



Facultad de
Ingeniería
Universidad Nacional de Mar del Plata

Trabajo Final

Ingeniería Electrónica

Dispositivo de Adquisición de Señales Mioeléctricas

Autor:

Rodrigo AZPILCUETA

Directores:

Dr. Ing. Marcelo Nicolás GUZMÁN

Ing. Gonzalo Roberto FONTANELLA



RINFI se desarrolla en forma conjunta entre el INTEMA y la Biblioteca de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata.

Tiene como objetivo recopilar, organizar, gestionar, difundir y preservar documentos digitales en Ingeniería, Ciencia y Tecnología de Materiales y Ciencias Afines.

A través del Acceso Abierto, se pretende aumentar la visibilidad y el impacto de los resultados de la investigación, asumiendo las políticas y cumpliendo con los protocolos y estándares internacionales para la interoperabilidad entre repositorios



Esta obra está bajo una [Licencia Creative Commons Atribución-
NoComercial-CompartirIgual 4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/).



Facultad de
Ingeniería
Universidad Nacional de Mar del Plata

Trabajo Final

Ingeniería Electrónica

Dispositivo de Adquisición de Señales Mioeléctricas

Autor:

Rodrigo AZPILCUETA

Directores:

Dr. Ing. Marcelo Nicolás GUZMÁN

Ing. Gonzalo Roberto FONTANELLA

Resumen

Los músculos del cuerpo humano son usados en todo tipo de actividades de nuestra vida, desde las tareas cotidianas más básicas, hasta deportes de alta competencia. Las fuerzas necesarias para realizar tareas tales como levantar un objeto, patear una pelota, sonreír, etc., son todas generadas por la contracción de los músculos esqueléticos. El proceso comienza con una señal eléctrica generada en el sistema nervioso, que se transmite a través de los nervios periféricos y hace contraer a los músculos. Cuando el impulso eléctrico llega a una terminación nerviosa, el mensaje se transmite y la actividad eléctrica se esparce sobre las fibras musculares. El registro de esta actividad se conoce como electromiografía.

La electromiografía puede ser registrada insertando electrodos dentro de los músculos o, alternativamente, colocando electrodos sobre la superficie de la piel. Esta última variante es la que se conoce como electromiografía superficial o SEMG. La SEMG tiene múltiples aplicaciones. Permite realizar análisis de movimientos, evaluar fatigas, detectar patologías neuromusculares, evaluación post quirúrgica, realizar análisis en deportes de alto rendimiento, manejar prótesis robóticas, entre otros.

El presente trabajo se enfoca en el diseño y construcción de un dispositivo prototipo que permite registrar las actividades electromiográficas en la superficie de los músculos. Fue requerido por el Laboratorio de Bioingeniería de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata para posteriormente evaluar las potenciales aplicaciones de este tipo de señales.

Agradecimientos

A mi padre Julio y a mi madre Mirta, por sostenerme en todos los sentidos durante este largo proceso, este logro es de ustedes.

A Gustavo Meschino, por todo el tiempo dedicado, por todo lo enseñado a nivel académico y humano. Por insistir y levantarme cuando me creía caído. Por hacerme volver a confiar en mi capacidad y por el amigo en el que hoy te has convertido.

A mis directores Gonzalo y Marcelo, por aguantarme en todo este proceso y por su esfuerzo y dedicación.

A la directora del Departamento de Ingeniería Electrónica y Computación de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata, Isabel Passoni, por involucrarse y valorar los avances a medida que ocurrían.

A laboratorio de Bioingeniería de la Facultad de Ingeniería de la Universidad de Mar del Plata por darme el espacio y los elementos para trabajar y siempre tenderme una mano cuando lo necesite. Por los mates de la tarde, las charlas y los consejos.

A mis amigos de Ayacucho por ser mi sostén siempre.

A mi hermana Ludmila.

A mis compañeros de casa Nico, Kaku, Turca, Maik y todos los que han pasado por el centro Ayacuchense. Jamás dejo de aprender de ustedes y sin ustedes no sería la persona que soy ahora.

A mi gran amigo y futuro ingeniero Natan.

A la Municipalidad de Ayacucho por alojarme y confiar en mí todos estos años para que pudiera cumplir mi sueño y el de mi familia, que de otra forma hubiese sido imposible.

A todos los excelentes profesores que tuve la suerte de tener durante toda la carrera.

A todas las personas que, directa o indirectamente, pude conocer en mi etapa de estudiante en Mar del Plata y que hicieron de esta experiencia algo único.

A la Facultad de Ingeniería en todo su conjunto y, más en general, a la educación pública, que entiendo es la herramienta más importante para achicar la brecha de la desigualdad entre las personas. Universidad PÚBLICA, GRATUITA y de CALIDAD siempre.

Dedicado a la memoria de Julio Cesar D'Augerot.

Índice

Capítulo 1.....	9
Proyecto y desarrollo	9
1.1 Objetivos del proyecto.....	9
1.2 Introducción.....	9
1.3 Características de las señales de EMG	13
1.4 Medición práctica de EMG	14
1.5 Amplificador de instrumentación.....	15
1.6 Electrodos	17
Capítulo 2.....	19
Ruido asociado a la medición de SEMG	19
2.1 Fuentes de ruido	19
2.2 Modelado de la interferencia a través del cuerpo.....	20
2.3 Reducción del voltaje de modo común	22
2.4 Reducción de la interferencia en los cables de medición.....	25
Capítulo 3.....	27
Diseño de hardware	27
3.1 Especificación Funcional y Técnica.....	27
3.2 Diagrama de Bloques	28
3.3 Electrodos y cables de interconexión.....	29
3.4 Circuito Analógico.....	32
3.5 Microcontrolador	49
3.6 Conexionado y operación del sistema	60
Capítulo 4.....	62
Simulaciones.....	62
4.1 Objetivo y herramientas utilizadas	62
4.1.2 Influencia del filtro pasabanda.	64
Capítulo 5.....	69
Conclusiones	69
Referencias.....	71

