



Universidad Autónoma de Querétaro

Facultad de ingeniería

Ingeniería Biomédica



Detección de fatiga mediante señales mioeléctricas.

Tesis

Que como parte de los requisitos para obtener el título de
Ingeniero Biomédico.

Presenta:

Leonardo Miguel Rueda Trejo

Dirigido por:

Dr. Carlos Andrés Pérez Ramírez

Octubre 2022



Dirección General de Bibliotecas y Servicios Digitales
de Información



Detección de fatiga mediante señales mioeléctricas

por

Leonardo Miguel Rueda Trejo

se distribuye bajo una [Licencia Creative Commons
Atribución-NoComercial-SinDerivadas 4.0
Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/).

Clave RI: IGLIN-255059



Universidad Autónoma de Querétaro
Facultad de ingeniería
Ingeniería Biomédica

DETECCIÓN DE FÁTIGA MEDIANTE SEÑALES MIOELÉCTRICAS.

Tesis

Que como parte de los requisitos para obtener el título de
Ingeniero Biomédico.

Presenta:

Leonardo Miguel Rueda Trejo

Dirigido por:

Dr. Carlos Andrés Pérez Ramírez

Dr. Carlos Andrés Pérez Ramírez
Presidente

Dr. Juan Pablo Amézquita Sánchez
Secretario

Ing. Eduardo Martínez Segoviano
Vocal

Dr. Jesús Alberto Basurto Hurtado
Suplente

Firma
Firma
Firma
Firma

Centro Universitario
Querétaro, Qro.
Octubre 2022

Resumen

El estado fisiológico que presentan las personas es fundamental al momento de realizar sus labores. Cuando se presenta un estado fisiológico óptimo se tendrá un buen desempeño durante la realización del trabajo. En cambio, cuando existen alteraciones en el estato fisiológico el desempeño que una persona tendrá en ciertas actividades se verá mermado, incluso llegando a tener accidentes graves. Así pues, algunos de los estados fisiológicos presentes durante la realización de las labores suelen ser el estrés y la fatiga. Ambos se van incrementando durante largas jornadas de trabajo, además de disminuir significativamente con periodos de descanso a lo largo de la jornada. De esta manera, el detectar oportunamente el estado de fatiga en una persona que realiza actividades de riesgo, como lo es la conducción, permitirá disminuir los accidentes, además de favorecer la salud de los trabajadores.

En el presente trabajo se propone una metodología para detectar el estrés y la fatiga mediante señales EMG. Para esto, se obtiene una base de datos para desarrollar el procesamiento que se le dará a la señal. Este procesamiento consiste, primero, en aplicar el algoritmo EMD, para después aplicar diferentes algoritmos para obtener los fractales de cada IMF obtenida. Al calcular cada IMF se le aplicará la herramienta estadística ANOVA, de forma que se identifiquen aquellas características que más diferencien los diferentes estados de estrés. Al final se utilizarán los fractales óptimos para la identificación de los estados de estrés, utilizando como clasificador una red neuronal probabilística. Al concluir se obtuvieron resultados favorables, teniendo un 92% de efectividad.

Palabras clave: Fatiga, Estrés, Señales EMG, Algoritmo EMD, Dimensión Fractal, Análisis ANOVA, Redes Neuronales Probabilísticas, Clasificación

Dedicatoria

Esta tesis va dedicada a mi familia, los cuales siempre me ofrecieron su ayuda, alentándome a seguir y dándome su apoyo ante las etapas difíciles a lo largo de la carrera.

A Diana Patricia Arellano Pérez, quien me acompañó durante mi trayectoria a lo largo de la carrera, dándome su apoyo y cariño, ayudándome a que esta etapa fuera más agradable, brindándome los mejores momentos.

Agradecimientos

Agradezco a mi familia, en especial a mis padres, los cuales me apoyaron a lo largo de la carrera, proporcionándome los recursos necesarios para poder continuar.

A Diana Patricia Arellano Pérez, por brindarme su apoyo durante la carrera, con su compañía mi trayectoria universitaria fue más agradable, siempre estaré agradecido por haber coincidido.

Agradezco a mis amigos, por darme grandes experiencias en mi vida, además de su apoyo, haciendo más amena mi vida en la universidad.

A mis sinodales, el Dr. Juan Pablo Amézquita Ramírez, el Ing. Eduardo Martínez Segoviano, el Dr. Jesús Alberto Basurto Hurtado, y en especial, a mi director de tesis, el Dr. Carlos Andrés Pérez Ramírez, por su apoyo en la realización de este trabajo, guiándome con su conocimiento y experiencia, permitiéndome finalizar este trabajo.

A la Universidad Autónoma de Querétaro, por darme la oportunidad de realizar mi formación profesional.

Tabla de contenido

Tabla de contenido.....	6
1. Introducción.....	1
1.1 Introducción.....	2
1.2 Antecedentes.....	2
1.3 Justificación.....	5
1.4 Descripción del problema.....	6
1.5 Hipótesis y objetivos.....	7
1.5.1 Hipótesis.....	7
1.5.2 Objetivo General:.....	7
1.5.3 Objetivos Particulares:.....	8
1.6 Planteamiento General.....	8
2. Revisión de literatura.....	9
2.1 Electromiografía.....	10
2.4 Fatiga.....	10
2.4.1 Estrés.....	12
2.5 Procesamiento digital de señales.....	12
2.5.1 Descomposición empírica de modos.....	13
2.5.2 Fractales.....	14
2.5.2.1 Katz.....	15
2.5.2.2 Sevcik.....	16
2.5.2.3 Box counting.....	16
2.5.2.4 Higuchi.....	17
2.5.3 ANOVA.....	18
2.5.4 Redes neuronales probabilísticas.....	18
3. Metodología.....	21
3.1 Metodología propuesta.....	22
3.2 Base de datos empleada.....	24
3.3 Ejemplo usando una señal sintética.....	25
4. Resultados obtenidos.....	29
4.1 Cuantificación de los niveles de estrés.....	30

4.2	Comparación de fractales por cada IMF	30
4.2.1	Estrés bajo	30
4.2.2	Estrés Medio	30
4.2.3	Estrés Alto.....	31
4.3	Valores P conseguidos con la técnica ANOVA	31
4.4	Discusión.....	36
5.	Conclusiones y perspectivas	38
5.1	Conclusiones y perspectivas	39
6.	Bibliografía.....	41

Índice de figuras

Figura 1.1 Planteamiento del problema.....	8
Figura 2.1 Ejemplo de señal EMG.....	10
Figura 2.2 Perceptrón multicapa	18
Figura 2.3 Red neuronal probabilística.....	19
Figura 3.1 Metodología propuesta.....	22
Figura 3.2 Comportamiento de la señal en cada etapa.....	24
Figura 3.3 Señal sintética	26
Figura 3.4 Descomposición de la frecuencia de 20Hz.....	27
Figura 3.5 Descomposición de la frecuencia de 5Hz	27
Figura 4.1 Katz quinta IMF	32
Figura 4.2 Katz sexta IMF	32
Figura 4.3 Higuchi tercer IMF	33
Figura 4.4 Higuchi cuarta IMF	33
Figura 4.5 BoxCounting quinta IMF	34
Figura 4.6 BoxCounting sexta IMF	34
Figura 4.7 Sevcik quinta IMF.....	35
Figura 4.8 Sevcik sexta IMF	35

Índice de tablas

Tabla 1 Fractales en la señal sintética.....	28
Tabla 2 Resultados obtenidos con la metodología propuesta	30
Tabla 3 Comparación estrés bajo	30
Tabla 4 Comparación estrés medio	31
Tabla 5 Comparación estrés alto	31
Tabla 6 Valores de probabilidad obtenidos mediante ANOVA	31
Tabla 7 Comparación de resultados	37

1. Introducción

1.1 Introducción

La fatiga es un estado fisiológico que afecta al rendimiento cognitivo, manifestándose como falta de atención y de energía. Además, aumenta la percepción de esfuerzo al realizar una tarea, la cual se define como la sensación de cuan dura es una labor (Martin et al., 2018). La detección de fatiga es un asunto sobre el cual se ha indagado en gran medida, ya que al presentarse en trabajos donde se requiere concentración, y sobre todo donde la vida está en riesgo, no se puede dejar de lado. Este es el caso de los conductores, ya que periodos largos de conducción conllevan a la reducción de la alerta mental, que a su vez implica una frecuente causa de accidentes (Dimitrakopoulos et al., 2018). Por otra parte, el estrés es una consecuencia directa de la fatiga, ya que ambos derivan de la realización prolongada y continua de alguna actividad. Debido a esto, es de suma importancia el desarrollo de un dispositivo capaz de detectar fatiga y prevenir esta clase de accidentes. Esto es sobre todo importante en conductores, ya que el acto de conducir implica precisamente una actividad prolongada en ciertas ocasiones. Una forma de hacer la medición de la fatiga es mediante el parpadeo que hace la persona, misma que se puede medir empleando señales mioeléctricas. Además, una forma de hacer la medición del estrés es mediante la medición de los movimientos musculares en la zona superior del cuerpo empleando señales mioeléctricas. Por esa razón en esta tesis se busca el desarrollo de un dispositivo que mediante un sensor mioeléctrico se detecte fatiga, buscando que sea tanto simple como eficaz, para que tenga una aplicación práctica.

