle contínuo dos estados de sedação anestésica durante as cirurgias, com concentração adequada de fármacos. **Objetivo:** propor uma estratégia de classificação para o reconhecimento automático de três estados de sedação anestésica em sinais eletroencefalográficos. **Método:** foram utilizados registros eletroencefalográficos de 27 pacientes submetidos à cirurgia abdominal com consentimento informado por escrito, excluindo aqueles com histórico de epilepsia, doenças cerebrovasculares e outras condições neurológicas. Um total de 12 drogas anestésicas e dois relaxantes musculares foram aplicados com um conjunto de 19 eletrodos de acordo com o Sistema Internacional 10-20. Artefatos nos prontuários foram removidos e técnicas de inteligência artificial foram aplicadas para realizar o reconhecimento automático dos estados de sedação. **Resultados:** foi proposta uma estratégia baseada no uso de máquinas de vetores de suporte com algoritmo One-Against-Rest multiclasse e a métrica Cosine Similarity para realizar o reconhecimento automático de três estados de sedação: profundo, moderado e leve, em sinais registrados pelo canal frontal F4 e os canais occipitais O1 e O2. Foi feita uma comparação da proposta com outros métodos de classificação. **Conclusões:** uma acurácia equilibrada de 92,67% é computada no reconhecimento dos três estados de sedação nos sinais registrados pelo canal eletroencefalográfico F4, o que favorece o desenvolvimento da monitorização anestésica.

Palavras-chave: sinais eletroencefalográficos; estados de sedação anestésica; reconhecimento automático; máquinas de vetor de suporte

Cómo citar este artículo:

González-Rubio T, Rodríguez-Aldana Y, Marañón-Reyes EJ, Montoya-Pedron A. Evaluación *in vivo* de la pirogenicidad de bioproductos fúngicos con potencial prebiótico. Rev Inf Cient [Internet]. 2022 [citado día mes año]; 101(3):e3766. Disponible en: <http://www.revinfcientifica.sld.cu/index.php/ric/article/view/3766>



INTRODUCCIÓN

En la práctica médica actual, la detección de estados de consciencia durante procedimientos quirúrgicos o en la inducción del coma barbitúrico, resulta de interés a fin de garantizar al paciente las mejores condiciones fisiológicas posibles, antes, durante y después de la administración de fármacos hipnóticos y otros como los relajantes musculares, con el propósito de inducir estados de inconsciencia, amnesia, analgesia y relajación muscular. En la actualidad, para distinguir el estado consciente del inconsciente se han estudiado varias observaciones clínicas y parámetros electrofisiológicos como la presión sanguínea, la frecuencia de respiración, así como estímulos motores y respuestas a comandos verbales, pero estos signos resultan ser inespecíficos debido a que durante la cirugía la evaluación clínica del paciente depende de su estado de salud, las reacciones que el mismo presente a los fármacos anestésicos y de la experiencia del especialista.⁽¹⁾

Esta situación se hace más compleja por la variación que existe entre los parámetros fisiológicos, que llega a ser extrema en pacientes de alto riesgo, por lo que dicho proceso incluye cierta incertidumbre, lo que provoca que el paciente pudiese cambiar de estados de sedación anestésica y los cambios fisiológicos ser imperceptibles al especialista. En consecuencia, debido a la administración insuficiente de los fármacos anestésicos o por un monitoreo poco certero, se reportan casos donde aparece el despertar intraoperatorio, lo que causa diversos efectos psicosomáticos en el paciente. Todo lo anterior justifica que la comunidad científica mundial estudie otras alternativas que optimicen los procedimientos de monitorización en aras de mejorar la calidad de la asistencia en los servicios de Anestesiología, cuidados Intensivos y, por ende, el confort de los pacientes.⁽¹⁾

En este sentido, diversas investigaciones han mostrado resultados relevantes en la utilización de las señales del electroencefalograma (EEG)⁽¹⁾ para identificar el efecto de drogas anestésicas, surgiendo así los monitores de anestesia; estos detectan de tres a cuatro estados de sedación con el uso de varias técnicas de procesamiento aplicadas a las señales electroencefalográficas para cuantificar el efecto de los fármacos, al utilizar para el registro de las señales de tres a cuatro electrodos o canales electroencefalográficos colocados en la frente del paciente (distribución frontopolar).