Acrónimos

ADC Analog-Digital Converter (Conversor Analógico Digital)
CMRR Common mode rejection ratio (Rechazo de Modo Común)
DAC Digital to Analog Converter (Conversor Digital Analógico)
DC Direct Current (Corriente Directa)
DIP Dual in-line package (Empaquetado de doble hilera)
DMA Direct Memory Access (Acceso directo a Memoria)
EMG Electromyography (Electromiografía)
EMI Electromagnetic Interference (Interferencia Electromagnética)
FPU Floating Point Unit (Unidad de Punto Flotante)
IDE Integrated Development Environment (Ambiente de desarrollo integrado)
IC Integrated Circuit (Circuito Integrado)
IIR Infinite Impulse Response (Respuesta al impulso Infinita)
INA Instrumentation Amplifier (Amplificador de Instrumentación)
LSB Less Significant Bit (Bit menos Significativo)
MSB Most Significant Bit (Bit más Significativo)
MUAP Motor Unit Action Potential (Potencial de Acción de la Unidad Motora)
MU Motor Unit (Unidad Motora)
PCB Printed Circuit Board (Placa de Circuito Impreso)
RAM RandomAccess Memory (Memoria de Acceso Aleatorio)
SEMG Surface Electromyography (Electromiografía Superficial)
SMD Surface Mount Device (Dispositivo de Montaje Superficial)
SNC Sistema Nervioso Central
SNP Sistema Nervioso Periférico
SOIC Small Outline Integrated Circuit
USART Universal Synchronous/Asynchronous Receiver Transmitter
USB Universal Serial Bus (Bus Universal Serie)
VCM Voltaje de Modo Común

Capítulo 1

Proyecto y desarrollo

1.1 Objetivos del proyecto

Desarrollar un dispositivo prototipo que permita la adquisición de señales electromiográficas. Dichas señales eléctricas son adquiridas en los músculos esqueléticos, originadas en el sistema nervioso durante la contracción muscular.

Utilizar técnicas no invasivas de medición y contar con dos canales independientes que permitan la adquisición simultánea de señales provenientes de músculos antagonistas.

Digitalizar y enviar la información a una PC donde el usuario podrá visualizar las señales.

Desarrollar un software que permita analizar los datos como parte del sistema.

1.2 Introducción

La electromiografía (**EMG**) es la técnica que registra la actividad eléctrica producida por los músculos esqueléticos, la cual es controlada por el sistema nervioso y se produce durante la contracción muscular. La señal representa las propiedades anatómicas y fisiológicas del músculo. Para entender las bases en las cuales se sustenta la electromiografía es necesario dar un pantallazo general de los procesos biológicos y las partes del cuerpo que están involucradas en la motricidad.

El sistema nervioso es el conjunto de órganos y estructuras de control e información del cuerpo humano. Cumple con tres grandes funciones, la *función sensitiva* que se refiere a la capacidad de recibir los estímulos (internos y externos), la *función integradora* se encarga de analizar dichos estímulos, almacenar la información e impulsar una decisión apropiada. Por último, la *función motora* que es la respuesta a los estímulos a través de un movimiento muscular, una secreción de una glándula, etc.

Está constituido por células altamente especializadas conocidas como neuronas las cuales son capaces de recibir, procesar y transmitir información a través de señales químicas y eléctricas. Se comunican con otras neuronas mediante un proceso conocido como sinapsis,

La estructura principal de esta célula está conformada por el cuerpo, conocido como *soma*; una o varias prolongaciones cortas que generalmente transmiten impulsos hacia el soma celular, denominadas *dendritas*; y una prolongación larga, denominada *axón*, que conduce los impulsos desde el soma hacia otra neurona, músculo, glándula, y otros efectores.

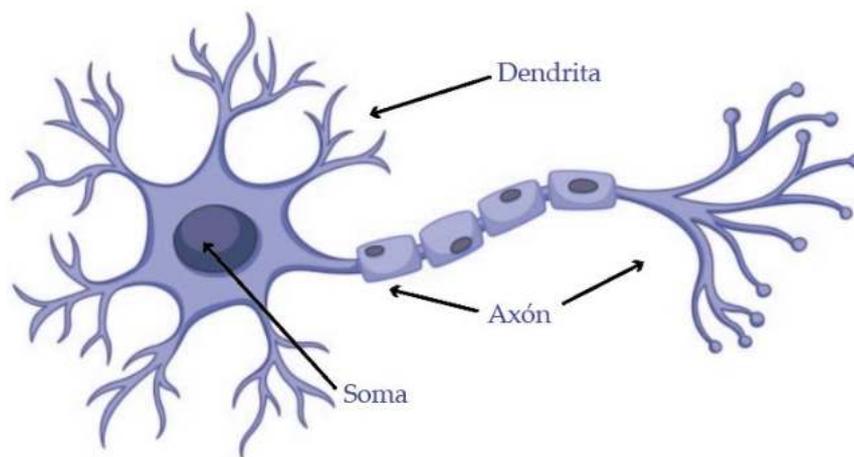


Figura 1.1

El sistema nervioso se puede dividir en *sistema nervioso central (SNC)* y *sistema nervioso periférico (SNP)*. El **SNC** es la unidad de procesamiento del cuerpo humano a donde arriba la información del entorno y de donde salen las órdenes hacia los efectores. Está constituido por el encéfalo y la espina dorsal. El encéfalo está constituido por el cerebro, el cerebelo y el tronco del encéfalo. La médula espinal es un cordón nervioso protegido por la columna vertebral y sirve para comunicar el encéfalo con el resto del cuerpo.

El **SNP** conecta el **SNC** con las diferentes partes del cuerpo, lleva la información hacia el **SNC** y es a través del cual salen las órdenes desde el sistema nervioso central a la periferia (zonas distales del organismo).

Las estructuras fundamentales del **SNP** son dos: los nervios y los ganglios. Los nervios son estructuras conductoras de impulsos nerviosos. Están formados por un conjunto de axones agrupados, cada uno de los cuales procede de una neurona. Pueden ser motores o sensitivos, pero la mayor parte son mixtos y contienen tanto fibras sensitivas como motoras. Se originan en la médula espinal

o parten directamente del encéfalo. Los ganglios son agregados celulares que forman parte del sistema inmunitario [2].