1.2 Antecedentes

La base de datos empleada consiste en catorce registros de señales mioeléctricas obtenidas bajo un protocolo de conducción. Este protocolo se realizó con el fin de obtener los diferentes niveles de estrés bajo diferentes circunstancias (Healey & Picard, 2005). Los diferentes escenarios de conducción consistirán en un periodo de reposo al inicio y al final del protocolo, en segundo lugar, un recorrido por una zona urbana, para después pasar a la conducción por carretera. Al pasar

por una caseta de salida el conductor debe de regresar para conducir por el mismo recorrido. Los estados de estrés en cada etapa de la conducción son estrés bajo en la etapa de reposo, estrés medio en la etapa de conducción de carretera y estrés alto en la conducción urbana. La duración de los recorridos va desde los cincuenta minutos hasta la hora y media.

El desarrollo de técnicas para la detección de fatiga ha ido progresando a lo largo de varios años, además los métodos utilizados son variados, tanto en los datos de entrada que pueden ser señales de electromiografía (EMG), electrooculografía (EOG), electroencefalograma (EEG), así como imágenes. Wen-Bing Horng et al., 2004 propusieron un sistema de detección de fatiga, el cual mediante una cámara colocada en el tablero de un carro se busca seguir la trayectoria de los ojos. Mediante una transformación de escala RGB a HSI se logra de segmentar la región de la cara, y la posición actual de los ojos se deduce de acuerdo con la posición normal de los ojos. Para obtener la segmentación de los ojos se utilizó el operador Sobel, con el cual se obtiene la posición vertical y horizontal. El análisis en la región del ojo se basa en que cuando el ojo está abierto hay pixeles pertenecientes al ojo, mientras que cuando está cerrado no aparecen estos pixeles. En este método cuando el ojo permanece cerrado más de 5 cuadros seguidos el conductor se considera fatigado. Recientemente, (Cai et al., 2019) utilizó el gráfico de visibilidad horizontal penetrable limitado, que mediante señales EEG, se utiliza el análisis de componentes individuales para filtrar la señal EEG. Posteriormente, se recrea el mapa del cerebro con el gráfico de visibilidad para identificar los nodos que se activan según el estado mental que la persona tiene. Como clasificador se emplea una máquina de soporte vectorial (SVM), logrando clasificar los estados mentales (descansado y fatiga) así como las áreas del cerebro asociadas a la fatiga. Por otra parte, (Luo et al., 2019) proponen un método en el cual se usa el algoritmo de factor de escala adaptativo, con el que se obtuvo un factor de escala con el objetivo de reconstruir la señal EEG y se procedió a sacar las entropías permutativa, muestral y difusa. Con este método se obtuvo un 95%

de eficacia, pero debido a que el método resulta en un uso alto de recursos computacionales no se considera práctica su implementación. (Ji et al., 2019) utilizaron una red neuronal convolucional en cascada de tareas múltiples, en la cual se utilizan 3 redes neuronales, las cuales se usan para delimitar la región de la cara, eliminar falsos positivos y obtener los puntos característicos de la cara, tales como los ojos y las comisuras de la boca. Aparte, se utilizaron dos redes más para definir el estado de los ojos y la boca. Para determinar la fatiga se utilizaron la frecuencia del pestañeo, el tiempo que permanecen los ojos cerrados y el tiempo del bostezo. Además, (H. Wang et al., 2019) propone un método que, mediante señales EOG y EMG, busca determinar la fatiga. Para ello se obtiene la entropía muestral de las señales EOG verticales y horizontales, además de la fusión de las entropías espectral, muestral y aproximada de distintas bandas de frecuencia de la señal EMG. Para la clasificación se usó una máquina de vector relevante, con la que se obtuvo una eficacia del 99%.

Con relación a la detección de estrés, Melillo et al. (2011), utilizó la variación del ritmo cardíaco para este fin. Para esto se usaron métodos tales como el gráfico Poincaré, aproximación de entropía, correlación de dimensión, análisis de fluctuación y la gráfica recursiva. Después de obtener las características se calculó la media, la desviación estándar y la mediana para describir su comportamiento durante el periodo de estrés y de reposo. Para la clasificación se utilizó el análisis discriminante lineal. Mediante este método se buscan las combinaciones de las características de entrada que permitan distinguir entre dos clases. Al final la efectividad de este método fue del 82%. Por otra parte, J. Healey & Picard (2000) realizó un algoritmo que utiliza distintas señales, las cuales son de electromiografía, electrocardiografía, conductividad de la piel y la respiración. Se obtuvieron la media y la varianza de cada minuta de las señales, además, del electrocardiógrafo se obtuvo además el ritmo cardíaco. Mediante un clasificador lineal se prueba la efectividad de cada característica individualmente, esto para verificar que tan buenas son para diferenciar los distintos estados. Se seleccionan las mejores

características y mediante el algoritmo de k-vecinos más cercanos se realiza la clasificación final. Para este algoritmo se obtuvo una efectividad del 88%. Recientemente, Zubair & Yoon (2020) desarrollaron un algoritmo que usa series de variabilidad de frecuencia de pulso ultracorta. Para su estudio utilizaron 14 estudiantes graduados, cuyas edades rondaban entre 25 y 30 años. Ninguno ha padecido ninguna enfermedad cardíaca o mental. Su usaron dos experimentos para registrar las señales de fotopletismografía (PPG) relacionadas con el estrés. El primero se diseñó como una serie de tareas aritméticas para inducir el estrés, las cuales tuvieron distinto nivel de dificultad. El segundo experimento consistió en mostrar el nombre de ciertos colores en una pantalla, y se le preguntaba al sujeto cual era la primera letra del color de la palabra. En el primer nivel de dificultad el color de las letras coincidía con las palabras, mientras que en el segundo nivel de dificultad las palabras se encontraban con un color distinto al de la palabra. Una vez caracterizada la señal se clasifican las señales mediante una máquina de vector soporte, y su precisión estuvo por encima del noventa por ciento.

A nivel interno, en la universidad no se encontraron trabajos relacionados con la fatiga como un estado fisiológico; únicamente se analiza como una propiedad mecánica.

A partir de los trabajos revisados, se observa que las metodologías empleadas requieren de la combinación de dos o más señales fisiológicas para detectar la fatiga; por otra parte, también se aprecia que tanto las técnicas de procesamiento como las técnicas de clasificación tienen una carga computacional considerable, lo que para una potencial aplicación en un sistema de detección en tiempo real de fatiga pudiera no ser práctico.

1.3 Justificación

Debido a la demanda laboral que se presenta hoy en día en muchas ocasiones los trabajadores se presentan al trabajo en condiciones en las cuales no pueden realizar sus actividades de manera óptima. Por otra parte, Gutiérrez Alanis

et al. (2015) menciona que en un estudio realizado en una empresa farmacéutica el 25% de los trabajadores a los cuales se les realizó el estudio padecían fatiga y/o estrés, que se relacionan a exceso de trabajo, debido a tener que cumplir con la cuota de producción. Esto derivó en daños a la salud y al rendimiento dentro de la empresa. tiempo de descanso personal para cumplir con las restantes obligaciones.

De acuerdo con Páez y Abarca (2017), la fatiga/estrés contribuye en al menos el 24% de los accidentes de tráfico. Esta situación causó en el año 2018, que 34 589 personas infortunadamente perdieran la vida a causa de accidentes de tránsito (INEGI, 2018). Esta situación demuestra la imperiosa necesidad de desarrollar estrategias que puedan detectar, a través de señales fisiológicas, cuando una persona esté experimentando estrés cuando maneja, ya que de esta manera se podrán prevenir una gran cantidad de muertes. Como ya se ha mencionado anteriormente el uso de señales EMG resulta más sencillo, debido a que su adquisición y procesamiento son más sencillos, además de que la complejidad de la señal no es tan alta como en otros casos, por ejemplo, las señales EEG. Desarrollar una metodología que sea capaz de detectar si una persona se encuentra en estado de fatiga, y que de una alarma evitar que la persona se exponga mientras realiza el trabajo es altamente deseable. Estas razones justifican la elaboración del presente trabajo.

1.4 Descripción del problema

Detectar la fatiga y el estrés asociado a ella es un asunto que se mantiene vigente a pesar del tiempo que se ha estudiado. Esto es debido a que, a pesar de las varias señales que proporciona el cuerpo al entrar en fatiga o sentirse estresado, el encontrar un método que sea eficaz para su detección y que a su vez sea práctico, o sea aplicable a un entorno real, no se ha resuelto. Este problema se debe sobre todo a la complejidad de las señales, las cuales son de difícil aplicación a ambientes comunes, tanto por la complejidad de la señal como los requisitos para obtenerla, ya que muchas veces se requiere que el paciente se mantenga en condiciones que difícilmente se podrán mantener en la vida diaria (Luo et al., 2019). Así mismo, es

necesario indicar que la detección del estrés es aún más problemática, ya que las diversas manifestaciones que éste tiene en el cuerpo humano pueden confundirse con otras condiciones, no necesariamente causantes de algún problema, pero que dificultan su detección.