Aunque se ha demostrado que esta región cerebral refleja la pérdida y recuperación de la consciencia durante la sedación anestésica, también se ha evidenciado que las señales registradas por estos electrodos son vulnerables a la aparición de artefactos y ruidos que modifican el trazado de la señal (aun cuando los equipos de registro cuentan con hardware para el filtrado y adecuación de la misma), lo que compromete la exactitud del diagnóstico. Si bien es cierto que la utilización de los electrodos en la región cerebral frontopolar no complejiza el proceder quirúrgico, se reporta que las señales registradas por estos monitores de anestesia son afectadas por la excesiva actividad electromiográfica proveniente de la musculatura del cuero cabelludo, la aparición de la onda R de las señales del electrocardiograma que se transmite por el cuello, así como la actividad electrooculográfica generada por el movimiento de dipolos eléctricos en el interior del globo ocular.^(2,3)

Aunque hasta el momento no ha sido sistematizado lo suficiente el efecto topográfico que provocan los cambios de los fármacos anestésicos en los registros del EEG, algunas investigaciones han demostrado que los cambios del espectro de potencia entre todos los electrodos usados son independientes del tipo



de anestésico, pero altamente significativos entre los diferentes estados de anestesia.⁽⁴⁾ Estudios demuestran que la pérdida de la conciencia radica en la reducción de la conectividad entre las regiones cerebrales, occipitales y frontales, reportándose que durante la sedación hipnótica el índice de bicoherencia del espectro entre ellas es diferente, con un incremento en la actividad de la banda de frecuencia beta en la zona frontal que se extiende a la occipital con el aumento de la sedación. También se reporta el traslado de las bandas *delta* y *alpha* hacia la zona frontal.⁽⁵⁻¹¹⁾

Con el empleo de estos criterios como punto de partida y en aras de caracterizar los registros de otros electrodos no usados en los monitores que se comercializan, en la investigación se utilizaron las señales registradas por el electrodo frontal F4 y los occipitales O1 y O2, localizaciones que resultan sensibles a la influencia de agentes anestésicos, fundamentalmente en el proceso de inducción y en los cambios bruscos de estados de sedación y, que por su ubicación en el área cerebral, no afectan el proceder quirúrgico.

La presente investigación se centró en la búsqueda de marcadores en el EEG de estados de sedación durante el monitoreo intraoperatorio, a fin de caracterizar la pertinencia de los electrodos antes mencionados en la pérdida y recuperación de la conciencia. Para ello se presenta una propuesta usando técnicas de inteligencia artificial para identificar tres estados de sedación, a partir de la combinación de nueve parámetros extraídos del dominio frecuencial de las señales electroencefalográficas.

MÉTODO

En la investigación se utilizaron el consentimiento informado escrito, los registros electroencefalográficos de 27 pacientes sometidos a cirugía abdominal de tipo video endoscópica en la unidad quirúrgica del Hospital General Docente "Juan Bruno Zayas Alfonso" de la provincia Santiago de Cuba.

Del estudio se excluyeron a pacientes con antecedentes de epilepsia, enfermedades cerebrovasculares y otras afecciones neurológicas.

En la muestra de estudio se utilizaron en total 12 fármacos anestésicos: isoflurane, óxido nitroso, midazolam, fentanil, fenotavil, propofol, halotane, diprivan, pentanol, nalozol, vecurorio, beraminia, y dos relajantes musculares: succinil colina o atracurio.

El registro de las señales se realizó con el equipo Medicid PHOENIX y un montaje de 19 electrodos según el Sistema Internacional 10-20.