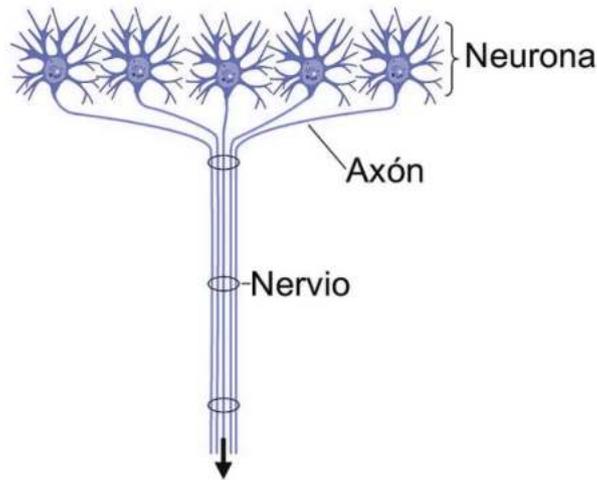


Figura 1.0-2 Esquema en el que se muestra la formación de un nervio a partir de los axones procedentes de varias neuronas

Cuando el axón se proyecta hacia un músculo o glándula, la célula es denominada motoneurona o neurona motora. Las neuronas motoras son, por tanto, eferentes. La unidad de control funcional y estructural del músculo esquelético es la unidad motora (**MU**, por *motor unit*). Corresponde a un sistema formado por una neurona motora y las fibras musculares que ella inerva.

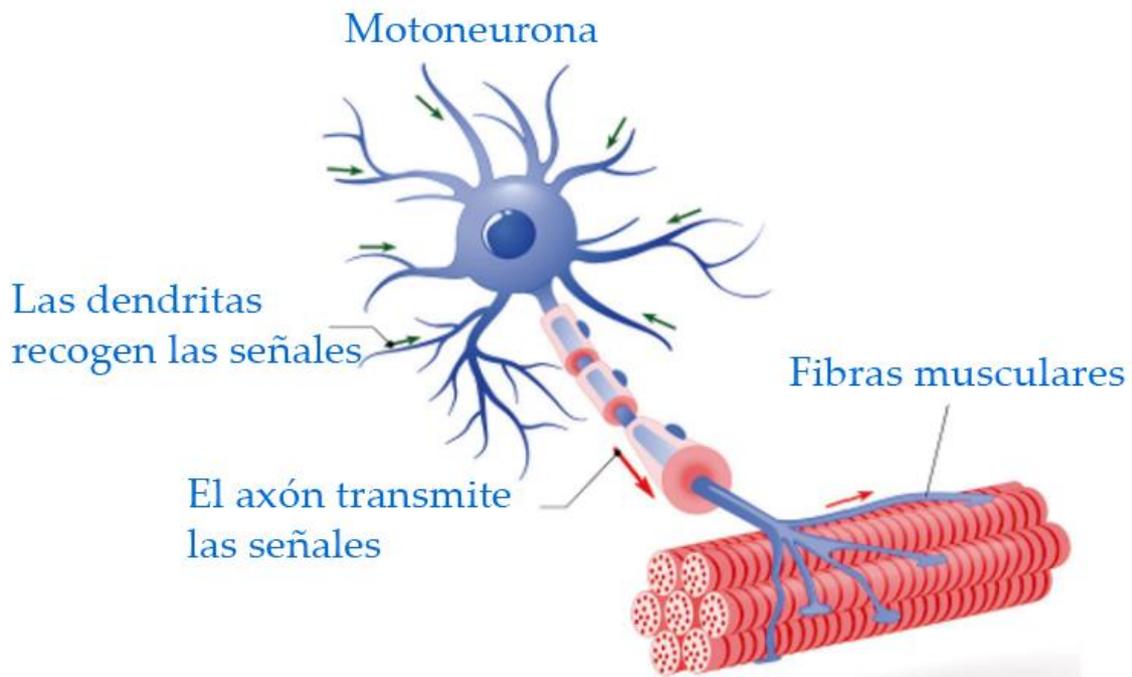


Figura 1.0-3 Unidad Motora

Para producir un movimiento voluntario el **SNC** envía la información a lo largo de los nervios en la forma de una serie de descargas eléctricas portando información. Cuando la señal llega a la unidad motora la misma genera lo que se conoce como potencial de acción que activa todas las fibras musculares asociadas a la neurona motora.

El potencial de acción es una onda de descarga eléctrica que viaja a lo largo de la membrana celular modificando su distribución de carga eléctrica. Siempre hay una diferencia de potencial o un potencial de membrana entre la parte interna y la parte externa de la misma (por lo general de -70 mV). Cuando una neurona recibe un estímulo el potencial de membrana decrece (se vuelve menos negativo) mediante el intercambio de iones produciéndose lo que se conoce como despolarización. Si la despolarización llega a un determinado potencial de umbral, se genera un potencial de acción (liberación de neurotransmisores que estimulan otras células o músculos). A continuación, se produce la repolarización de la membrana y luego la hiperpolarización hasta llegar al estado de reposo para aguardar otro ciclo. Ver figura 1.4

