

IDENTIFICACIÓN DE NIÑOS CON TRASTORNO DE LENGUAJE USANDO EL ANÁLISIS CUANTITATIVO DE EEG

*IDENTIFICATION OF CHILDREN WITH LANGUAGE DISORDER
USING QUANTITATIVE EEG ANALYSIS*

Rebeca Abigail Álvarez Vázquez

Universidad Autónoma Metropolitana, México
rebealvarez8113@gmail.com

Javier Alducin Castillo

Universidad Autónoma Metropolitana, México
jac@azc.uam.mx

Marlene Galicia Alvarado

Instituto Nacional de Rehabilitación, México
magalicia@inr.gob.mx

Recepción: 29/noviembre/2022

Aceptación: 13/marzo/2023

Resumen

En este trabajo se diseñó un clasificador de Máquina de Soporte Vectorial (SVM) para identificar niños con Trastorno de Lenguaje (TDL) y niños sanos (control), a partir de un análisis cuantitativo de las características de la potencia espectral, en las bandas de frecuencia del electroencefalograma (EEG) de cada niño. Se implementaron distintos métodos de selección de atributos: Chi-Square, LDA, regresión lineal univariante y RFE. Posteriormente, se realizó una evaluación del desempeño de la SVM, usando: validación cruzada, matriz de confusión y la ROC. Para el análisis hecho por cada electrodo, los parámetros de evaluación arrojaron una tasa de clasificación arriba del 60%, mostrando mayor efectividad en los electrodos F8 y T4. Para el análisis hecho en cada banda de frecuencia se logró un mejor resultado, mostrando un porcentaje arriba del 70% en la banda de frecuencia beta.

Palabras Clave: Electroencefalograma, densidad de potencia espectral, máquina de soporte vectorial, TDL.

Abstract

In this work, a Support Vector Machine classifier was designed to try to identify children with Language Disorder (TDL) and healthy children (control), based on a quantitative analysis of the spectral power characteristics in the EEG frequency bands of each child. Two different databases were implemented, through a selection of attributes with four different methods: Chi-Square, LDA, Univariate Linear Regression and RFE. Subsequently, an evaluation of the performance of the SVM was carried out using the following methods: cross-validation, confusion matrix and ROC. For the analysis made by each electrode the evaluation parameters showed a classification rate above 60%, showing greater effectiveness in electrodes F8 and T4. For the analysis done in each frequency band, a better result was achieved in general, showing an accuracy above 70% in the beta frequency band.

Keywords: *Electroencephalogram, power spectral density, support vector machine (SVM), TDL.*

1. Introducción

En la actualidad, se espera que un niño mantenga un desarrollo favorable en las características del habla y el lenguaje. Por esta razón, muchos padres de familia ignoran conductas específicas del niño, que podrían dar indicios de algún problema para expresarse por medio del lenguaje. El Trastorno de Lenguaje (TDL) es un trastorno de comunicación que interfiere en el desarrollo de las habilidades del lenguaje en niños. Si no se detecta a tiempo, puede afectar durante la etapa de desarrollo del niño y en la edad adulta.

Un niño con TDL suele tener problemas con la lectura, la escritura, el cálculo matemático, problemas de atención, cierto grado de hiperactividad, problemas para la comunicación social y comportamientos negativos. Tiene un mayor riesgo de padecer problemas emocionales en la adolescencia y grandes dificultades para las relaciones sociales, por lo que se convierte en un objetivo fácil del acoso [Maldonado, 2011] y es importante localizar a tiempo dicho trastorno. Sin embargo, el TDL no es un retraso simple del lenguaje al que haya que dar tiempo, no es un problema de pronunciación, ni una cuestión de inmadurez o de educación; el TDL

es un trastorno grave, que, si no es diagnosticado a tiempo acompañará a la población infantil afectada a lo largo de la trayectoria de su vida [Vilameá, 2014].

A través de los años, se han explorado diversos enfoques para tratar de identificar el TDL en la población infantil, en conjunto con pruebas neuropsicológicas, con el objetivo de intervenir sobre el trastorno oportunamente, dando la atención adecuada. En ocasiones, las pruebas psicológicas no son suficientes para detectar a un niño con TDL. Por ello, existe un gran interés en la identificación de diferencias que ayuden y, complementen la información de dichas pruebas, para diagnosticar y ejecutar intervenciones adecuadas de acuerdo con las necesidades del niño.

Diversos trabajos han intentado realizar la detección y clasificación de niños con problemas de lenguaje a través del análisis de vocablos o voz. En [Sharma, 2020a], [Sharma, 2020b], se utiliza el vocablo "a" para la detección y clasificación de niños TEL. Se estudió mediante coeficientes de Codificación Predictiva Lineal (LPC). El análisis se basó en dos clasificadores: naïve-Bayes (NB) y Máquina de Soporte Vectorial (SVM). Ambos protocolos fueron más altos cuando se utilizó el clasificador naïve-Bayes, con una precisión de 97.9 y 97.8%, para 20 y 10 características, respectivamente. En [Sharma, 2020b], se diseñó un clasificador k-NN, con un enfoque de análisis de componentes de vecindad (NCA).