Se definieron (a partir de la escala clínica de 8 niveles de anestesia utilizados por los anestesiólogos) 3 estados de sedación: Ligero, que representa los estados de menor sedación con respuesta a comandos verbales y sedación con movimientos luego de estímulos de dolor leves; Moderado, para los estados hipnóticos moderado y; Profundo, representativo del estado hipnótico muy profundo.



En las señales registradas se detectaron artefactos producidos por movimientos oculares que provocan la detección de trascendentes no estacionarias similares a eventos epileptiformes⁽¹²⁾, artefactos resultantes del complejo QRS, onda del electrocardiograma que puede aparecer en el EEG como picos agudos con frecuencia intermitente y que se transmite por el cuello⁽¹²⁾, artefactos de gradiente (diferencia absoluta entre dos muestras vecinas) y varianza (valor de la misma en cada ventana de la señal).

La eliminación de los artefactos fisiológicos se realizó mediante la reconstrucción parcial de la señal, a partir de un procedimiento de corrección de artefactos basado en la descomposición en modos empíricos del EEG.⁽¹²⁾ Se eliminaron los artefactos no fisiológicos, al comparar las ventanas de las señales (256 muestras, 1,28 segundos) con umbrales previamente establecidos.

A continuación, se calcularon 9 parámetros derivados del espectro de potencia que definen las cuatro bandas de frecuencias (*alpha*, *beta*, *theta* y *delta*) presentes en la señal del EEG: poder absoluto en *delta* y *theta*; frecuencia media en las bandas *theta* y *alfa*; frecuencia media total, poder relativo en *theta* y *beta*, *theta-beta2* y *beta* ratio. De un total de 27 registros, 17 se usaron en el entrenamiento de la máquina de aprendizaje y 10 en la validación de la misma.

La técnica de inteligencia artificial usada para efectuar el reconocimiento automático de los estados de sedación fueron las máquinas de soporte vectorial (SVM: *Support Vector Machine*), estas son clasificadores que aprenden la frontera de decisión de 2 clases, a partir de la descripción dada por unos puntos conocidos como vectores de soporte (puntos que se encuentran en el margen de decisión). Dado un conjunto de entrenamiento de tamaño N compuesto de pares patrón-target (x_i, y_i) , se desea obtener una ecuación para un hiperplano que divida los datos de entrenamiento de manera que los puntos con igual *target* queden al mismo lado del hiperplano. Entre todos los posibles hiperplanos, aquel cuya distancia al punto más cercano es máxima, se denomina hiperplano óptimo de separación.⁽¹³⁾

La estrategia multiclase usada en esta investigación fue el algoritmo Uno-Contra-Resto (OAR: *One-Against-Rest*), en el cual se implementaron y entrenaron tantas SVM como clases (Q) tuvo el problema. Luego del aprendizaje de la máquina, los patrones de prueba fueron clasificados en todas las SVM entrenadas y se les asignó la clase en la que se obtuvo el resultado positivo al evaluar la ecuación del hiperplano. El algoritmo multiclase Uno-Contra-Uno no se tuvo en cuenta debido a que, con él, la cantidad de SVM a implementar y validar aumenta de manera exponencial cuando Q es mayor o igual que cuatro.

Sin embargo, con el algoritmo OAR se presentan los siguientes conflictos de clasificación en la toma de decisiones: un patrón puede ser clasificado en más de una clase positiva o para todas las SVM implementadas el patrón puede ser reconocido en la clase negativa. Para corregir este problema y teniendo en cuenta que, en el reconocimiento de patrones, el análisis de la distancia entre dos vectores es una medida de similitud (mientras más pequeña sea la distancia, mayor será su parecido), se evaluó la similitud entre el patrón a clasificar y los centroides de un subconjunto de los vectores de soporte de las clases implicadas en el conflicto de clasificación, aplicando como medida de semejanza entre dos vectores a la métrica Similitud Coseno. Estos subconjuntos se eligieron de igual tamaño y se



usaron los vectores de soporte debido a que ellos definen la frontera de decisión y el hiperplano óptimo de separación.