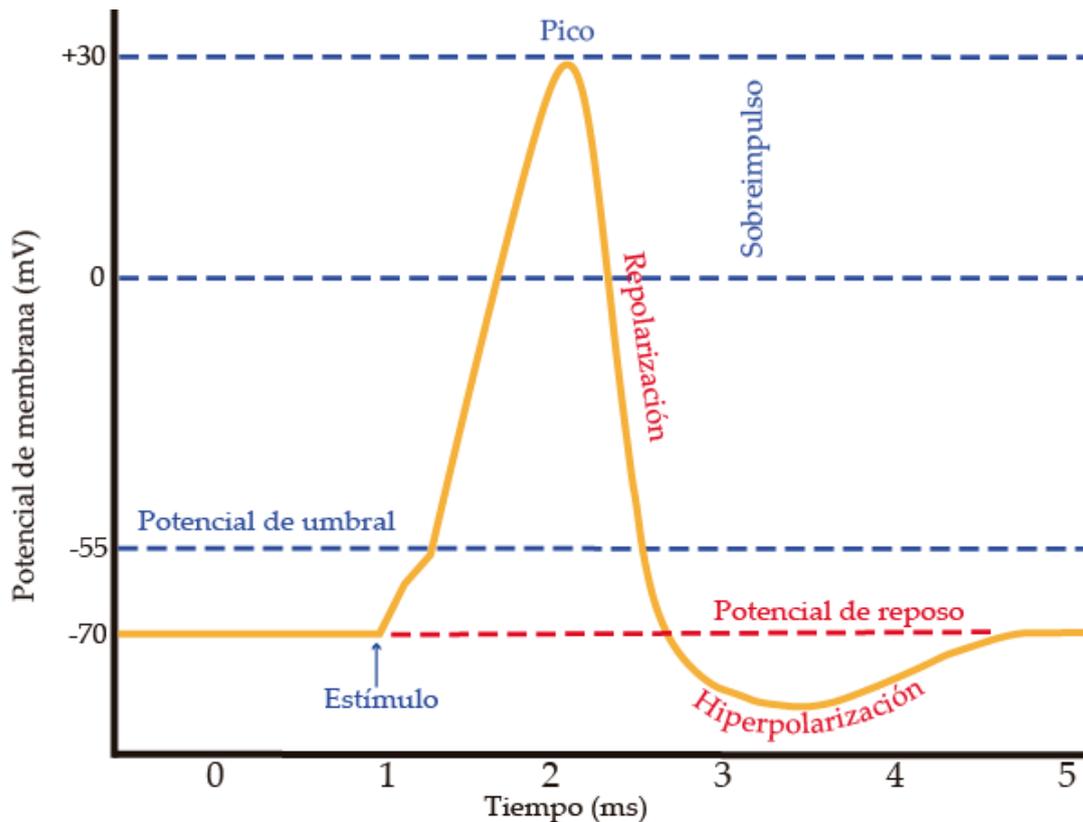


Figura 1. 4 Diagrama temporal de activación de una motoneurona cuando se ejecuta una acción

El número de fibras por **MU** puede llegar a varios cientos; los músculos que controlan los movimientos finos (dedos, ojos) tienen **MU** pequeñas. Las fibras musculares de una **MU** están ampliamente repartidas por todo el músculo, por tanto, la estimulación de una única unidad motora origina una débil contracción de todo el músculo. Cuando se requiere un esfuerzo grande la cantidad de unidades motoras reclutadas y por ende la cantidad de fibras será mayor. La suma de todos los potenciales de acción (actividad eléctrica) es llamada "motor unit action potential" (**MUAP**) y esto es lo que se evalúa en la **EMG**.

1.3 Características de las señales de EMG

Se puede considerar que la amplitud de una señal de **EMG** es de naturaleza aleatoria y puede ser aproximada a una función con distribución de probabilidad Gaussiana [4]. Las amplitudes varían de 0 a 10 mV (pico a pico). El ancho de banda útil de la señal está limitado a un rango de frecuencias entre 0 y 500 Hz con máximo contenido espectral entre 50 – 150 Hz (Figura 1.5).

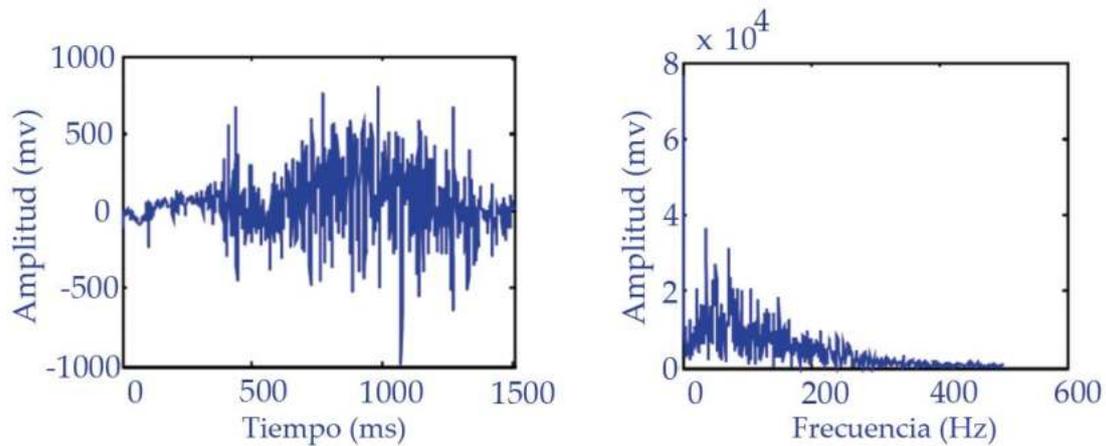


Figura 1. 5 Representación de señal de EMG en el dominio temporal y frecuencial.

1.4 Medición práctica de EMG

La actividad bioeléctrica dentro del músculo de un cuerpo humano es detectada con la ayuda de electrodos **EMG** [2], se busca obtener información acerca de la intensidad y duración de la misma. La señal recogida por los electrodos es amplificada, filtrada y digitalizada para su análisis y procesamiento.

En el registro de la señal se observa la suma de los aportes de todos los potenciales de acción de las unidades motoras. Estos potenciales como ya se ha mencionado cuentan con una fase positiva seguida de una fase negativa. Debido a esto se pueden producir cancelaciones entre dos unidades motoras, lo que enmascara la existencia real de los potenciales de acción. Entre más unidades se activan más cancelaciones se producirán.

La señal se adquiere a través de la técnica de amplificación diferencial. La actividad eléctrica es recogida por el par de electrodos colocados sobre el músculo. Dado que los mismos están posicionados en lugares distintos cada uno obtendrá una versión distinta de la señal, la circuitería restará dichas señales obteniendo como resultado la señal de EMG. Las señales están referenciadas a un potencial (en este caso electrodo de referencia) que actúa como masa de las mismas.

El amplificador diferencial debe tener una alta impedancia de entrada y una muy baja impedancia de salida [9]. En la figura 1.0-6 se observa el esquema simplificado de conexionado de un amplificador de SEMG.