Los métodos más efectivos para detectar la fatiga o el estrés utilizan señales electroencefalográficas, cardíacas o una combinación de ambas. Esto implica, como ya se ha mencionado (Liu et al., 2016), que se deban generar metodologías cuya carga computacional sea mayor, lo que implica que el sistema de procesamiento deba cumplir con requisitos muy concretos, generando potencialmente mayores costos de comercialización, además de restringir su uso en ambientes muy controlados. Una señal fisiológica que poco se ha explorado para hacer la detección de la fatiga o estrés es la señal EMG. Su uso implica que se simplifica la adquisición de los datos, ya que la mayoría de las veces solo se requiere conectar los electrodos en la zona de la cual se obtendrá la señal. Además, las técnicas utilizadas en el procesamiento de las señales EMG son variados, ya que suelen ser las más fáciles de trabajar al ser más específicas que, por ejemplo, una señal EEG.

1.5 Hipótesis y objetivos

1.5.1 Hipótesis

Al emplear una técnica de descomposición de señales y medidas no lineales, es posible hacer la diferenciación entre una persona fatigada o no fatigada empleando señales de electromiografía.

1.5.2 Objetivo General:

Desarrollar una metodología para el análisis de señales EMG, empleando una transformada tiempo-frecuencia y medidas no lineales, para la detección de fatiga en personas.

1.5.3 Objetivos Particulares:

- 1) Descomponer las señales mediante la aplicación de técnicas de tiempo-frecuencia para su posterior procesamiento.
- 2) Extraer características a las señales descompuestas mediante medidas no lineales para determinar si existe fatiga.
- 3) Analizar las características obtenidas, por medio de métodos estadísticos, para definir cuál presenta mayor diferencia entre fatiga y no fatiga.
- 4) Implementar un algoritmo, mediante técnicas de inteligencia artificial, capaz de clasificar las señales obtenidas para determinar fatiga.

1.6 Planteamiento General

A continuación, se presenta el esquema del planteamiento general del problema, el cual consta de 4 etapas.



Figura 1.1 Planteamiento del problema

Se aplicarán técnicas para la descomposición de la señal en el dominio de tiempo-frecuencia, para después caracterizar la señal mediante técnicas no lineales. Al conseguir las características se procederá a realizar el análisis estadístico, con el cual podremos determinar si las características obtenidas son independientes entre sí. Al final, se utilizará un sistema de clasificación que diferencie entre el estado mental de fatiga y de no fatiga.

2. Revisión de literatura

2.1 Electromiografía

La electromiografía es el procedimiento mediante el cual se registra la actividad eléctrica del músculo. La unidad básica del músculo (UM) consiste en una sola fibra motora nerviosa y el conjunto de fibras musculares a la cual está unida (Webster & Clark, 2010). El potencial evocado de la UM tiene una duración de entre 3-15ms y una amplitud de 20 a 2000 μV . Las señales EMG han sido ampliamente utilizadas para el diagnóstico de patologías, esto debido a la facilidad con la cual pueden ser obtenidas.




Figura 2.1 Ejemplo de señal EMG

2.4 Fatiga

La fatiga es un estado fisiológico causado por largos periodos de demanda cognitiva (Marcora et al., 2009). Aunque en la mayoría de los casos con un simple periodo de descanso desaparece, la exigencia laboral ha provocado que las

personas suelen ignorar los síntomas de fatiga para cumplir la demanda. Esto puede derivar en accidentes, los cuales en algunos trabajos pueden llegar a ser fatales, además de disminuir el desempeño en el trabajo.

Complementando lo visto en el primer capítulo, Navarrete et al. (2004) menciona que, en Estados Unidos, entre los años 1991 y 1993, se reportó que la causa de entre el 30% y el 40% de los accidentes relacionados al transporte se debieron a la fatiga de los conductores. Así pues, la fatiga empezó a tener mayor relevancia en cuanto a la seguridad vial. Por otra parte, existe también una relación entre el tipo de arreglo económico, el pago por hora en lugar de kilómetros recorridos disminuye la incidencia de accidentes, así como el número de horas reglamentarias de servicio continuo.

De acuerdo con (Hu & Lodewijks, 2020), suele haber una confusión al momento de definir la fatiga, ya que varios autores suelen mezclar el concepto de fatiga con el de somnolencia. Es importante separar estos dos conceptos, ya que el origen de ambos es diferente. Dado que se derivan de distintos factores, es fundamental definir cuáles son dichas causas de ambos padecimientos:

- Somnolencia: es provocada por una insuficiente cantidad de sueño, aunque también puede ser un síntoma en los casos de fatiga pasiva. Aun cuando puede ser un síntoma de fatiga, es importante diferenciarlos, debido a que sus manifestaciones fisiológicas son diferentes. Mientras que la fatiga desaparece con un periodo de descanso e inactividad, la somnolencia empeora.
- Fatiga mental: se deriva de grandes cargas de trabajo cognitivo, lo que se exterioriza como un aumento en la incomodidad y pérdida de respuesta, lo que conlleva a una disminución en la calidad de trabajo. Hay que resaltar los factores que de los cuales se origina la fatiga, pues debido a estos se pueden diferenciar dos tipos de fatiga:

- a) **Fatiga activa:** proviene de una prolongada jornada de trabajo, en el cual se requiere una elevada cantidad de esfuerzo mental. Un ejemplo sería una carretera donde haya muchos obstáculos y se requiera la máxima concentración del conductor provocara a la larga una disminución en sus reflejos. Naturalmente, después de horas de una actividad exigente, las personas suelen presentar síntomas tales como la angustia y la preocupación.

- b) **Fatiga pasiva:** se origina cuando la carga mental es leve en actividades prolongadas. Es principalmente caracterizado por una disminución en la motivación de seguir realizando una labor, además de que se presenta un aumento en la sensación de somnolencia. Uno de sus principales riesgos es el caso en el que ocurra un evento imprevisto, y al no estar alerta no se reaccione con suficiente rapidez. Esto, en circunstancias tales como la conducción por carreteras en las que haya pocos coches, pueden resultar en accidentes graves.

2.4.1 Estrés

El estrés puede ser definida como una reacción que ocurre al pasar de un estado de calma a un estado excitado, con el fin de preservar la integridad del organismo (K. Wang & Guo, 2020). La relación entre el desempeño al conducir y el estrés del conductor se puede expresar como una U invertida, el desempeño incrementa con el estrés hasta un estado optimo, y después empieza a disminuir debido al estrés derivado de la continua actividad. El punto óptimo de estrés varia en cada persona. Debido a esto, es posible distinguir un rendimiento bajo al conducir al detectar un nivel anormal de estrés, el cual puede hacer que el conductor disminuya su capacidad de realizar decisiones rápidamente.

2.5 Procesamiento digital de señales

El procesamiento de señales es la ciencia del análisis, la síntesis, el muestreo, la transformación, la decodificación, el mejoramiento, el transporte, y en

general de la manipulación de las señales de alguna manera (Antoniou, 2018). El manejo apropiado de las señales es crucial a la hora de obtener un buen resultado, una metodología apropiada simplifica el problema y reduce la carga computacional requerida. De hecho, al momento de aplicar un algoritmo, no solo se debe tomar en cuenta la cantidad de operaciones que requiere, sino además que tan adecuado es para la arquitectura de la computadora en la cual se ejecuta (Lim et al., 1988).

En el presente trabajo el procesamiento de la señal se llevará, a grandes rasgos, a través de tres pasos. La primera etapa será la descomposición de la señal a través de la transformada de descomposición empírica de modos, la cual separa la señal en bandas específicas de frecuencia. A continuación, se obtendrá el valor fractal de las distintas bandas de frecuencia, esto mediante cuatro algoritmos distintos, los cuales son los métodos de box counting, Higuchi, Katz y Sevcik. Como paso final, se utilizará una red neuronal como clasificador, completando así la finalidad del trabajo, que es la determinación de la fatiga mediante señales EMG.

2.5.1 Descomposición empírica de modos.

La descomposición empírica de modos (EMD) permite descomponer una señal en un conjunto de bandas de frecuencias, las cuales son conocidas como funciones de modo intrínseco (IMFs) (Moreno-Gómez et al., 2018). Esta transformada es ideal para analizar señales no lineales y no estacionarias. Para obtener cada IMF de la señal se deben de cumplir dos condiciones, la primera es que el número de cruces por cero y máximos debe ser igual, la segunda es que el valor promedio de los envolventes superior e inferior debe ser igual a cero.

El proceso para descomponer una señal dada en diferentes IMFs es llamado proceso de cernido, y se puede dividir en los siguientes pasos (Dong et al., 2009):

1. Identificar todos los máximos locales de la señal y unirlos mediante una curva cubica, la cual será la envoltura superior.