En [Reddy, 2020], se emplearon las muestras de voz de niños con TEL y niños sanos enfocándose en las características glotales y acústicas extraídas de la señal del habla. Se analizaron dos algoritmos de aprendizaje automático: la SVM y la red neuronal de avance (FFNN). Se concluyó que el clasificador FFNN proporcionó un mayor rendimiento con las características glotales en conjunto con las características MFCC. En [Kotarba, 2020], se ejecutó el entrenamiento, validación y prueba de los espectros de potencia logarítmica (LPS) para el preprocesamiento de datos. Se entrenó una red neuronal profunda basado en la arquitectura ResNet. Se obtuvo una tasa de precisión del 99.48%, por lo que logró un enfoque eficiente para la detección automática de trastornos específicos del lenguaje. Otro trabajo es [Sharma, 2020c], donde se realizó un análisis de la textura de las emisiones del habla, para analizar el trastorno específico del lenguaje mediante un sistema de aprendizaje automático que filtra el habla. En este caso, se utilizó como herramienta

la característica de Haralick (14 características) y los patrones binarios locales (LBP) (59 características) para extraer las características espectro-temporales para la clasificación de los niños. Se entrenó un modelo SVM con kernel cuadrático. En los resultados, la característica de textura de Haralick mostró una precisión del 97,41% y alrededor del 98% cuando se relacionó con las características de LBP.

Otro enfoque ha sido el análisis cuantitativo del EEG. En [Lubar, 1985], se analizó la potencia espectral del EEG de 69 niños con discapacidades específicas de aprendizaje (LD) y 34 niños control, que se encontraban realizando tareas de lectura, aritmética y espaciales en sus escuelas. Se dividieron las actividades en siete niveles de dificultad, con el objetivo de encontrar una metodología para detectar a niños con LD. Se identificó la mayor potencia espectral en cada banda de frecuencia (Δ , θ , α , β) mediante cuatro hipótesis. Las bandas theta, theta-baja y alpha resultaron distinguir a los niños control de los niños con LD. Se concluyó que el análisis discriminante indica diferencias entre los dos grupos de niños, lo que podría ser útil en un futuro para la identificación de trastornos de comunicación.

En [Justice, 2019], se realizó un estudio en niños de preescolar con edades de entre 3 a 5 años, para identificar un conjunto de variables que permitieran clasificar a niños diagnosticados con trastorno específico de lenguaje (TEL) de niños control. Mediante el empleo de Machine-Learning con el método LASSO, se desarrollaron cuatro modelos para encontrar la mayor precisión en la clasificación.

En el modelo 1, se concentraron las siete variables más importantes: deterioro cognitivo, género, edad, habilidades pragmáticas, habilidades sociales y de alfabetización. Estas variables no confirman un modelo de predicción unidireccional, pero son posibles contribuyentes en la precisión para la clasificación de niños TEL.

Electroencefalografía

La electroencefalografía es un sistema de registro de datos electrofisiológicos no invasivo y eficaz. Con una implementación sencilla y relativamente económico, para el estudio de cambios en el desarrollo de las relaciones cerebro-conducta [Bell, 2012], [Alducin, 2016]. El EEG se registra colocando electrodos, que se sitúan en el cuero cabelludo, para capturar las oscilaciones de la actividad eléctrica a lo largo

del tiempo [Smith, 2008]. Las oscilaciones se agrupan en bandas de frecuencia, estas se diferencian unas de otras y reflejan diferentes procesos cognitivos [Alducin, 2021]. Aunque existen otras técnicas de adquisición de datos del cerebro, el EEG sigue siendo una opción de bajo costo, no invasivo, repetible y sin contraindicaciones médicas [Brailowsky, 1999], aunque adolece de resolución espacial.

El análisis cuantitativo del EEG, generalmente, se emplea para el análisis de la actividad eléctrica del cerebro. Esta actividad se estudia en el dominio de la frecuencia, donde se obtiene la Densidad Espectral de Potencia (PDS). Esta densidad, ayuda a conocer la distribución de la potencia de los componentes de frecuencia de la señal. Si se obtiene el área bajo la curva (de la densidad), en un intervalo de frecuencia específico, el valor obtenido se conoce como potencia absoluta (PA). Estas dos medidas, en la frecuencia, brindan información relevante de las diferentes oscilaciones que componen las señales complejas del EEG.

Clasificador

Un clasificador es un algoritmo que busca separar datos en clases. Tiene la finalidad de asociar cada atributo a su clase perteneciente, a partir de información característica que se tiene sobre ellos. Esta característica puede enseñarse al clasificador, esto se conoce como *aprendizaje supervisado* ya que *aprende* mediante ejemplos, por lo que es necesario entrenar al clasificador con base en ejemplos. Una SVM es un algoritmo de aprendizaje supervisado. Este modelo tiene la capacidad de representar a los puntos de muestra en el espacio, definido formalmente por un hiperplano óptimo que separa todas las clases, actúa como un clasificador discriminativo. Su funcionamiento básico se observa en la figura 1.