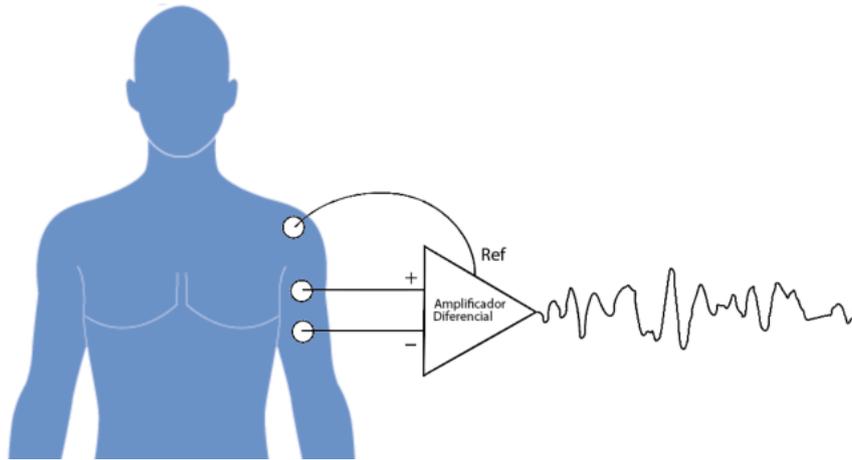


Figura 1.0-6 Esquema simplificado de conexión de un amplificador de SEMG

1.5 Amplificador de instrumentación

Un amplificador de instrumentación (**INA**) es un tipo especial de amplificador lineal de entrada diferencial. Utilizado para la amplificación precisa de la diferencia entre dos (a menudo pequeños) voltajes, que en general se encuentran en presencia de voltajes mucho más grandes. Está formado por un par diferencial (usualmente de alta impedancia) de terminales de entrada, conectados a las fuentes V_{in1} y V_{in2} ; una ganancia bien definida de modo diferencial A_{DM} ; y un voltaje de salida V_{out} que responde a la siguiente relación [5]:

$$V_{out} = A_{DM}(V_{in1} - V_{in2})$$

El tipo más común de **INA** es el basado en la configuración de tres amplificadores operacionales mostrados en la figura 1.0-7

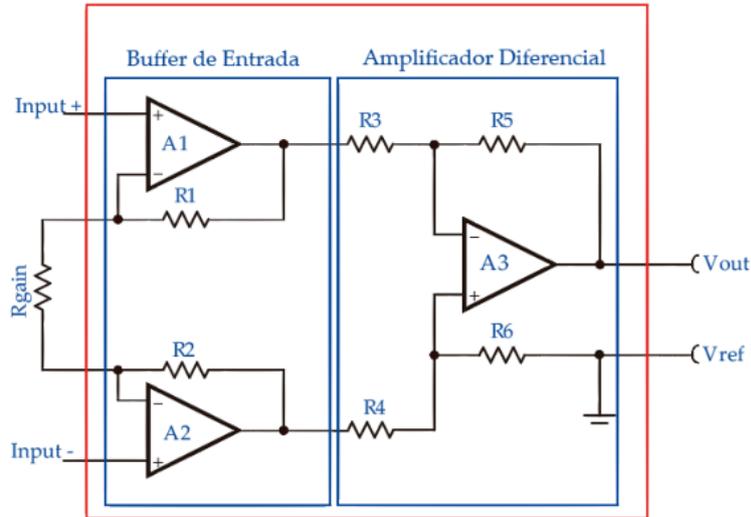


Figura 1. 7 Esquema básico de un amplificador de instrumentación

Esta configuración puede ser armada de forma discreta con operacionales comerciales o alternativamente usar un circuito integrado **INA** que además de ahorrar espacio en el diseño, reducirá los errores debido a que posee un alto rechazo al modo común (**CMRR**) [6]. Cuenta con una primera etapa separadora de muy alta impedancia donde con solo una resistencia (R_{gain} en la figura 1.7) se puede fijar la ganancia total del amplificador. La segunda etapa es el amplificador diferencial, es aquí donde el amplificador rechaza el **VCM** sustrayendo las señales que entran por el par diferencial.

En un diseño discreto, R_3 y R_4 deberían ser iguales, así como R_5 y R_6 , lo que implica conseguir resistencias discretas con mínima dispersión en sus valores; estas resistencias determinarán la ganancia. En un **INA**, la ganancia es seteada mediante el resistor externo R_{gain} , para ello $R_3 = R_4 = R_5 = R_6$, sumado al hecho que se encuentran todas integradas en un mismo componente, de manera que la ganancia de la etapa diferencial es $1 V/V$.

$$G_{diff} = \frac{R_4}{R_3} = 1$$

Quedando entonces determinada la ganancia total del **INA** por la ecuación:

$$G_{INA} = \frac{R_4}{R_3} + \frac{2 \times R_1}{R_{gain}} = 1 + \frac{2 \times R_1}{R_{gain}}$$

Como ya se ha mencionado las señales de **EMG** son en general varios órdenes de magnitud más pequeñas que la interferencia producida por la red domiciliaria la cual es captada por los electrodos colocados en la superficie de la piel. Cualquier señal generada en lejanías de los puntos de medición aparecen como señales comunes, mientras que las señales en la vecindad inmediata de la superficie de detección serán distintas y por ende serán amplificadas [4]. Si en cada entrada tenemos dos señales contaminadas con ruido en modo común:

$$V_{in1} = V_1 + V_{cm}$$

$$V_{in2} = V_2 + V_{cm}$$

Aplicando la ecuación (1) a la salida tendremos:

$$V_{out} = A_{DM}(V_{in1} - V_{in2}) = A_{DM}(V_1 + V_{cm} - V_2 - V_{cm})$$

$$V_{out} = A_{DM}(V_1 - V_2)$$

Eliminando así el ruido de modo común.

1.6 Electrodo

Un electrodo es un conductor eléctrico utilizado para hacer contacto con una parte no metálica de un circuito, en este caso la piel del sujeto de prueba. Los tipos más comunes de electrodos utilizados para el registro electromiográfico son dos: superficiales (o electrodos de contacto) y electrodos intramusculares (de aguja o electrodos de cable fino). La electromiografía superficial (**SEMG**) es el método más común de medición dado que es no invasivo y puede ser llevado a cabo por personal no médico, con riesgos mínimos sobre el paciente. Los electrodos de contacto cuentan también con varias limitaciones. Uno de los principales problemas es el Crosstalk con otros músculos. Además, su posición debe mantenerse estable sobre la piel, de lo contrario, la señal sufrirá distorsiones.

Existen dos tipos principales de electrodos superficiales para **EMG**, con gel o secos. Los primeros contienen una sustancia electrolítica gelatinosa que auspicia

de interfaz entre la piel y los electrodos. En la mayoría de las aplicaciones se utiliza un compuesto de plata-cloruro de plata para la junta metálica del electrodo. Dada la disponibilidad y bajo costo este es el tipo de electrodo seleccionado.