La clasificación final consistió en otorgar al patrón la clase del centroide con el que se obtuvo el menor valor positivo diferente de 0 al evaluar la métrica antes mencionada. La Figura 1 muestra en un diagrama la metodología que se propone para el reconocimiento de los 3 estados de sedación en las señales electroencefalográficas.

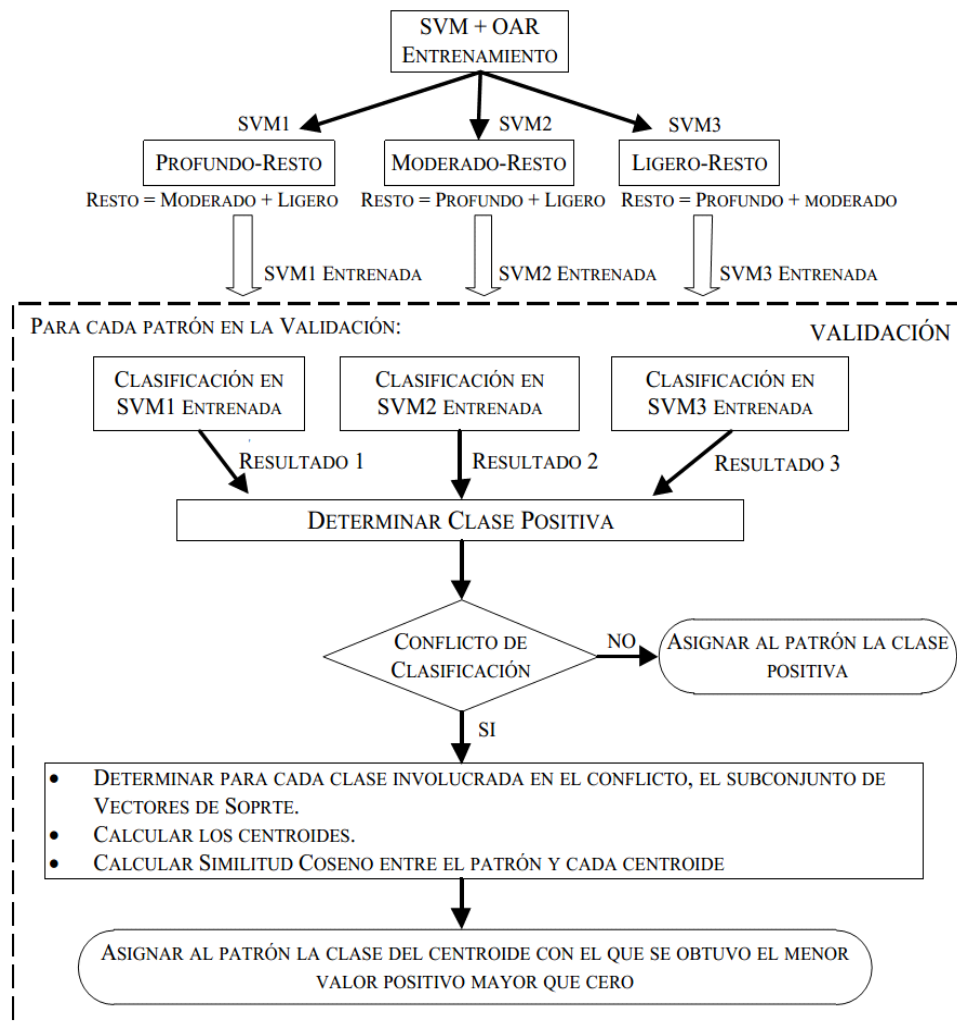


Fig. 1. Metodología para el reconocimiento automático de los estados de sedación: profundo, moderado y ligero en las señales electroencefalográficas.

El entrenamiento de las SVM se realizó con el uso de 5 funciones kernel y los métodos de optimización: mínimos cuadrados, optimización mínima secuencial y programación cuadrática. Los resultados que se presentan se obtuvieron con el *Kernel Multilayer Perceptron* y el método de optimización basado en mínimos cuadrados. El tiempo promedio del entrenamiento de las SVM fue de 2,08 segundos.