Selección de atributos

La selección de atributos es una técnica que se utiliza para la reducción de datos en el proceso de minería de datos; se puede asociar a un algoritmo que se encarga de tomar los parámetros más relevantes y de esa forma, ser utilizados como elementos representativos de cada clase [Sarmiento, 2019].

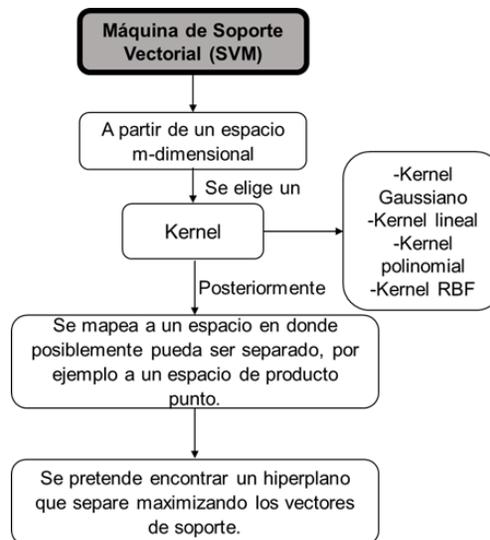


Figura 1 Esquema de las etapas de una Máquina de Soporte Vectorial (SVM).

Antes de construir cualquier tipo de clasificador, conviene suprimir datos innecesarios y redundantes que, posiblemente, no aportarán información relevante o pueden sobreentrenar al clasificador, y así mejorar su rendimiento. Existen diversos algoritmos de selección de atributos, entre los cuales se destacan:

- χ^2 (Chi-Square) se centra en una relación entre atributo y variable dependiente. Se encarga de aplicar una evaluación para cada atributo, haciendo uso de una unidad de medida para la información y así calcular el valor estadístico Chi-square dependiendo de la clase.
- El análisis discriminante lineal (LDA), es un algoritmo que busca la proyección de los datos maximizando la separación entre clases, es decir, detecta una combinación lineal de las variables originales que permita la mejor separación entre grupos de un conjunto de datos.
- Regresión lineal univariante, trata de explicar la relación que existe entre una variable dependiente y un conjunto de variables independientes, por lo tanto, su manera de funcionar es describir los datos para posteriormente encontrar los patrones que existen en ellos.
- La eliminación de características recursivas (RFE), optimiza los datos buscando un subconjunto de funciones con mejor rendimiento. Este método, crea repetidamente modelos y deja de lado la mejor o la peor característica

de rendimiento en cada iteración. Es decir, en cada etapa de la búsqueda, los predictores menos importantes se eliminan iterativamente antes de reconstruir el modelo.

Al utilizar un sistema de clasificación, es necesario conocer el rendimiento de dicho sistema. Se trata de conocer el número de casos categorizados correcta e incorrectamente, y a partir de esto, obtener una medida de acierto sobre todo el conjunto de prueba, para poder definir la confiabilidad de evaluación. La validación cruzada es una herramienta de evaluación para los resultados de un análisis estadístico, con el fin de garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Hace posible decidir un número fijo de particiones de los datos, por lo tanto, este método utiliza todos los registros disponibles para entrenamiento y al mismo tiempo usa muchos registros como conjuntos de prueba [Ochoa, 2019].

Una matriz de confusión es una herramienta útil que funge como método de evaluación de rendimiento de un clasificador. Su funcionamiento radica en la comparación de los valores reales con los obtenidos del algoritmo de aprendizaje supervisado. Toma en cuenta la siguiente clasificación: casos positivos clasificados correctamente (TP), casos falsos clasificados incorrectamente (FN), casos positivos clasificados incorrectamente (FP), casos negativos clasificados correctamente (TN). A partir de estos parámetros, se cuantifican las siguientes métricas: precisión, sensibilidad, tasa de clasificación y especificidad. Teniendo determinadas estas métricas, podemos identificar el grado de corrección que necesita nuestro algoritmo de aprendizaje para su funcionamiento en cuestión.

La curva ROC es la representación gráfica de la sensibilidad respecto a la especificidad para un sistema clasificador. Esta curva se emplea para determinar un umbral que ayudará a concentrar mejor la información, maximizando los verdaderos positivos y minimizando los falsos positivos en los clasificadores.

En este trabajo, se plantea la posible aportación del análisis de la potencia espectral del EEG para realizar una clasificación de dos grupos: niños con TDL (21 niños) y niños control (21 niños). Se propone desarrollar un clasificador SVM, utilizando

características relevantes, obtenidas a través de un algoritmo de selección de características en la potencia espectral del EEG.

2. Métodos

En la figura 2, se muestra un diagrama a bloques de las etapas necesarias para el desarrollo del trabajo, las cuales se describirán a continuación; cabe destacar que este trabajo se concentra en las etapas 4, 5 y 6.