Posicionamiento óptimo de los electrodos

Si se desea obtener los mejores resultados de una **SEMG**, es necesario una apropiada comprensión del músculo del cual se extraerán las señales. Adicionalmente una buena preparación de la superficie de la piel ayudará a la obtención de resultados aceptables reduciendo considerablemente la impedancia de esta.

La posición y orientación en la cual se colocan los electrodos con respecto al músculo es importante [3]. Los electrodos deben ser colocados entre el punto motor ¹(o zona de inervación) y la inserción del tendón o entre dos puntos motores, a lo largo de la línea longitudinal media del músculo alineados de forma paralela a las fibras musculares [4].



Figura 1.0-8 Posicionamiento óptimo de los electrodos sobre el músculo

¹ Lugar anatómico en el que el nervio entra en el músculo [3]

Capítulo 2

Ruido asociado a la medición de SEMG

2.1 Fuentes de ruido

Existen varias fuentes de ruidos que afectan al registro de las señales, a continuación, se citarán las más importantes.

1. **Ruido propio del equipamiento electrónico de registro:** todo equipamiento electrónico genera ruido eléctrico. Este ruido tiene componentes frecuenciales en el rango que va desde 0 *Hz* a varios *KHz*. No puede ser eliminado, pero puede ser reducido utilizando componentes de calidad y prestando especial cuidado al diseño y construcción del circuito. [5]
2. **Ruido ambiente:** este ruido proviene de fuentes de radiación electromagnéticas, como radio, televisión, red eléctrica, lámparas fluorescentes, etc. El cuerpo humano auspicia como antena receptora de estas señales las cuales son prácticamente imposibles de evitar en casos prácticos. El más preponderante de los antes citados es el ruido debido a la radiación proveniente de los cables de alimentación de la red de suministro eléctrico. Esta radiación a menudo presenta amplitudes de varios órdenes de magnitud mayor que las señales electromiográficas con una frecuencia bien definida (50 *Hz* en Argentina). [5]
3. **Ruido debido al movimiento:** el primero de este tipo se corresponde al movimiento de los electrodos sobre la superficie de la piel, el segundo tipo es el debido al movimiento de los cables de medición que transportan la señal hacia el amplificador. Ambas señales concentran su energía en el rango de frecuencias de 0 a 20 *Hz* [4]
4. **Inestabilidad propia de la señal:** la amplitud de la señal como se mencionó anteriormente es de naturaleza cuasi-aleatoria. Las componentes frecuenciales comprendidas entre 0 y 20 *Hz* son particularmente inestables ya que son afectadas por la tasa de disparo de las unidades motoras [4]

La medición y precisa representación de la señal de **EMG** depende de las propiedades de los electrodos y su interacción con la piel, del diseño del amplificador, de la conversión analógica a digital y del correcto almacenamiento de la señal .

La calidad de la medición es a menudo descrita por la relación entre la señal medida y el ruido indeseado. El objetivo será maximizar la amplitud mientras se minimiza el ruido. La relación señal a ruido se define como el cociente entre la potencia de la señal y la potencia del ruido que la contamina.

$$\frac{S}{N} = \frac{P_{señal}}{P_{ruido}}$$

2.2 Modelado de la interferencia a través del cuerpo

Las capacitancias entre el paciente, la red eléctrica y tierra provoca que una pequeña corriente de interferencia fluya a través del cuerpo. En la figura 2.1 se presenta el modelado de una situación típica de medición.