2. Repetir el primer paso para los mínimos locales para obtener la envoltura inferior.
3. Designar el promedio como $m_1(t)$ y obtener la diferencia entre la señal original, $x(t)$, y el promedio:

$$h_1 = x(t) - m_1(t) \quad \text{(Ecuación 2.1)}$$

4. En caso de que $h_1(t)$ no satisfaga las condiciones de una IMF se repite del paso uno al paso 3, hasta obtener la primer IMF. Entonces, es designada como:

$$c_1(t) = h_{1k}(t) \quad \text{(Ecuación 2.2)}$$

5. Se remueve $c_1(t)$ de la señal original, obteniendo así el residuo:

$$r_1(t) = x(t) - c_1(t) \quad \text{(Ecuación 2.3)}$$

6. Tratando a $r_1(t)$ como una nueva señal, se repite el proceso de cernido hasta que el residuo se convierta en una función monótona de la cual no se puedan extraer más IMFs.

7. Sumando todas las IMFs y el ultimo residuo se reconstruye la señal original:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad \text{(Ecuación 2.4)}$$

2.5.2 Fractales

Los fractales son objetos conceptuales que existen en el espacio de los sistemas caóticos (Theiler, 1990). Se caracterizan por ser autosimilares, lo cual implica que, sin importar la escala, la forma se mantendrá. Esta propiedad es una de las razones por las cuales los fractales son usados en distintas disciplinas, ya que es una herramienta útil para caracterizar distintos elementos de diferentes áreas.

Por eso, en el procesamiento de señales resulta provechoso al poder medir la repetitividad de las señales no lineales y no estacionarias, ya que su naturaleza las vuelve más complejas de analizar.

A lo largo del tiempo, se han desarrollado métodos para cuantificar los fractales de una señal. Dentro de la metodología propuesta en se pretende probar cuatro algoritmos distintos, y mediante la combinación de estos se pretende caracterizar la señal EMG del parpado para determinar el estado de fatiga mental.

2.5.2.1 Katz

El algoritmo de Katz calcula la fractalidad mediante el uso de conjunto de pares de puntos (Katz, 1988). Como primer paso, se calcula la longitud total de la curva mediante la suma de las distancias entre puntos consecutivos.

$$L = \sum_{i=1}^{N-1} (x_{(i+1)} - x_i) \quad (\text{Ecuación 2.5})$$

Después, se obtiene la distancia entre el primer punto y el punto más lejano a este.

$$d = \max(x_i - x_1) \quad (\text{Ecuación 2.6})$$

Además, se usa el cociente de la longitud de la curva entre la distancia promedio entre puntos sucesivos, representado por la letra a .

$$n = L/a \quad (\text{Ecuación 2.7})$$

Para finalizar, se estima el valor fractal mediante la siguiente fórmula:

$$D = \frac{\log(n)}{\log(n) + \log\left(\frac{d}{L}\right)} \quad (\text{Ecuación 2.8})$$

2.5.2.2 Sevcik

Sevcik obtiene el valor fractal mediante el uso de un conjunto de valores muestreados de una señal (Sevcik, 2010). Estos valores se normalizan, tanto en las abscisas como en las ordenadas, mediante las siguientes formulas:

$$x^n = \frac{x_i}{x_{max}} \quad (\text{Ecuación 2.9})$$

$$y^n = \frac{(y_i - y_{min})}{(y_{max} - y_{min})} \quad (\text{Ecuación 2.10})$$

Además, se obtiene la longitud de la curva de la señal normalizada, esto mediante la suma de la distancia euclidiana de valores consecutivos:

$$L = \sum_{i=0}^{N-1} \sqrt{(x_{i+1}^n - x_i^n)^2 + (y_{i+1}^n - y_i^n)^2} \quad (\text{Ecuación 2.11})$$

Una vez que se tiene la longitud total de la curva, se calcula la fractalidad mediante la siguiente formula:

$$D = 1 + \frac{\ln(L)}{\ln(2 * (N - 1))} \quad (\text{Ecuación 2.12})$$

2.5.2.3 Box counting

El método de box counting consiste en dividir la señal en cuadrados de tamaño ε (Prieto et al., 2011). Después de esto se cuenta el número de cuadrados

N requeridos para cubrir la totalidad de la señal. Al final se obtiene la fractalidad mediante la siguiente formula:

$$BCF = \frac{-\log_{10}(N(\varepsilon))}{\log(\varepsilon)} \quad (\text{Ecuación 2.13})$$

2.5.2.4 Higuchi

El algoritmo de para calcular la fractalidad de Higuchi comienza con transformar la señal en un nuevo conjunto de datos X_k^m de acuerdo con la siguiente definición (Higuchi, 1988):

$$X_k^m; X(m), X(m+k), X(m+2k), \dots, X\left(m + \left[\frac{N-m}{k}\right] \cdot k\right) \quad (m = 1, 2, \dots, k) \quad (\text{Ecuación 2.14})$$

Después, se define la longitud de la curva X_k^m de la siguiente manera:

$$L_m(k) = \left\{ \left(\sum_{i=1}^{\left[\frac{N-m}{k}\right]} |X(m+ik) - X(m+(i+1) \cdot k)| \right) \frac{N-1}{\left[\frac{N-m}{k}\right] \cdot k} \right\} k \quad (\text{Ecuación 2.15})$$

donde $N - 1 / \left[\frac{N-m}{k}\right] \cdot k$ representa el factor de normalización. Este proceso se realiza con un valor k inicial de uno, incrementando en una unidad cada iteración hasta llegar al valor máximo requerido. A continuación, se obtiene el valor promedio de cada subconjunto $L_m(k)$. Para obtener la dimensión fractal D, se busca la proporcionalidad entre el valor promedio $\langle L_m(k) \rangle$ y k^{-D} .

$$\langle L_m(k) \rangle \propto k^{-D} \quad (\text{Ecuación 2.16})$$

2.5.3 ANOVA

El análisis de varianza (ANOVA) es una técnica estadística que permite estimar las diferencias que existen entre distintos conjuntos de datos (Kim, 2017). Al evaluar estos conjuntos se obtiene un valor que indica la probabilidad de rechazar la hipótesis nula, lo que significa que no hay diferencia entre los conjuntos. Este valor varía en el intervalo de 0 a 1, donde 0 significa que no existe similitud entre los datos, mientras que el 1 representa que los datos contenidos en estos conjuntos son iguales o comparten información (Amezquita-Sanchez et al., 2018).

2.5.4 Redes neuronales probabilísticas

Las redes neuronales se componen de elementos adaptativos conectados en paralelo, los cuales interactúan de forma similar a la que lo hace el sistema nervioso humano (Matich, 2001). El perceptrón multicapa, la red neuronal más empleada, ilustrada en la Figura 2.10, presentan ciertas desventajas que lo vuelven inviable para clasificar los datos obtenidos, siendo la principal que tiene dificultades para manejar datos que están muy cercanos entre sí (Haykin, 2008). Si bien es cierto que potencialmente pueden agregarse neuronas en la capa oculta, el entrenamiento de estas no garantiza que puedan detectar esas diferencias, además de hacer tardado el tiempo de entrenamiento (Haykin, 2008). Esto implica que

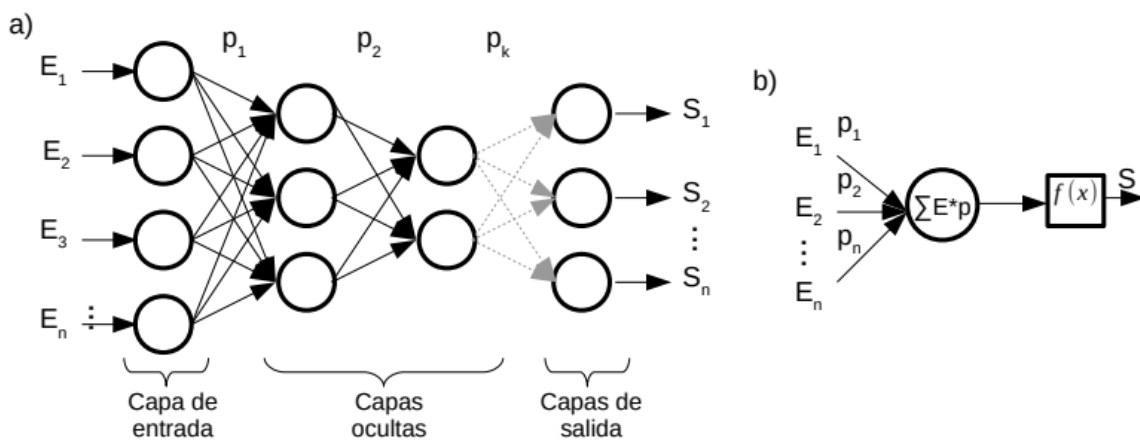


Figura 2.2 Perceptrón multicapa

diversas alternativas deben explorarse, considerando que no deben ser computacionalmente complejas tanto en su esquema de implementación como en el tiempo de cómputo requerido para obtener un resultado.