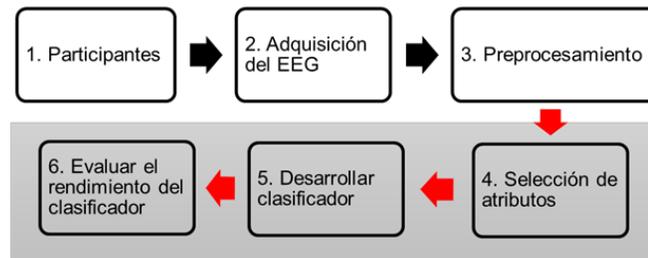


Figura 2 Diagrama a bloques general para la implementación del proyecto.

Participantes

Los registros de EEG, utilizados en este trabajo, fueron realizados en el Laboratorio de Electroencefalografía de la Dirección de Investigación del Instituto Nacional de Rehabilitación (INR). Los registros fueron obtenidos de niños (33 niños y 9 niñas) provenientes de escuelas primarias públicas y de población general, con participación voluntaria, consentimiento y asentimiento informado por el padre o tutor. La muestra está conformada por 42 niños (21 niños TDL y 21 niños control) de 5-8 años. Los criterios de inclusión son: niños en edad escolar de 5 a 8 años, antecedentes prenatales, perinatales y neonatales sin incidentes. Los criterios de exclusión para el grupo control son: presencia de alteraciones neurológicas, tales como traumatismo craneoencefálico, enfermedades del Sistema Nervioso Central, epilepsia, convulsiones, cefaleas, tics, tartamudeos, Trastorno Generalizado del Desarrollo, Trastorno por Déficit de Atención, Lenguaje y Aprendizaje. Los criterios de eliminación son: i) signos de depresión, ansiedad, oposicionista desafiante u otro trastorno de inicio de la infancia acorde a los criterios del DSM-V-TR (Manual Diagnóstico y Estadístico de los Trastornos Mentales) vigente. ii) Presencia de

electromorfogramas anormales en el EEG (trenes de onda delta o theta de voltaje, cuatro veces superior a la actividad de fondo y ondas agudas). Ninguno de los menores ha estado bajo medicación durante el curso del estudio. El protocolo fue aprobado por los Comités de Ética e Investigación del Instituto Nacional de Rehabilitación (INR) con apego a los criterios de la declaración de Helsinki. Todos los niños fueron evaluados, por una batería de pruebas psicológicas, por personal calificado en el Laboratorio de Electroencefalografía del Instituto Nacional de Rehabilitación (INR), bajo la supervisión de la Mtra. Marlene Galicia Alvarado [Galicia, 2019].

Adquisición del EEG

El EEG se registró, para cada niño y niña, en una cámara Faraday con baja iluminación y temperatura controlada, ubicada al interior del Laboratorio de Electroencefalografía del INR, mediante el equipo Nicolet One con 31 canales, arreglo monopolar, con impedancia menor a $5k\Omega$ y referencia en el hueso Mastoides. Se utilizaron 19 electrodos para modelar las redes funcionales, el arreglo se puede observar en la figura 3.

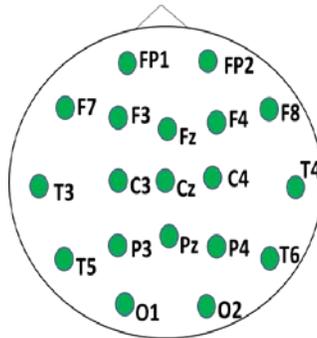


Figura 3 Distribución de electrodos en el cuero cabelludo.

Durante el registro los niños estuvieron sentados con ojos cerrados alternando con ojos abiertos, en posición relajada y se les indicó que mantuvieran dicha posición sin movimientos corporales ni faciales. El registro tuvo una duración en promedio de 30 minutos. Antes de obtener el registro se brindó una capacitación al menor de forma lúdica para tratar de asimilar el estado de reposo requerido. Un especialista,

a través de inspección visual, seleccionó épocas de 2 segundos con la menor presencia de artefactos, obteniendo en promedio 50 épocas por cada niño y niña, es decir, se tienen alrededor de 2 minutos por sujeto de estudio.

Preprocesamiento

Los registros fueron preprocesados con algoritmos de procesamiento probados en diversos estudios previos [Alducin, 2014], [Alducin, 2016], [Brust, 2017], [Brust, 2017], [Galicía, 2019]. A continuación, se describen brevemente dichos algoritmos. Se acondicionó el EEG realizando un filtrado digital de 0.5–40Hz, para atenuar información fuera de las frecuencias de interés. Se utilizó un filtro elíptico de séptimo orden, debido a que mantiene un rizado constante en la banda de paso y en la banda de rechazo, con una zona de transición estrecha. El filtro se aplicó a todos los canales en forma no causal de fase cero.

Para tratar de minimizar el efecto de la conducción por volumen, se aplicó una referencia promediada (Common Average Reference, CAR). Los artefactos oculares y musculares se removieron utilizando el Análisis de Componentes Independientes (ICA) (usando el algoritmo FastICA), para encontrar las fuentes de ruido en el registro del EEG. Una vez preprocesado el EEG, se obtuvo la potencia espectral en cada banda de frecuencia por cada época de análisis (por cada electrodo).