El rendimiento de los experimentos se evaluó a partir de las métricas: sensibilidad (TPR: *True Positive Rate*), especificidad (Sp), Precisión o valor predictivo positivo (PPV: *Positive Predictive Value*), razón de falsos positivos (FPR: *False Positive Rate*), razón de falsos negativos (FNR: *False Negative Rate*) y exactitud balanceada. Los primeros experimentos se realizaron con la derivación F4.

RESULTADOS

Es conveniente señalar que el 68,06 % de precisión obtenido para el estado de sedación ligero, estuvo condicionado a la diferencia en la cantidad de patrones de las clases en la matriz de confusión asociada (Tabla 1), vea cómo los falsos positivos detectados en el reconocimiento representaron solo el 2,51 % de las muestras. En el estado moderado, la sensibilidad resultó en un 93,25 %, para un 6,75 % de falsos negativos; los falsos positivos solo representaron un 6,04 % en este estado para una especificidad del 93,96 %. En la sedación profunda se alcanzó una sensibilidad de 90,77 % y se computó la especificidad en un 97,49 %, para una razón de falsos positivos y falsos negativos de 2,51 % y 8,46 %, respectivamente.

Tabla 1. Detección de tres estados de sedación en el canal electroencefalográfico F4 aplicando SVM con algoritmo OAR y Similitud Coseno

Estados de sedación	TPR (%)	Sp (%)	PPV (%)	FPR (%)	FNR (%)	$\hat{\lambda}$ (%)
Profundo	90,77	97,49	84,89	2,51	8,46	
Moderado	93,25	93,96	98,52	6,04	6,75	92,67
Ligero	94,23	97,49	68,06	2,51	5,77	

Como se observa en la Tabla 2, se realizó una comparación entre la propuesta para la toma de decisiones con SVM y otras técnicas de inteligencia, artificial tales como:

- máquina de soporte libSVM (usando el toolbox de Matlab PRTool).
- red neuronal artificial (RNA) del tipo Feedforward con algoritmo de entrenamiento *Backpropagation Broyden-Fletcher-Goldfarb-Shanno* (BFGS) quasi-Newton method, la red estuvo compuesta por una capa de entrada con 9 neuronas (cantidad de parámetros del QEEG), 1 capa de salida con 3 neuronas (una para cada estado de sedación) y 2 capas ocultas. Se usaron las funciones de transferencia: tangente sigmoideal hiperbólica (en la capa de entrada y las capas ocultas) y sigmoideal logarítmica (en la capa de salida).
- sistema de inferencia difuso basado en Redes adaptivas (ANFIS: *Adaptive Networks Based Fuzzy Inference Systems*) con 6 funciones de membresía, alcanzando los mejores resultados (en todos los casos) con la función del tipo diferencia sigmoideal.

Todos estos experimentos se realizaron con la misma muestra de estudio.



Tabla 2. Comparación del método propuesto con otros algoritmos de clasificación usando el canal electroencefalográfico F4

Técnica de <i>Machine Learning</i>	Estados de sedación	TPR (%)	Sp (%)	$\hat{\lambda}$ (%)
SVM con OAR y Similitud Coseno (F4)	Profundo	90,77	97,49	92,67
	Moderado	93,25	93,96	
	Ligero	94,23	97,49	
libSVM	Profundo	76,13	99,43	86,67
	Moderado	99,22	77,66	
	Ligero	84,85	99,80	
RNA	Profundo	90,00	99,88	63,33
	Moderado	99,88	62,66	
	Ligero	-	100,00	
ANFIS	Profundo	80,00	98,93	63,19
	Moderado	99,16	60,00	
	Ligero	10,42	99,89	

Los métodos antes descritos se usaron con los registros de los canales electroencefalográficos occipitales O1 y O2. A continuación se muestran los resultados obtenidos (Tabla 3).