Para el presente trabajo se utilizó una red neuronal probabilísticas (RPN) (Pérez Ramírez & Fernández Castaño, 2007), ya que puede manejar conjuntos de




Figura 2.3 Red neuronal probabilística

datos cuyos valores se encuentran muy cerca, además de poder incorporar la incertidumbre que los mismos datos tienen, cuestión que para señales fisiológicas es importante (Haykin, 2008). La Figura 2.11 muestra de manera gráfica la RPN.

El funcionamiento de una RPN se describe a continuación. En primer lugar, se realiza el producto punto del vector de pesos por el vector de entradas $z_i = x \cdot w_i$. Cada neurona cuenta con una función de activación dada por $\exp\left(\frac{z_i-1}{\alpha^2}\right)$. La primera capa se encarga de calcular las distancias desde el vector de entrada a los vectores de entrenamiento. Se debe de considerar que para cada vector de entrada existe un vector de salidas deseadas. Estos vectores de entrada tienen K elementos, de los cuales alguno de ellos tiene un valor de uno, y los demás tienen el valor de cero. Así cada vector de entrada se agrupa con una clase. Como ya se mencionó

anteriormente, en la primera capa se calculan las distancias entre la entrada y el conjunto de entrenamiento. Después, elemento por elemento se multiplica y el resultado pasa por la función de activación. Las entradas que se encuentran próximas a un vector de entrenamiento tienen un valor de salida en la primera capa cercano a uno. Para la segunda capa se multiplica la matriz de vectores deseados por la salida de la capa anterior. El resultado pasa por una función de transferencia de tipo competitiva, la cual asigna un uno en el elemento con mayor valor, y cero en los demás.

Es importante notar que, para la RPN, la función de activación de cada neurona es una Gaussiana, cuya expresión es:

$$g_1(x) = \left[1/\sqrt{(2\pi\sigma^2)^N}\right] \exp\left\{-\|x - x^{(p)}\|^2/(2\sigma^2)\right\} \quad (\text{Ecuación 2.17})$$

Donde los valores de σ equivalen a la mitad de la distancia promedio entre los vectores en el mismo grupo. Para el total de neuronas de la capa, la salida se expresa como:

$$f_1(x) = \left[1/\sqrt{(2\pi\sigma^2)^N}\right] (1/P) \sum_{p=1}^P \exp\left\{-\|x - x^{(p)}\|^2/(2\sigma^2)\right\} \quad (\text{Ecuación 2.18})$$

Siendo x y y los vectores de entrada para cada clase, $x^{(p)}$ y $y^{(p)}$ los vectores de caracterización, y σ es el parámetro de propagación. Además, $\|x - x^{(p)}\|$ representa la distancia euclidiana entre x y $x^{(p)}$. El parámetro de propagación es el que se ajusta durante el entrenamiento, mismo que se obtiene usando el método del gradiente conjugado para obtener la menor distancia entre x y $x^{(p)}$ (Kusy & Zajdel, 2014).

3. Metodología

En el presente capítulo se abordará la metodología que se usará para el procesamiento de señales. Además, se explicará el método de obtención de la señal, así como la aplicación de cada algoritmo de fractalidad sobre una señal sintética para comprobar la detección en el cambio de los fractales.

3.1 Metodología propuesta

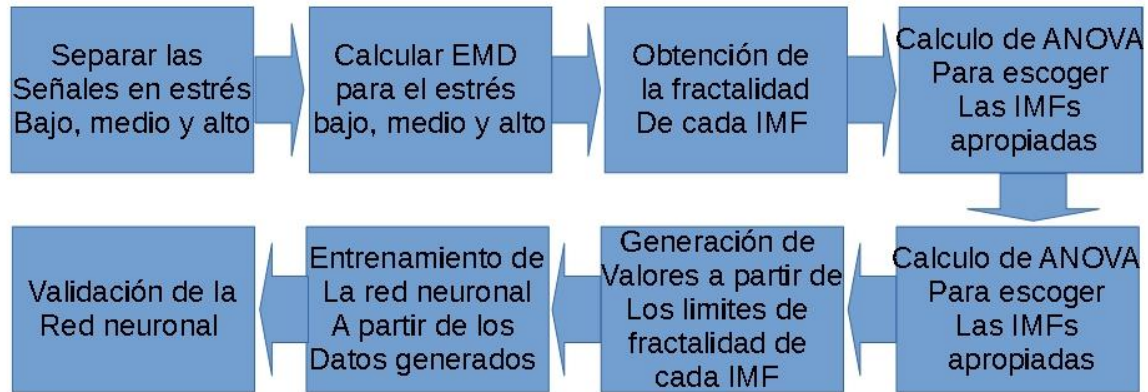


Figura 3.1 Metodología propuesta

- **Primer paso: Separar las señales.** De acuerdo con K. Wang & Guo (2020), las señales se dividen en tres etapas, estrés bajo, estrés medio y estrés medio. Para el simplificar el análisis se descompusieron las señales de acuerdo con estos tres parámetros, de acuerdo con el tiempo estimado en cada uno.
 - Estrés bajo: en este caso se tomaron los primeros y últimos quince minutos de cada señal. Para esto se calculó el número de datos que se adquieren en quince minutos mediante una relación entre la frecuencia de muestreo y la cantidad de segundos que hay en quince minutos. A partir de estos datos se extraen los datos de cada señal.
 - Estrés medio: a diferencia del estrés bajo, en este caso no se conoce con exactitud, sin embargo, se conoce que ocupa aproximadamente el 36% de la señal, 18% después de los primeros quince minutos y el otro 18% antes de los últimos quince minutos. Debido a esto para calcular cuantos datos se toman para el estrés medio se estima la cantidad de datos que

ocupan el 18% de la señal. Con el resultado se extraen esa cantidad de datos de la señal a tomando como referencia los límites que existen en cada sección de estrés bajo.

➤ Estrés alto: de la misma manera que el estrés medio, no se conoce exactamente el tiempo que ocupa en cada señal. Para extraer los datos que corresponden a estrés alto únicamente se toman en cuenta los datos que no se utilizaron en las otras dos clases de estrés.

- **Segundo paso: Descomposición EMD.** A partir de los datos separados se realizó la descomposición EMD de cada señal. Las IMFs resultantes se agruparon de acuerdo con su clasificación (estrés bajo, medio o alto).
- **Tercer paso: Calculo de fractalidad.** Las descomposiciones obtenidas son procesadas con cuatro distintos algoritmos para la obtención del fractal, Higuchi, Katz, Sevcik y box counting. Después se almacenan en estructuras de datos de acuerdo con el tipo de estrés que corresponden y el algoritmo utilizado.
- **Cuarto paso: Análisis ANOVA.** Los datos de fractalidad se compararon agrupando los datos de acuerdo con la descomposición y tipo de algoritmo usado. Mediante el análisis ANOVA se pretende encontrar la descomposición apropiada para diferenciar entre los tres estados de estrés, ya que proporciona la probabilidad de que cada conjunto de datos sea el mismo. En este caso, a menor probabilidad mayor es la diferencia entre cada conjunto de cierta descomposición. Por lo tanto, al utilizar dichas descomposiciones se obtiene un mejor resultado.
- **Quinto paso: Entrenamiento de la red neuronal.** Para el entrenamiento se usó una porción de los datos de las descomposiciones seleccionadas. Además, se varió el valor “spread” hasta obtener el mejor resultado posible.

Por otra parte, se creó una matriz para la asignación de las salidas deseadas a cada vector de entrenamiento.

- **Sexto paso: Validación de la red neuronal.** Al final, se usa el conjunto completo de los datos. Estos se evalúan en la red y se contabiliza la cantidad de aciertos que hubo.