Selección de atributos

Se implementa código haciendo uso de la multiplataforma de desarrollo integrado Spyder, utilizando el lenguaje de código abierto en Python. En esta etapa, se utilizaron cuatro métodos: χ^2 , LDA, RFE y regresión lineal univariante. Para los cuatro métodos se implementaron dos casos, el primero fue utilizando 4 variables independientes correspondientes a las bandas de frecuencia: delta, theta, alpha y beta, y una variable dependiente que corresponde a la categoría del grupo: TDL o control. El segundo fue utilizando 19 variables independientes correspondientes a los 19 electrodos del montaje (Figura 3), en cada banda de frecuencia y la misma variable dependiente para el primer caso. Se realizaron dos bases de datos:

- La primera está conformada por cada electrodo del EEG (19 electrodos)
- La segunda por cada banda de frecuencia (4 bandas). Esto con el fin de investigar cuál electrodo o banda provee información relevante para la clasificación.

Cada base de datos contiene 2,043 épocas de la potencia espectral en cada banda de frecuencia: delta, theta, alpha y beta. Para la implementación del método Chi-square, se realizó una extracción de características haciendo uso del módulo *SelectKBest* con la finalidad de seleccionar las mejores tres características.

Para la implementación de LDA, se preparó la base de datos por medio de un escalamiento con respecto al máximo valor, con la finalidad de ajustar las características de los datos para que se asemejaran entre ellos y hacer más sencillo su tratamiento. Se dividieron los datos en entrenamiento y prueba del 50% y 50%, respectivamente, para así proyectarlo mediante el módulo *LinearDiscriminantAnalysis as LDA* que reduce la dimensionalidad de los datos generando ajustes en ellos.

Para la regresión lineal univariante se realizó un escalamiento de los datos con respecto al máximo valor. Posteriormente utilizando el módulo *SelectKBest*, se implementó la función *f_regression*, con el propósito de estimar la relación entre una variable dependiente y las variables independientes, para obtener un nuevo arreglo con las mejores características de la base de datos. Por último, en RFE se utilizó un escalamiento para el tratamiento previo de los datos y se seleccionó el módulo *RFE*, el cual se implementó con un estimador llamado *DecisionTreeRegressor*, seleccionando tres características de la base de datos y así, obtener: el número de características, las características seleccionadas y el ranking de características, por medio de las funciones: *rfe.n_features_*, *rfe.support_* y *rfe.ranking_* respectivamente.

Clasificador

Una vez elegidos los atributos, se utilizaron dos conjuntos de datos para la elaboración del algoritmo: datos de prueba y datos de entrenamiento para la SVM.

Se emplearon tres tipos de kernel: lineal, polinomial (segundo grado) y radial con la finalidad de observar el rendimiento del clasificador con distintos kernels y selector de atributos. En Python, se implementaron con las funciones: *linearSVC*, *poly* y *rbf*, respectivamente. De acuerdo con cada tipo de método, se hizo la división de la base de datos: entrenamiento y prueba. Cabe resaltar que, en el caso de la regresión lineal univariante, se seleccionan las mejores dos características de la base de datos: delta y beta, para la posterior clasificación, solo en el caso uno (4 variables independientes y 1 dependiente).

Evaluación del rendimiento del clasificador

Una vez entrenado el algoritmo, se procedió a realizar predicciones con él, haciendo uso de tres tipos de evaluación, para comprobar la relación entre ellas. Se realizó la validación cruzada con 10 particiones y una repetición para los métodos: Chi-Square y LDA, así mismo, se realizó con 10 particiones y dos repeticiones para los métodos: regresión lineal univariante y RFE. Se realizó el cálculo de las medidas de rendimiento: *accuracy*, *recall* y *precision*; se dio seguimiento de estas medidas para todos los métodos implementados. Se procedió a calcular la AUC, para obtener el rendimiento del clasificador en una sola métrica y obtenerla de forma gráfica, mostrando una mejor visualización del resultado. Generalmente, cuanto mayor es la puntuación AUC, mejor es el rendimiento de un clasificador.

3. Resultados

Para la selección de atributos con Chi-square, la potencia espectral en las bandas de frecuencia delta, theta y alpha fueron aquellas que podrían ayudar en la posterior clasificación, con la totalidad de épocas. Para la segunda base de datos, el sistema arrojó que, de los 19 electrodos, 18 son útiles para la clasificación. La regresión lineal univariante seleccionó dos bandas de frecuencia: delta y beta, manteniendo la dimensión de 2,043 épocas. Con RFE, se seleccionaron 3 características, es decir, delta, alpha y beta. Para la segunda base de datos, seleccionaron 18 electrodos, descartando un electrodo por cada banda. Ambas mantuvieron una dimensión de 2,043 épocas.

Para cada método de selección de atributos, una vez que se eligieron las características más relevantes de los datos, se introdujeron al clasificador. Dado que se probaron diversos kernels, utilizando validación cruzada se muestran y detallan los resultados obtenidos. La tabla 1, muestra los resultados del mean accuracy con mayor porcentaje del análisis hecho para la primera base de datos.

Tabla 1 Resultados de validación cruzada para la primera base de datos.