Tabla 3. Comparación del método propuesto con otros algoritmos de clasificación usando el canal electroencefalográfico O1

Técnica de <i>Machine Learning</i>	Estados de sedación	TPR (%)	Sp (%)	$\hat{\lambda}$ (%)
SVM con OAR y Similitud Coseno (O1)	Profundo	81,30	71,62	80,5
	Moderado	83,27	82,57	
	Ligero	76,80	83,70	
libSVM	Profundo	73,20	43,16	47,13
	Moderado	48,54	84,10	
	Ligero	21,50	12,87	
RNA	Profundo	45,63	34,26	27,46
	Moderado	36,81	79,18	
	Ligero	0,23	13,48	
ANFIS	Profundo	73,89	63,72	78,31
	Moderado	85,43	78,10	
	Ligero	75,31	73,00	

La Tabla 4 muestra los resultados obtenidos en la clasificación con los registros del canal O2, para los cuales una vez más los mejores porcentajes se alcanzaron con la propuesta de SVM realizada.

Tabla 4. Comparación del método propuesto con otros algoritmos de clasificación usando el canal electroencefalográfico O2

Técnica de <i>Machine Learning</i>	Estados de sedación	TPR (%)	Sp (%)	$\hat{\lambda}$ (%)
SVM con OAR y Similitud Coseno (O2)	Profundo	87,58	79,93	84,1
	Moderado	85,10	85,70	
	Ligero	79,62	83,70	
libSVM	Profundo	65,60	69,27	58,63
	Moderado	67,14	53,60	
	Ligero	43,10	49,40	
RNA	Profundo	39,46	41,60	39,5
	Moderado	53,96	50,62	
	Ligero	25,20	16,70	
ANFIS	Profundo	75,32	52,70	73,9
	Moderado	81,80	65,43	
	Ligero	64,57	54,80	

La Figura 2 muestra la estimación de estados de sedación anestésica de dos pacientes usando SVM con algoritmo OAR y Similitud Coseno.




Fig. 2. Estimación de estados de sedación anestésica de dos pacientes usando SVM con algoritmo OAR y Similitud Coseno. (a) Paciente 1, (b) Paciente 2.

DISCUSIÓN

Los resultados obtenidos en la detección de los 3 estados de sedación a partir de las señales registradas por el canal electroencefalográfico F4, aplicando SVM con algoritmo OAR y Similitud Coseno, evidenciaron la efectividad del método de clasificación a partir del análisis de una muestra de estudio relativamente extensa, compleja y variada.

La exactitud balanceada calculada demostró la pertinencia de los 9 parámetros espectrales usados para caracterizar los estados de sedación en las señales electroencefalográficas sujetas a estudio. Se comprobó que la señal registrada por este canal fue resistente a la interferencia de artefactos y, además, representativo del comportamiento de fármacos anestésicos en la actividad cerebral, por lo

que pudo servir para monitorear diferentes estados de sedación, independientemente del tipo de fármaco que se utilizó, lo cual podría constituir un aporte relevante si se tiene en cuenta que los monitores de profundidad anestésica que existen en la actualidad, utilizan para el análisis del estado hipnótico de 3 a 4 canales electroencefalográficos solo de localización frontopolar.

Los registros del canal F4 se usaron con otros algoritmos de clasificación para establecer criterios de comparación con la estrategia de reconocimiento que se propone. En estos experimentos, ANFIS no resultó ser lo suficientemente efectiva con la muestra de estudio utilizada, alcanzando una exactitud balanceada de 63,19 %. Aunque con esta técnica de *Machine Learning* la detección del estado profundo fue adecuada (a partir del análisis de sensibilidad y especificidad), no sucedió de igual manera con la sedación moderada y ligera.

En los resultados obtenidos con libSVM, el reconocimiento del estado de sedación ligero fue adecuado con un TPR y Sp igual a 84,85 % y 99,8 %, respectivamente; sin embargo, la detección de los verdaderos positivos en la sedación profunda y de verdaderos negativos en moderado no alcanzó el 78 %, por consiguiente, aunque la exactitud fue de 86,67 %, los resultados obtenidos con libSVM no se consideraron correctos.