3.2 Base de datos empleada

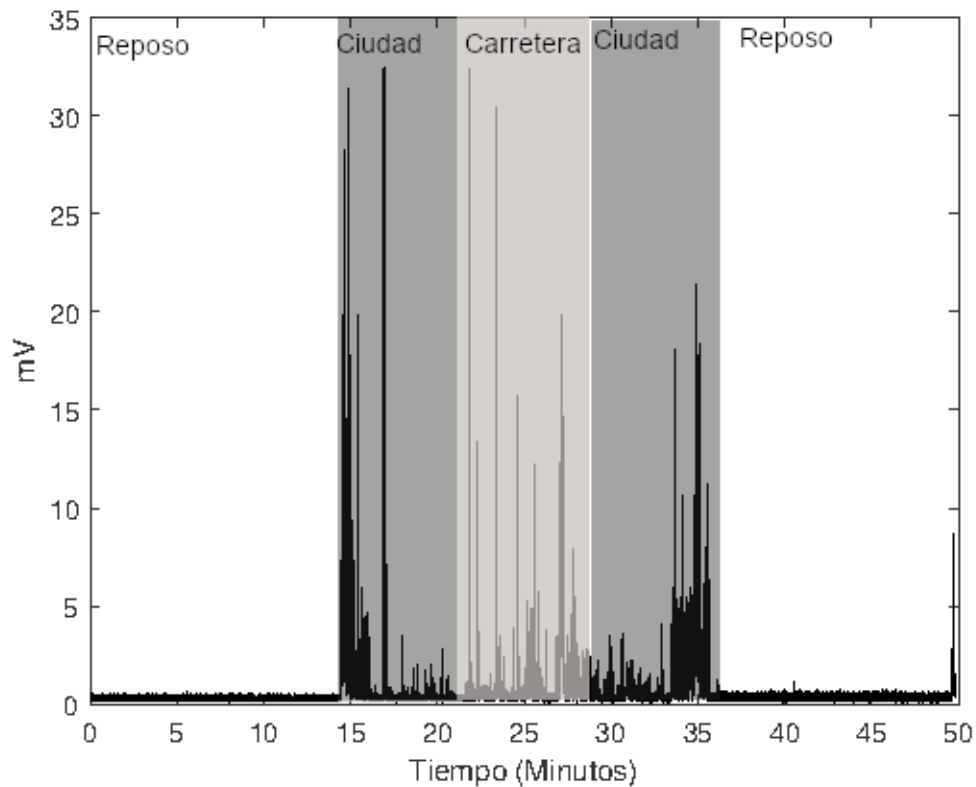


Figura 3.2 Comportamiento de la señal en cada etapa

De acuerdo con Healey & Picard (2005), el protocolo de conducción consistió en más de 20 millas de camino y varias instrucciones que los conductores debían de seguir. La ruta fue planeada para que los eventos de distintos grados de estrés ocurrieran en momentos específicos, por lo que la conducción incluye

periodos de descanso, carretera y conducción urbana para producir estrés bajo, medio y alto, respectivamente.

Dos periodos de descanso ocurren al principio y al final de la conducción. Estos descansos consistieron en poner el coche en neutral y sentarse en el garaje con los ojos cerrados. Después, los conductores condujeron a través de distintas calles hasta llegar a una concurrida calle de la ciudad. El propósito de pasar por esta calle fue obtener una situación de alto estrés donde el conductor encontrará numerosas situaciones de alto e inesperadas situaciones de peligro. A continuación, los conductores llegaban a una carretera, donde se experimentaba una conducción ininterrumpida. Después de llegar a la caseta de salida, los conductores debían de regresar a la ciudad, tomar la misma calle concurrida y regresar al punto de salida. La duración total del recorrido vario entre 50 minutos y hora y media.

Se usaron cuatro distintos tipos de sensores: electrocardiógrafo, electromiógrafo, la conductividad de la piel y la respiración. Los sensores fueron conectados a un convertidor analógico-digital aislado de la fuente de poder. El convertidor se conectó en una computadora embebida en un Volvo S70. El EMG fue conectado en el músculo trapecio, usado comúnmente como un indicador de estrés. Además, se usa una cámara montada en el volante y otra en el tablero. En total se obtuvieron 27 registros de conducción, aunque solo 14 de ellos contaban con la señal EMG necesaria.

3.3 Ejemplo usando una señal sintética

Mediante el empleo de una señal sintética se probaron los algoritmos de la descomposición EMD y los fractales Katz, Huguchi, Sevcik y Box counting. La señal generada consiste en la suma de dos ondas senoidales de 5 Hz y 20 Hz, con una frecuencia de muestro de 200Hz durante 5 segundos. La figura siguiente muestra la señal realizada.




Figura 3.3 Señal sintética

Una vez que se genera la señal se procede a aplicar la descomposición EMD sobre ella, obteniendo así dos IMF's, que se muestran a continuación.




Figura 3.5 Descomposición de la frecuencia de 5Hz




Figura 3.4 Descomposición de la frecuencia de 20Hz

Después, a cada una de las descomposiciones se les aplican los cuatro métodos de fractal, obteniendo así ocho valores distintos. La siguiente tabla muestra dichos valores.

	Katz	Higuchi	BoxCounting	Sevcik
Señal de 20Hz	1.4360507	2.13200819	1.35624811	1.69541882
Señal de 5Hz	1.35954017	1.82256392	1.76869076	1.51030178

Tabla 1 Fractales en la señal sintética

De esta manera, es posible observar como los valores fractales varían dependiendo de las características de las señales. Así pues, cuando se presentan señales que reflejan distintos estados, como es el caso del estrés, se pueden obtener valores fractales diferentes dependiendo de cada estado. Sin embargo, en algunas ocasiones las diferencias suelen ser mínimas, o al momento de separar la señal algunas de las señales derivadas no presentan diferenciación. Debido a esto, resulta necesario realizar un análisis estadístico, de forma que se determine en cuales de las características obtenidas se presenta una mayor diferenciación. Esto permitirá que al momento de aplicar un clasificador este pueda realizar de manera apropiada la diferenciación de estados, obteniendo así una mayor precisión.

4. Resultados obtenidos

4.1 Cuantificación de los niveles de estrés

A continuación, se presentan los resultados obtenidos a partir de los fractales evaluados en la red neuronal probabilística:

	Reposo	Estrés bajo	Estrés medio	Estrés alto	Eficiencia
Reposo	9	1	0	0	90%
Estrés bajo	1	9	0	0	90%
Estrés medio	1	0	9	0	90%
Estrés alto	0	0	0	10	100%
				Eficiencia total	92.5%

Tabla 2 Resultados obtenidos con la metodología propuesta

4.2 Comparación de fractales por cada IMF

4.2.1 Estrés bajo

IMF	Katz	Higuchi	BoxCounting	Sevcik
1	1.4002	1.9898	-1.3946	1.5707
2	1.3742	1.9434	-1.4323	1.5091
3	1.3424	1.8179	-1.4288	1.4396
4	1.3012	1.5206	-1.4104	1.3546
5	1.2684	1.1452	-1.3648	1.2928
6	1.2319	1.0261	-1.3884	1.2432
7	1.2073	1.0059	-1.4127	1.2121
8	1.1656	1.0007	-1.3758	1.1704
9	1.1264	1.0007	-1.2216	1.1240
10	0.4796	0.4289	-0.5136	0.4782

Tabla 3 Comparación estrés bajo

4.2.2 Estrés Medio

IMF	Katz	Higuchi	BoxCounting	Sevcik
1	1.3996	1.9810	-1.4086	1.5577
2	1.3642	1.9272	-1.4182	1.4729
3	1.3256	1.7745	-1.4220	1.3930
4	1.3030	1.4926	-1.4507	1.3464
5	1.2710	1.1284	-1.4447	1.2907
6	1.2321	1.0230	-1.4525	1.2383
7	1.1970	1.0048	-1.4225	1.2013
8	1.1482	1.0018	-1.2375	1.1402

9	0.4826	0.4291	-0.5086	0.4813
10	0	0	0	0

Tabla 4 Comparación estrés medio

4.2.3 Estrés Alto

IMF	Katz	Higuchi	BoxCounting	Sevcik
1	1.3768	1.9803	-1.2968	1.5051
2	1.3454	1.9247	-1.3359	1.4339
3	1.3224	1.7691	-1.3784	1.3856
4	1.2948	1.4717	-1.3878	1.3280
5	1.2690	1.1085	-1.3977	1.2830
6	1.2392	1.0173	-1.4388	1.2413
7	1.2036	1.0031	-1.4164	1.1985
8	1.1535	1.0008	-1.2927	1.1458
9	1.1115	1.0001	-1.1854	1.1142
10	0.0779	0.0714	-0.0779	0.0777

Tabla 5 Comparación estrés alto

4.3 Valores P conseguidos con la técnica ANOVA

Se evalúan las diez IMF's, agrupando los valores de fractalidad obtenidos en los estados de estrés bajo, medio y alto, de manera que se puedan comparar la diferencia entre los fractales de cada IMF que se calculó.

IMF	Katz	Higuchi	BoxCounting	Sevcik
1	0.3004	0.9064	0.0803	0.3812
2	0.7171	0.0726	0.1720	0.8088
3	0.1186	0.0036	0.0023	0.1545
4	4.8700e-04	0.4283	9.9324e-05	0.0016
5	7.9835e-04	0.1560	0.0038	0.0078
6	4.0007e-06	0.0328	2.0114e-05	5.2116e-06
7	5.0917e-04	0.0205	1.6024e-05	1.0132e-05
8	0.0906	0.0339	0.3033	0.0084
9	0.3650	0.3706	0.1620	0.4685
10	4.7671e-04	4.6251e-04	8.5327e-05	4.7750e-04

Tabla 6 Valores de probabilidad obtenidos mediante ANOVA

A continuación, se muestran las gráficas de cajas y bigotes de los fractales elegidos para la red neuronal:




Figura 4.1 Katz quinta IMF




Figura 4.2 Katz sexta IMF




Figura 4.3 Higuchi tercer IMF




Figura 4.4 Higuchi cuarta IMF




Figura 4.5 BoxCounting quinta IMF




Figura 4.6 BoxCounting sexta IMF




Figura 4.7 Sevcik quinta IMF




Figura 4.8 Sevcik sexta IMF

4.4 Discusión

En el presente trabajo se ha podido obtener una precisión mayor al 90%, la cual es una precisión similar a otros trabajos similares. Por una parte, Horng et al. (2004) presenta la menor precisión entre los diferentes trabajos comparados. Esto se debe a que la metodología usada resulta bastante imprecisa, ya que la señal de video se ve afectada en gran medida por los cambios en la luz ambiental. Por otra parte, el trabajo de Cai et al. (2019) fue el que obtuvo la mayor precisión, sin embargo, la adquisición de las señales que ocupa resulta complicada, ya que para adquirir de forma correcta las señales EEG es necesario que la superficie se encuentre apropiadamente preparada, lo cual resulta imposible en situaciones reales. Por otro lado, las señales ECG también presentan problemas al momento de la adquisición, ya que la conexión ocupa conectar los electrodos en posiciones que resultan complicadas, sobre todo cuando es necesario realizar movimientos constantes. Las señales EMG permiten solucionar estos problemas, ya que la colocación no necesita una preparación tan complicada. Además, al colocarse en una zona en específico los problemas que pueden ocurrir al haber movimiento se disminuyen.