Selección de atributos	Electrodo	Kernel clasificador	Mean accuracy
Chi-Square	F8	Lineal	60.157 (0.030)
	T4	Lineal	60.892 (0.024)
		Radial	61.283 (0.022)
LDA	F7	Radial	60.722 (0.052)
	T4	Lineal	60.328 (0.039)
		Radial	60.330 (0.030)
Regresión lineal univariante	Fp2	Radial	60.13271162
RFE	Fp2	Radial	61.161 (0.029)
	P4	Radial	60.914 (0.028)
	F8	Radial	60.131 (0.022)
	T4	Radial	61.404 (0.023)

De acuerdo con el análisis hecho por cada electrodo, en la figura 4 se muestra un resultado alentador para el electrodo T4, con un porcentaje de clasificación del 63.3 y 63.08%, respectivamente.

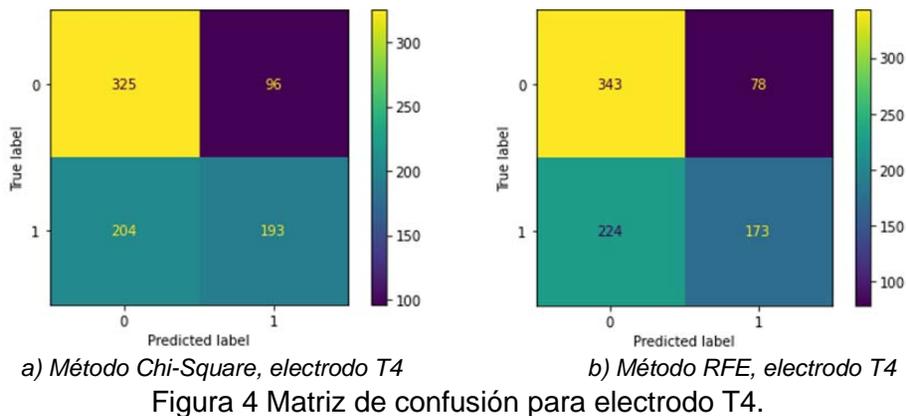


Figura 4 Matriz de confusión para electrodo T4.

La tabla 2, muestra los resultados del mean accuracy con mayor porcentaje en el análisis hecho para la segunda base de datos. En la figura 5, se muestran dos resultados predominantes en el análisis para cada banda de frecuencia. En figura

5a, la banda de frecuencia theta arrojó una tasa de clasificación del 67.97%, empleando el método Chi-Square y un kernel radial. En figura 5b, la banda de frecuencia beta arrojó una tasa de clasificación del 67.68%, empleando el método RFE y un kernel radial.

Tabla 2 Resultados de validación cruzada para la segunda base de datos.

Selección de atributos	Banda de frecuencia	Kernel clasificador	Mean accuracy
Chi-Square	Delta	Radial	60.942 (0.029)
	Theta	Radial	66.520 (0.027)
	Alpha	Radial	63.683 (0.038)
	Beta	Lineal	67.500 (0.021)
Radial		69.260 (0.016)	
LDA	Delta	Radial	60.917 (0.052)
	Theta	Lineal	65.229 (0.033)
	Alpha	Radial	64.540 (0.059)
	Beta	Lineal	69.447 (0.034)
Radial		68.959 (0.036)	
RFE	Delta	Radial	61.605 (0.026)
	Theta	Radial	68.758 (0.022)
	Alpha	Radial	67.605 (0.033)
	Beta	Lineal	66.213 (0.039)
Radial		71.231 (0.032)	

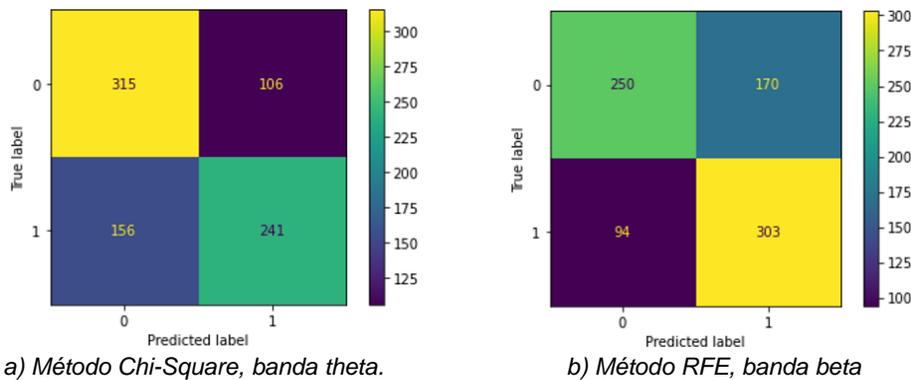


Figura 5 Matriz de confusión para segunda base de datos.

En la figura 6a, se observa la curva ROC de la banda de frecuencia beta y figura 6b la curva ROC del electrodo T4, ambas curvas fueron obtenidas implementando el método RFE y un kernel radial. En la tabla 3, se muestran los datos más relevantes de la AUC para el primer análisis, puede observar que la tasa de clasificación es cercana al 66% para los electrodos relevantes (T4 y F8), con tres diferentes kernels.