La detección de verdaderos negativos en el análisis del estado de sedación moderado usando RNA no fue correcta, computando una especificidad de 62,66 %. En la sedación ligera, ningún patrón se reconoció correctamente, todos fueron detectados de manera errónea en el estado moderado. Estos experimentos permitieron poner en evidencia la validez de la estrategia de reconocimiento que se propone en la detección de estados de sedación en los pacientes durante intervenciones quirúrgicas.

De los resultados obtenidos con todas las técnicas *Machine Learning* aplicadas a los registros del canal electroencefalográfico O1, el mejor desempeño se obtuvo con la propuesta que se realizó en esta investigación. El peor desempeño en cuanto a especificidad se obtuvo con el estado de sedación profundo con un 71,62 %, y en la sensibilidad, el estado ligero con solo un 76,8 % de verdaderos positivos reconocidos de manera correcta. Se debe señalar que la exactitud balanceada con un 80,5 % no superó a la obtenida con el canal F4, sin embargo, este dato no se consideró despreciable y sugiere un estudio más profundo de esta localización en la detección de niveles de anestesia.

Se puede apreciar que los mejores resultados se obtuvieron con los registros del canal O2, el cual coincidentemente se posicionó en el mismo hemisferio que el canal F4; de aquí se puede discernir no solo que el canal O2 podría ser el canal occipital que mejor reflejó los cambios en la sedación anestésica de los pacientes, sino también la necesidad de realizar un estudio topográfico que permita arribar a conclusiones que favorezcan la toma de decisiones respecto a cuál sería la combinación óptima de canales electroencefalográficos a usar, para diagnosticar eficientemente estados de sedación anestésica durante procedimientos quirúrgicos.

El nivel de coincidencia entre ambas escalas: la escala clínica de profundidad anestésica (línea azul) y la escala estimada por la propuesta para la detección automática de estados de sedación (línea roja), obtenidas para dos pacientes seleccionados de manera aleatoria, corroboró la efectividad de la propuesta, así como la pertinencia del canal electroencefalográfico F4 en la detección de estados de sedación.



CONCLUSIONES

Los resultados obtenidos en el reconocimiento de los estados de sedación: profundo, moderado y ligero a partir de la información registrada por los canales electroencefalográficos F4, O1 y O2, sugieren que estas señales son representativas del comportamiento de distintos medicamentos hipnóticos en la actividad cerebral, lo que proporciona importantes beneficios en la detección de estados de conciencia.

Todo lo anterior contribuye al estudio topográfico del EEG aplicado a la monitorización intraoperatoria. La propuesta de clasificación basada en SVM con algoritmo multiclase OAR y la métrica Similitud Coseno, aplicada a la toma de decisión final en la detección de estados de sedación anestésica, resulta ser efectiva alcanzando los mejores resultados con el canal electroencefalográfico F4, el cual no se utiliza en los monitores de profundidad anestésica que actualmente se comercializan. Esto favorece el logro de resultados significativos en la disminución del riesgo de despertar intraoperatorio en los pacientes, lo que permite potenciar la calidad y eficiencia de los servicios médicos que brinda el país.