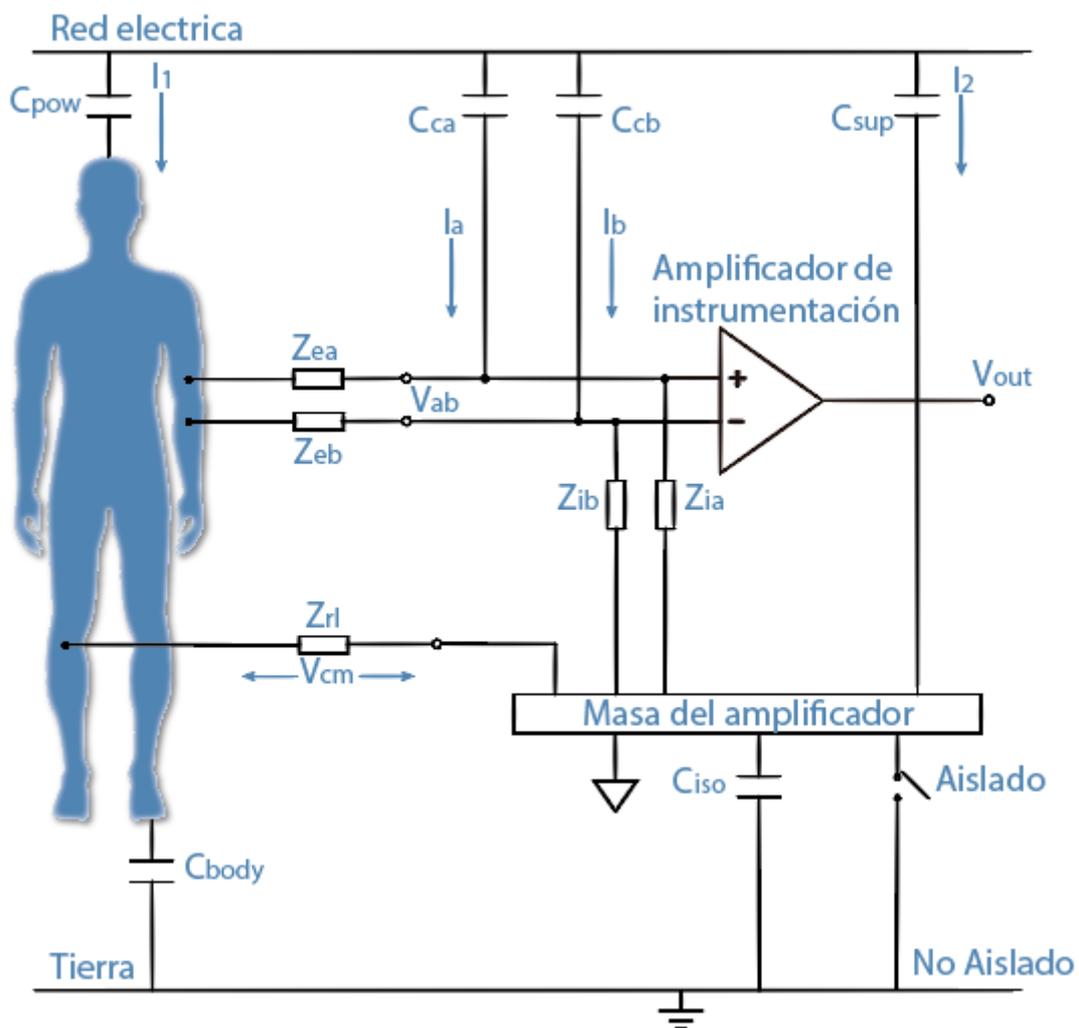


Figura 2.1 Esquema de interferencias

Como valores típicos se pueden asumir $C_{body} = 300pF$ y $C_{pow} = 3pF$ [5]. La corriente I_1 de $0.5 \mu A$ pico a pico fluye desde las líneas de alimentación de la red ($220 V_{RMS}$, $50 Hz$) a través del cuerpo hacia tierra [5]. Debido a que las capacitancias pueden exhibir grandes variaciones con respecto a los valores típicos es posible encontrar corrientes 10 veces más grandes [5].

Esta corriente se divide en parte a través de C_{body} y en parte por Z_{rl} (la impedancia de la interfaz electrodo-piel del electrodo de referencia). La corriente que atraviesa Z_{rl} provoca una diferencia entre el potencial promedio del cuerpo con respecto a la masa del amplificador, esta tensión se conoce como Voltaje de modo común (**VCM**).

Esta tensión será mitigada parcialmente por el rechazo de modo común del amplificador de instrumentación que para circuitos comerciales actuales superan en general los 100 dB. Cuando hay diferencias entre las impedancias que resultan de la combinación de la impedancia de la interfaz electrodo-piel, impedancia de los cables, circuitería de protección (usualmente resistores, capacitores y diodos) Z_{ea} , Z_{eb} la tensión de modo común se convierte en una tensión diferencial (V_{ab}) la cual es amplificada.

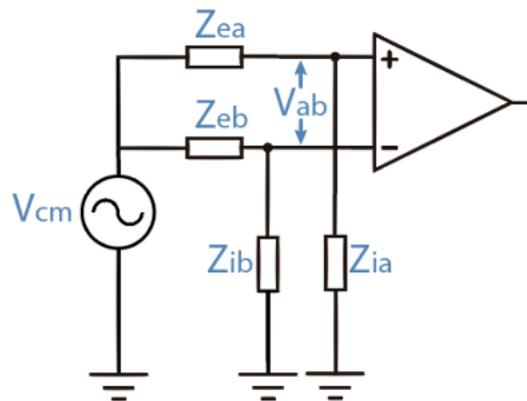


Figura 2.2 Esquema simplificado de la interferencia a través del cuerpo

Este efecto suele conocerse como efecto divisor de potencial y sigue la siguiente relación.

$$V_{ab} = V_{cm} \left(\frac{Z_{ia}}{Z_{ia} + Z_{ea}} - \frac{Z_{ib}}{Z_{ib} + Z_{eb}} \right)$$

Donde $Z_{ia,b}$ son las impedancias de entrada del amplificador.

Debido a las avanzadas tecnologías actuales de producción de circuitos integrados se puede considerar que esencialmente $Z_{ia,b}$ son iguales.

De la ecuación anterior se puede deducir que el potencial generado por el efecto divisor depende principalmente de la tensión de modo común y la diferencia relativa de las impedancias Z_{ia} y Z_{ib} . Se debe entonces realizar un cuidadoso diseño a fin de mantener los valores de impedancias Z_{ea} y Z_{eb} relativamente próximos. A menudo esto no es posible debido a las altas variaciones que presentan los electrodos [6], por lo que será necesario poner el foco en la reducción del **VCM**.

2.3 Reducción del voltaje de modo común

Se presentan dos casos:

- A. La masa del amplificador está conectada a tierra (sin aislación). En este caso la corriente que circula a través de Z_{rl} está determinada principalmente por la capacitancia C_{pow} .
- B. Si el amplificador está aislado de tierra la corriente que circula por Z_{rl} depende de 4 valores de capacidad: C_{pow} , C_{body} , C_{sup} y C_{iso} . Reduciendo estas capacidades reduciremos las corrientes.

La forma más directa de reducir la tensión de modo común se logra alejando al paciente y el dispositivo de las fuentes de interferencia, solución que en la mayoría de los casos prácticos es inviable. Se debe entonces minimizar la impedancia Z_{rl} . Una buena preparación de la superficie de contacto entre la piel y el electrodo contribuirá a la reducción de dicha impedancia. La mejor manera de reducir el **VCM** es con la adición de un circuito "driven right leg" figura 2.3, este circuito activamente reduce el voltaje de modo común logrando atenuaciones del orden de 10 a 50 dB [7].

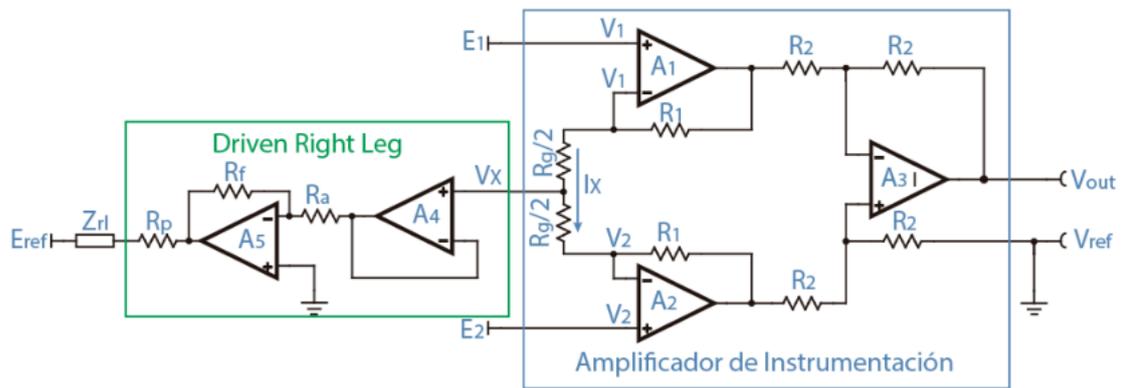


Figura 2.3 Conexión de Driven Right Leg

Desde los electrodos E_1 y E_2 se obtienen las tensiones V_1 y V_2 respectivamente. La tensión V_x queda determinada por:

$$I_x = \frac{V_1 - V_2}{R_g} \quad V_x = V_2 + \frac{V_1 - V_2}{R_g} \frac{R_g}{2} = \frac{V_2 + V_1}{2}$$