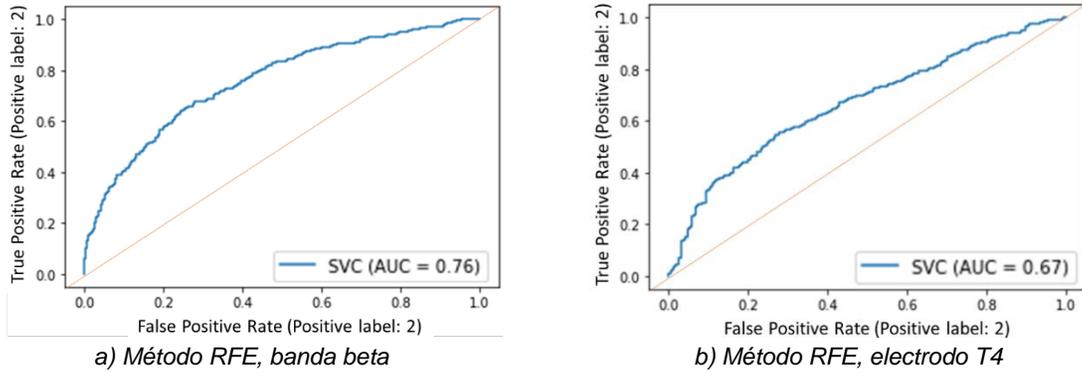


Figura 6 Curva ROC.

Tabla 3 Resultados de la AUC para la primera base de datos.

Método	Electrodo	Kernel	AUC
Chi-Square	F8	Lineal	0.65
		Polinomial	0.65
		Radial	0.65
	T4	Lineal	0.65
		Polinomial	0.66
LDA	F8	Lineal	0.65
	T4	Lineal	0.65
Regresión lineal univariante	F8	Lineal	0.64
		Polinomial	0.64
		Radial	0.65
RFE	F8	Lineal	0.65
		Radial	0.65
		Polinomial	0.66
		Radial	0.67

4. Discusión

De acuerdo con los resultados obtenidos del clasificador, el método Chi-Square descartó la banda beta de las cuatro bandas de frecuencia en cuestión. Para la segunda base de datos, seleccionó 18 electrodos para la clasificación, descartando el electrodo F4 para la banda delta, Cz para la banda beta y theta, y Pz para la banda alpha. El método LDA analizó la potencia espectral de cada banda de frecuencia creando dos conjuntos de datos: entrenamiento y prueba, del 50%. El método de regresión lineal univariante se realizó únicamente para la primera base de datos y descartó dos bandas de frecuencia: theta y alpha. Por otra parte, el método RFE descartó la banda de frecuencia theta en la primera base de datos. Luego, seleccionó 18 características (electrodos), descartando el electrodo P4 para

la banda delta, Fz para theta, C4 para alpha y T5 para beta, en la segunda base de datos.

En la evaluación de validación cruzada realizada con 10 particiones y una repetición, implementando el método RFE, se obtuvo una tasa de clasificación arriba del 60% para los electrodos: Fp2, P4, F8 y T4, con el kernel radial en la SVM. En la tabla 1, el método RFE destaca con el resultado más alto para la clasificación en los electrodos con el kernel radial, para la primera base de datos. En la evaluación con la matriz de confusión, el mejor resultado fue con la segunda base de datos. Se presentó una tasa de clasificación alrededor del 67% en los métodos Chi-Square y RFE en las bandas de frecuencia theta y beta, implementando el kernel radial. En las figuras 4 y 5, se observa la matriz de confusión para ambos análisis.

El análisis de la curva ROC, muestra la relación entre la sensibilidad y la especificidad. La figura 6, es la representación gráfica de la curva ROC de dos casos sobresalientes en la clasificación. La banda de frecuencia beta y el electrodo T4, obtuvieron una tasa de clasificación arriba del 70%, con el método RFE y un kernel lineal.

En términos generales, se observa que siempre se mantuvo una tasa de clasificación más alta cuando se implementó el kernel radial con el método RFE.

5. Conclusiones

Esta investigación se realizó con la finalidad de conocer si era posible detectar y clasificar a niños TDL de niños control, mediante la potencia espectral en las bandas de frecuencia del EEG. Idealmente, se espera que un clasificador tenga una efectividad alrededor del 80-100% para considerarse bueno, sin embargo, lograr esa efectividad no sólo depende del algoritmo que se emplee para clasificar, también influye el tratamiento previo de los datos a clasificar.

Con base en los resultados, para el análisis hecho por cada electrodo (primer base de datos), los métodos Chi-Square y RFE fueron los mejores para la selección de atributos, debido a que en la SVM se logró una efectividad del 61% en la validación cruzada, una efectividad del 63% en la matriz de confusión y un 67% en la curva ROC con el kernel radial para el electrodo T4. Así mismo, cabe mencionar que, en

la mayoría de los métodos, la única banda de frecuencia que no fue descartada fue delta. La investigación demostró que, los electrodos F8 Y T4, lograron alcanzar una efectividad arriba del 60% con cualquier método.