Trabajo	Señal	Metodología	Precisión
Horng et al., 2004	Video	Se coloca una cámara en el tablero del coche. Al video obtenido se le realiza una transformación de la escala RGB a HSI, y mediante un operador Sobel se obtiene la posición de los ojos. La detección del parpadeo se obtiene cuando no se puede identificar el ojo, o sea, cuando el ojo está cerrado.	88.9%
Cai et al., 2019	EEG	Se conecta una gorra de adquisición de 40 canales a los conductores. Mediante un gráfico de visibilidad horizontal se recrea el mapa del cerebro, identificando los nodos que se activan de acuerdo con el estado mental del conductor. Se utiliza una máquina de soporte vectorial para clasificar los estados mentales de fatiga y descanso.	99.09%

Luo et al., 2019	EEG	Se utiliza un factor de escala adaptativo, el cual permite reconstruir la señal EEG. A la señal reconstruida se le calcula tres tipos de entropías, la permutativa, la muestral, y difusa. Como clasificador se usó una máquina de soporte vectorial.	95.37%
Melillo et al., 2011	ECG	Se utiliza la variación del ritmo cardiaco, y los métodos usados para el procesamiento de la señal fueron la entropía, la correlación de dimensión, el análisis de fluctuación y la gráfica recursiva. A estas características se les calcula la media, la desviación estándar y la mediana, con lo cual se puede usar como clasificador el análisis discriminante lineal. Se prueban las combinaciones de las características que puedan diferenciar entre los dos estados.	90%
Zubair & Yoon, 2020	PPG	A las señales adquiridas se les realiza el procesamiento necesario para obtener diferentes características de la variación del ritmo cardiaco, tales como la media, la desviación estándar, o la entropía, entre otras. Al elegir las características que mejor diferencian los diferentes estados se utiliza una máquina de soporte vectorial para realizar la clasificación.	94.33%
Este trabajo	EMG	Se utiliza la descomposición empírica de modos para separar la señal en diferentes rangos de frecuencias. A las descomposiciones se les aplican diferentes fractales para su caracterización. Se utiliza la técnica ANOVA para determinar cuáles son las descomposiciones y características que permiten diferenciar de mejor manera los diferentes estados. Al final se usa una red neuronal probabilística para la clasificación de los estados.	92.5%

Tabla 7 Comparación de resultados

5. Conclusiones y prospectivas

5.1 Conclusiones y prospectivas

La fatiga es el estado fisiológico que se produce al realizar una tarea durante un periodo prolongado de tiempo sin tomar un descanso adecuado. Esto provoca que el rendimiento cognitivo disminuya, por lo que la persona que se encuentra en estado de fatiga sea incapaz de realizar sus actividades con la atención necesaria para evitar accidentes. Esto cobra especial importancia en actividades prolongadas y en las cuales se posee un riesgo alto de tener un accidente grave, como es el caso de la conducción, donde, de acuerdo con Páez y Abarca (2017), la fatiga en los conductores causa el 24% de los accidentes de tráfico.

Debido a esto, en el presente trabajo de tesis se propone una metodología que, mediante el uso de la descomposición empírica de modos, junto con el uso de fractales y una red neuronal probabilística, se detecte la fatiga mediante señales EMG. Para esto, se usó una base de datos con catorce señales EMG obtenidas bajo un protocolo de conducción que permitiera detectar las diferencias que se presentan entre los estados de reposo, de bajo estrés, de medio estrés y alto estrés. A estas señales se les aplicó el algoritmo EMD, obteniendo una serie de descomposiciones para cada señal. A su vez, a cada descomposición se le aplicaron cuatro diferentes algoritmos para obtener su valor de fractalidad. Después, mediante el análisis estadístico ANOVA se determinaron cuales señales permitían distinguir mejor entre los diferentes estados. Al final, se utilizan los valores de los fractales de estas señales para entrenar y validar la red neuronal probabilística. De esta forma, se pudo obtener una precisión del 92.5%.

Al obtener estos resultados es posible determinar que el método planteado es útil para detectar la fatiga, aunque se deben considerar algunos puntos para un trabajo futuro que permita mejorar la metodología para su aplicación en un entorno real. En primer lugar, debido a las restricciones derivadas a la contingencia sanitaria no fue posible realizar pruebas con un circuito EMG propio. Debido a esto se tuvo que utilizar una base de datos, la cual, si bien posee un protocolo adecuado, la colocación de los electrodos que se usa no resulta practica para la conducción. Esto

ya que al colocarse en la espalda se tiene el riesgo de que al conducir se produzcan movimientos que afecten la señal adquirida. Esto, mediante la colocación en el parpado que se propone en el presente trabajo, resulta un problema menor, ya que el movimiento sería mínimo. Otro punto que se debe de considerar es que el estado que se busca detectar en el estudio que se realizó para la obtención de la base de datos utilizado es el estrés. Esto provoca que, si bien el estrés en la conducción esté relacionado a la fatiga, sería necesario comprobar que mediante esta metodología y el circuito propuesto se pueda detectar de forma igual de eficaz el estado de fatiga. Por otra parte, también es necesario considerar que la base de datos presenta pocas señales, siendo así necesario que en un trabajo futuro se realicen un mayor número de señales para garantizar la efectividad de la metodología. Por último, es importante que se utilicen protocolos específicos para la obtención de fatiga mediante el circuito propuesto en el presente trabajo. Para concluir, es necesario destacar que la ventaja de la metodología propuesta en este trabajo es que, además de que la obtención de señales EMG es bastante sencilla, el algoritmo utilizado requiere una baja carga computacional. De esta forma es posible utilizar un microcontrolador que permita que el sistema de adquisición y procesamiento pueda monitorizar de forma continua, logrando una aplicación práctica y no solo teórica.

6. Bibliografía

- Amezquita-Sanchez, J. P., Valtierra-Rodríguez, M., Adeli, H., & Perez-Ramirez, C. A. (2018). A Novel Wavelet Transform-Homogeneity Model for Sudden Cardiac Death Prediction Using ECG Signals. *Journal of Medical Systems*, 42(10), 176. <https://doi.org/10.1007/s10916-018-1031-5>
- Antoniou, A. (2018). *Digital filters: Analysis, design, and signal processing applications* (2nd edition). McGraw-Hill Education.
- Baker, B. C. (1999). Anti-aliasing, analog filters for data acquisition systems. AN699, *Microchip Technology Inc.*
- Cai, Q., Gao, Z.-K., Yang, Y.-X., Dang, W.-D., & Grebogi, C. (2019). Multiplex Limited Penetrable Horizontal Visibility Graph from EEG Signals for Driver Fatigue Detection. *International Journal of Neural Systems*, 29(05), 1850057. <https://doi.org/10.1142/S0129065718500570>
- De Luca, C. J. (1997). The Use of Surface Electromyography in Biomechanics. *Journal of Applied Biomechanics*, 13(2), 135-163. <https://doi.org/10.1123/jab.13.2.135>
- Dimitrakopoulos, G. N., Kakkos, I., Dai, Z., Wang, H., Sgarbas, K., Thakor, N., Bezerianos, A., & Sun, Y. (2018). Functional Connectivity Analysis of Mental Fatigue Reveals Different Network Topological Alterations Between Driving and Vigilance Tasks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(4), 740-749. <https://doi.org/10.1109/TNSRE.2018.2791936>
- Dong, H., Qi, K., Chen, X., Zi, Y., He, Z., & Li, B. (2009). Sifting process of EMD and its application in rolling element bearing fault diagnosis. *Journal of Mechanical Science and Technology*, 23(8), 2000-2007. <https://doi.org/10.1007/s12206-009-0438-9>
- Gutiérrez Alanis, M. T., Sánchez, C., & Argüello, C. (2015). Estrés, fatiga y somnolencia en trabajadores del área de producción de una empresa farmacéutica en México. En *Salud de los trabajadores* (Vol. 23).
- Haykin, S. S. (2008). *Neural networks and learning machines* (3rd ed). Prentice Hall.
- Healey, J. A., & Picard, R. W. (2005). Detecting Stress During Real-World Driving Tasks Using Physiological Sensors. *IEEE Transactions on Intelligent Transportation Systems*, 6(2), 156-166. <https://doi.org/10.1109/TITS.2005.848368>
- Healey, J., & Picard, R. (2000). SmartCar: Detecting driver stress. *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*, 4, 218-221. <https://doi.org/10.1109/ICPR.2000.902898>