REFERENCIAS BIBLIOGRÁFICAS

1. Ince R, Adanir SS, Sevmez F. The inventor of electroencephalography (EEG): Hans Berger (1873–1941). Childs Nerv Syst [Internet]. 2021 [citado 11 Ene 2022]; 37. DOI: <https://doi.org/10.1007/s00381-020-04564-z>
2. Gajbhiye P, Tripathy RK, Bhattacharyya A, Pachori RB. Novel Approaches for the Removal of Motion Artifact From EEG Recordings. IEEE Sensors J [Internet]. 2019 [citado 11 Ene 2022]; 19(22):10600-10608. DOI: <http://dx.doi.org/10.1109/JSEN.2019.2931727>
3. Bisht A, Kaur C, Singh P. Recent Advances in Artifact Removal Techniques for EEG Signal Processing. Intelligent Communication, Control and Devices. Adv Intel Sys Comp [Internet]. 2020 [citado 13 Ene 2022]; 989:[aproximadamente 8 p.]. DOI: https://doi.org/10.1007/978-981-13-8618-3_41
4. Afshani F, Shalhaf A, Shalhaf R, et al. Frontal–temporal functional connectivity of EEG signal by standardized permutation mutual information during anesthesia. Cogn Neurodyn [Internet]. 2019 [citado 13 Ene 2022]; 13:531-540. DOI: <https://doi.org/10.1007/s11571-019-09553-w>
5. Vlisides PE, Bel-Bahar T, Nelson A. Subanaesthetic ketamine and altered states of consciousness in humans. Brit J Anaesth [Internet]. 2018 [citado 11 Ene 2022]; 121(1):249-259. DOI: <https://doi.org/10.1016/j.bja.2018.03.011>
6. Moraes SB, Tarnal V, Vanini G, Bel-Behar T, et al. Network Efficiency and Posterior Alpha Patterns Are Markers of Recovery from General Anesthesia: A High-Density Electroencephalography Study in Healthy Volunteers. Fron Comp Neurosc [Internet]. 2017 [citado 13 Ene 2022]; 11(328):8. DOI: <https://doi.org/10.3389/fnhum.2017.00328>
7. Rathee D, Cecotti H, Prasad G. Propofol-induced sedation diminishes the strength of frontal-parietal-occipital EEG network. En: 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society; 2017. Disponible en:



- <https://ieeexplore.ieee.org/abstract/document/8037847>
8. Hambrecht-Wiedbusch VS, Li D, Mashour GA. Administration of Subanesthetic Ketamine during Isoflurane Anesthesia Induces Burst Suppression but Accelerates Recovery. *Anesthesiol* [Internet]. 2017 [citado 5 Dic 2021]; 126(3):482-491. DOI: <https://doi.org/10.1097/aln.0000000000001512>
 9. Kreuzer M. EEG Based Monitoring of General Anesthesia: Taking the Next Steps. *Fron Comp Neurosc* [Internet]. 2017 [citado 5 Dic 2021]; 11(56):7. DOI: <https://doi.org/10.3389/fncom.2017.00056>
 10. Sanders RD, Banks MI, Darracq M, Moran R, *et al.* Propofol-induced unresponsiveness is associated with impaired feedforward connectivity in cortical hierarchy. *Brit J Anaesthesia* [Internet]. 2018 [citado 13 Ene 2022]; 121(5):1084-1096. DOI: <https://doi.org/10.1016/j.bja.2018.07.006>
 11. Soldevilla DL. On the Physiological Modulation and Potential Mechanisms Underlying Parieto-Occipital Alpha Oscillations. *Fron Comp Neurosc* [Internet]. 2018 [citado 11 Ene 2022]; 12(23):19. Disponible en: <https://doi.org/10.3389%2Ffncom.2018.00023>
 12. Rodríguez Y, González T, Marañón E, Montoya A, Sanabria F. Aplicación de corrección de artefactos en el electroencefalograma para monitoreo anestésico. *Rev Cubana Neurol Neurocir* [Internet]. 2015 [citado 11 Ene 2022]; 5(1):S9-S14. Disponible en: <http://revneuro.sld.cu/index.php/neu/articloe/view/179>
 13. Kubat M. *An Introduction to Machine Learning*. 1ed. 2015; 291.

Declaración de conflicto de intereses:

Los autores de la investigación no presentan conflicto de intereses.

Contribución de los autores:

TGR: conceptualización, implementación, validación y evaluación de la propuesta para el reconocimiento automático de los estados de sedación anestésica.

YRA: procesamiento de las señales, detección y eliminación de artefactos.

EJMR: análisis e interpretación de los datos, redacción, revisión y edición.

AMP: adquisición, análisis e interpretación de los datos.

Financiación:

Los autores no recibieron financiación para el desarrollo de la presente investigación.