En general, la SVM arrojó mayores resultados realizando el análisis por cada banda de frecuencia en cada electrodo (segunda base de datos), dando porcentajes de efectividad arriba del 70%. Cabe destacar que, los mejores resultados, se obtuvieron al implementar el kernel radial con el método RFE en la banda beta. Por lo que resulta ser útil saber que la potencia espectral en dicha banda de frecuencia puede ser una aportación relevante en investigaciones posteriores.

Es importante considerar que los datos procesados, en este trabajo, fueron obtenidos en estado de reposo con ojos cerrados. Este estado si bien, es replicable y se considera que puede contener una menor cantidad de artefactos visuales, es posible que, en un trabajo futuro, sea relevante comparar con el estado de reposo de ojos abiertos. con el objetivo de obtener un estado basal de referencia con ambos paradigmas y que puedan involucrar tareas visuales.

6. Bibliografía y Referencias

- [1] Alducin, C. J., Yáñez, S. O., & Brust, C. H. Análisis electroencefalográfico de la conectividad funcional en habituación por teoría de gráficas. *Revista Mexicana de Ingeniería Biomédica*, Vol. 37, No. 3, 181-200, 2016.
- [2] Alducin, C. J. Aplicación de la teoría de gráficas al análisis de la conectividad funcional cerebral a partir del EEG. Tesis. Universidad Autónoma Metropolitana-Iztapalapa, 2014.
- [3] Alducin, C. J. Evaluación de redes de conectividad funcional en el electroencefalograma en estado de reposo. Tesis. Universidad Autónoma Metropolitana- Iztapalapa, 2021.
- [4] Bell, M., & Cuevas, K. Using EEG to Study Cognitive Development: Issues and Practices. *Journal of cognition and development*, Vol. 13, No. 3, 281-294, 2012.
- [5] Brailowsky, S. *Las sustancias de los sueños: Neuropsicofarmacología*. Fondo de cultura Económica, México, 1999.

- [6] Brust, C. H., Martínez, S. Y., Sánchez, Q. A., Flores, A. B., Alducin C. J., & Yañez, S. O. EEG Oscillations in basal mode, and those evoked by habituation and visual-motor association in male college students. *Revista de Investigación Clínica-Clinical and Translational Investigation*, 2017.
- [7] Galicia, A. M., Alducin, C. J., Ramírez, F. M., Sánchez Q. A., Yañez S. O., & Flores, A. B. Cognitive and spectral coherence of EEG alterations in resting state in children with chronic TBI. *Salud Mental*, Vol. 42, No. 2, 91–100, 2019.
- [8] Justice, L., Ahn, W. Y., & Logan, J. A. Identifying children with clinical language disorder: an application of machine-learning classification. *Journal of Learning Disabilities*, Vol. 52, No. 5, 351-365, 2019.
- [9] Kotarba, K., & Kotarba, M. Efficient detection of specific language impairment in children using ResNet classifier. *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, 169-173, 2020.
- [10] Lubar, J. F., Bianchini, K. J., Calhoun, W. H., Lambert, E. W., Brody, Z. H., & Shabsin, H. S. Spectral analysis of EEG differences between children with and without learning disabilities. *Journal of Learning Disabilities*, vol. 18, No. 7, 403-408, 1985.
- [11] Maldonado, D. J. La identificación del trastorno específico de lenguaje en niño hispano-hablantes por medio de pruebas formales e informales. *Revista Neuropsicología, Neuropsiquiatría y Neurociencias*, Vol. 11, No. 1, 33-50, 2011.
- [12] Ochoa, L. Evaluación de Algoritmos de Clasificación utilizando Validación Cruzada. 17th LACCEI International Multi-Conference for Engineering, Education, and Technology, 2019.
- [13] Reddy, M., Alku, P., & Rao, K. S. Detection of specific language impairment in children using glottal source features. In *IEEE Access*, vol. 8, 15273-15279, 2020.
- [14] Sarmiento, L. C. Interfaces cerebro-computador para el reconocimiento automático del habla silenciosa. Universidad Pedagógica Nacional, 2019.
- [15] Sharma, G., Prasad, D., Umapathy, K., & Krishnan, S. Screening and analysis of specific language impairment in young children by analyzing the textures

- of speech signal. Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), vol. 42, 964-967, 2020a.
- [16] Sharma, Y., & Singh, B. K. Classification of Children with Specific Language Impairment Using Pitch-Based Parameters. IEEE Recent Advances in Intelligent Computational Systems (RAICS), 42-46, 2020b.
- [17] Sharma Y., & B. K. Singh. Prediction of Specific Language Impairment in Children Using Speech Linear Predictive Coding Coefficients. First International Conference on Power, Control and Computing Technologies (ICPC2T), 305-310, 2020c.
- [18] Smith E., & Kosslyn, S. Procesos cognitivos: modelos y bases neurales. Pearson educación, S.A., Madrid, 2008.
- [19] Vilameá, M. Trastorno específico de lenguaje: Guía para la intervención en el ámbito educativo. Asociación TEL Galicia, 2014.