- Higuchi, T. (1988). Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, 31(2), 277-283. [https://doi.org/10.1016/0167-2789\(88\)90081-4](https://doi.org/10.1016/0167-2789(88)90081-4)
- Hu, X., & Lodewijks, G. (2020). Detecting fatigue in car drivers and aircraft pilots by using non-invasive measures: The value of differentiation of sleepiness and mental fatigue. *Journal of Safety Research*, 72, 173-187. <https://doi.org/10.1016/j.jsr.2019.12.015>
- Ibarra Lúzar, J. I., Pérez Zorrilla, E., & Fernández García, C. (2005). Electromiografía clínica. *Rehabilitación*, 39(6), 265-276. [https://doi.org/10.1016/S0048-7120\(05\)74360-7](https://doi.org/10.1016/S0048-7120(05)74360-7)
- INEGI. (2018). *CARACTERÍSTICAS DE LAS DEFUNCIONES REGISTRADAS EN MÉXICO DURANTE 2018*. CARACTERÍSTICAS DE LAS DEFUNCIONES REGISTRADAS EN MÉXICO DURANTE 2018
- Ji, Y., Wang, S., Zhao, Y., Wei, J., & Lu, Y. (2019). Fatigue State Detection Based on Multi-Index Fusion and State Recognition Network. *IEEE Access*, 7, 64136-64147. <https://doi.org/10.1109/ACCESS.2019.2917382>
- Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in Biology and Medicine*, 18(3), 145-156. [https://doi.org/10.1016/0010-4825\(88\)90041-8](https://doi.org/10.1016/0010-4825(88)90041-8)
- Kim, T. K. (2017). Understanding one-way ANOVA using conceptual figures. *Korean Journal of Anesthesiology*, 70(1), 22-26. <https://doi.org/10.4097/kjae.2017.70.1.22>
- Kusy, M., & Zajdel, R. (2014). Probabilistic neural network training procedure based on Q(0)-learning algorithm in medical data classification. *Applied Intelligence*, 41(3), 837-854. <https://doi.org/10.1007/s10489-014-0562-9>
- Lim, J. S., Bace, M. M., Oppenheim, A. V., Bondaryk, J. E., Brandstein, M. S., Cobra, D. T., Covell, J. E., Feder, M., Musicus, B. A., & Patil, R. (1988). *Digital signal processing*. Research Laboratory of Electronics (RLE) at the Massachusetts Institute of ...
- Liu, P., Wang, Y., Cong, W., & Lei, W. (2016). Grouping-Sorting-Optimized Model Predictive Control for Modular Multilevel Converter With Reduced Computational Load. *IEEE Transactions on Power Electronics*, 31(3), 1896-1907. <https://doi.org/10.1109/TPEL.2015.2432767>
- Luo, H., Qiu, T., Liu, C., & Huang, P. (2019). Research on fatigue driving detection using forehead EEG based on adaptive multi-scale entropy. *Biomedical Signal Processing and Control*, 51, 50-58. <https://doi.org/10.1016/j.bspc.2019.02.005>

- Marcora, S. M., Staiano, W., & Manning, V. (2009). Mental fatigue impairs physical performance in humans. *Journal of Applied Physiology*, 106(3), 857-864. <https://doi.org/10.1152/jappphysiol.91324.2008>
- Mario Páez, & Emilio Abarca. (2017, octubre). *Herramientas para la seguridad en la movilidad, modelos predictivos de somnolencia en conductores* [Publicación bimestral de divulgación externa]. Instituto Mexicano del transporte. <https://imt.mx/resumen-boletines.html?IdArticulo=449&IdBoletin=168>
- Martin, K., Meeusen, R., Thompson, K. G., Keegan, R., & Rattray, B. (2018). Mental Fatigue Impairs Endurance Performance: A Physiological Explanation. *Sports Medicine*, 48(9), 2041-2051. <https://doi.org/10.1007/s40279-018-0946-9>
- Match, D. J. (2001). Redes Neuronales: Conceptos básicos y aplicaciones. *Universidad Tecnológica Nacional, México*.
- Melillo, P., Bracale, M., & Pecchia, L. (2011). Nonlinear Heart Rate Variability features for real-life stress detection. Case study: Students under stress due to university examination. *BioMedical Engineering OnLine*, 10(1), 96. <https://doi.org/10.1186/1475-925X-10-96>
- Moreno-Gomez, A., Amezcua-Sanchez, J., Valtierra-Rodriguez, M., Perez-Ramirez, C., Dominguez-Gonzalez, A., & Chavez-Alegria, O. (2018). EMD-Shannon Entropy-Based Methodology to Detect Incipient Damages in a Truss Structure. *Applied Sciences*, 8(11), 2068. <https://doi.org/10.3390/app8112068>
- Navarrete, R., Miguel Martínez Madrid, Eduardo Betanzo Quezada, Oswaldo Ramírez Cano, & Jesús Mateo Fortanell Romero. (2004). *ASPECTOS DE LA FATIGA DEL CONDUCTOR Y ESTUDIO DE LAS TECNOLOGÍAS PARA DETECTARLA Y PREVENIRLA*. Instituto Mexicano del Transporte.
- Naylamp Mechatronics. (s. f.). *Electrodos para EMG*. Naylamp Mechatronics. Recuperado 26 de octubre de 2020, de <https://naylampmechatronics.com/biomedico/310-electrodos-para-emg.html>
- Nehorai, A. (1985). A minimal parameter adaptive notch filter with constrained poles and zeros. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 33(4), 983-996. <https://doi.org/10.1109/TASSP.1985.1164643>
- Pérez Ramírez, F. O., & Fernández Castaño, H. (2007). Las redes neuronales y la evaluación del riesgo de crédito. *Revista Ingenierías Universidad de Medellín*, 6(10), 77-91.
- Prieto, M. D., Espinosa, A. G., Ruiz, J.-R. R., Urresty, J. C., & Ortega, J. A. (2011). Feature Extraction of Demagnetization Faults in Permanent-Magnet Synchronous Motors

- Based on Box-Counting Fractal Dimension. *IEEE Transactions on Industrial Electronics*, 58(5), 1594-1605. <https://doi.org/10.1109/TIE.2010.2066538>
- Sevcik, C. (2010). A procedure to Estimate the Fractal Dimension of Waveforms. *arXiv:1003.5266 [nlin]*. <http://arxiv.org/abs/1003.5266>
- Srinivasan, R., Tucker, D. M., & Murias, M. (1998). Estimating the spatial Nyquist of the human EEG. *Behavior Research Methods, Instruments, & Computers*, 30(1), 8-19. <https://doi.org/10.3758/BF03209412>
- Theiler, J. (1990). Estimating fractal dimension. *Journal of the Optical Society of America A*, 7(6), 1055. <https://doi.org/10.1364/JOSAA.7.001055>
- Villarroya Aparicio, M. A. (2005). Electromiografía cinesiológica. *Rehabilitación*, 39(6), 255-264. [https://doi.org/10.1016/S0048-7120\(05\)74359-0](https://doi.org/10.1016/S0048-7120(05)74359-0)
- Wang, H., Wu, C., Li, T., He, Y., Chen, P., & Bezerianos, A. (2019). Driving Fatigue Classification Based on Fusion Entropy Analysis Combining EOG and EEG. *IEEE Access*, 7, 61975-61986. <https://doi.org/10.1109/ACCESS.2019.2915533>
- Wang, K., & Guo, P. (2020). An Ensemble Classification Model With Unsupervised Representation Learning for Driving Stress Recognition Using Physiological Signals. *IEEE Transactions on Intelligent Transportation Systems*, 1-13. <https://doi.org/10.1109/TITS.2020.2980555>
- Webb, A. G. (2018). *Principles of Biomedical Instrumentation: (1.^a ed.)*. Cambridge University Press. <https://doi.org/10.1017/9781316286210>
- Webster, J. G., & Clark, J. W. (Eds.). (2010). *Medical instrumentation: Application and design* (4th ed). John Wiley & Sons.
- Wen-Bing Horng, Chih-Yuan Chen, Yi Chang, & Chun-Hai Fan. (2004). Driver fatigue detection based on eye tracking and dynamic template matching. *IEEE International Conference on Networking, Sensing and Control, 2004*, 7-12. <https://doi.org/10.1109/ICNSC.2004.1297400>
- Zubair, M., & Yoon, C. (2020). Multilevel mental stress detection using ultra-short pulse rate variability series. *Biomedical Signal Processing and Control*, 57, 101736. <https://doi.org/10.1016/j.bspc.2019.101736>