Es decir que la tensión en V_x es el promedio de las tensiones en V_1 y V_2 . Si suponemos ahora que en ambos electrodos ingresa la misma tensión (**VCM**):

$$V_x = V_{cm}$$

La tensión V_x es sensada mediante el Buffer (A_4), luego amplificada (A_5) lo que resulta en una tensión de salida:

$$I_a = \frac{V_{cm}}{R_a} \quad I_f = \frac{V_a}{R_f}$$

$$I_f = I_a \rightarrow \frac{V_{cm}}{R_a} = \frac{V_0}{R_f} \rightarrow V_0 = -V_{cm} \frac{R_f}{R_a} = -V_{cm} G$$

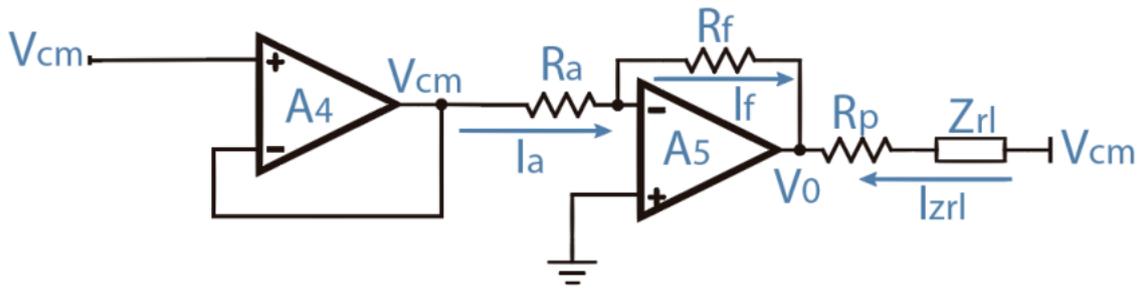


Figura 2.4 Driven Right Leg

Analizando la rama de salida:

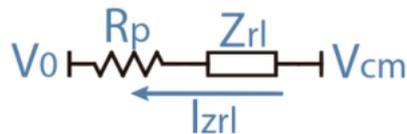


Figura 2.5

$$V_{cm} = V_0 + I_{zrl}(R_p + Z_{rl})$$

$$V_{cm} = -V_{cm}G + I_{zrl}(R_p + Z_{rl})$$

$$V_{cm} = -V_{cm}G + \frac{(R_p + Z_{rl})}{(1 + G)} I_{zrl}$$

De la ecuación anterior se puede deducir que la tensión de modo común se reduce conforme aumenta la ganancia G . De alguna manera se puede interpretar que la función del circuito es la reducción de la impedancia de la interfaz electrodo-piel (Z_{rl}). Si bien la adición de la resistencia R_p a priori pareciera ir en contra de la idea anterior cumple la función de protección del paciente.

Si accidentalmente el paciente quedara expuesto a la red eléctrica la corriente encontraría un camino a través del electrodo de referencia hacia tierra (en el caso de que el amplificador no esté aislado).

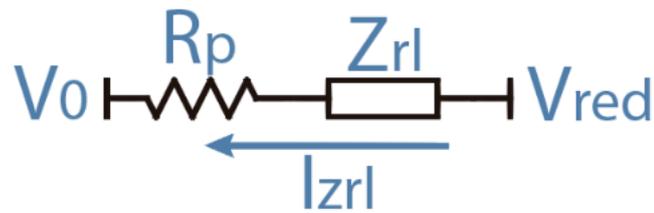


Figura 2.5

Debido a que las entradas estarán al potencial de red, la salida V_0 se encuentra saturada a la tensión DC con la cual se alimenta el amplificador de instrumentación la cual frente a la tensión de red (220 V) puede considerarse despreciable.

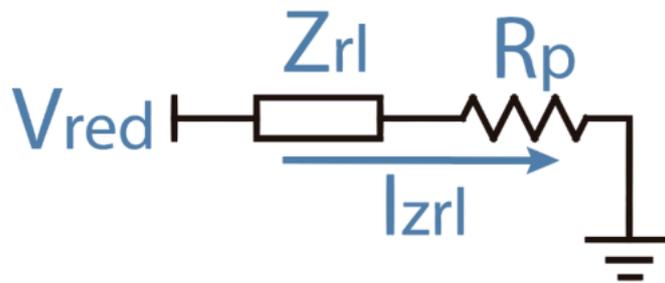


Figura 2.6

Si colocamos allí una resistencia de $390k$ circulará por el cuerpo una corriente aproximada de 0.5 mA , que se corresponde con el umbral de percepción [8]. El umbral de percepción es el valor mínimo de corriente que hace perceptible el paso de esta a través del cuerpo humano.

2.4 Reducción de la interferencia en los cables de medición

Con el objeto de reducir la interferencia electromagnética, los cables cuentan con un mallado metálico, esto provoca un efecto de jaula de Faraday que protege al conductor o conductores centrales. Existen diferentes maneras de conectar el blindaje al equipo.

2.4.1 Blindaje conectado a la masa del equipo

Si conectamos el blindaje de los cables directamente a masa eliminamos parte de las corrientes interferentes en los cables, sin embargo, esto no reduce el nivel total de interferencia debido a que, como contrapartida, la capacidad distribuida de los cables reduce la impedancia de entrada del amplificador aumentando así por efecto divisor el nivel de interferencia.

2.4.2 Guarda

Si inyectamos en el blindaje una copia de la señal que viaja por el conector interior virtualmente no existe capacidad y su contribución a la impedancia de entrada del equipo es prácticamente nula. Por otro lado, el uso de esta técnica implica el agregado de un amplificador adicional por cada conector. Como solución se suele optar por inyectar en todos los blindajes el promedio de las señales de entrada, de esta manera con un solo amplificador es suficiente y el efecto de reducción virtual de la capacidad es más que suficiente para evitar el efecto divisor [5].

Capítulo 3

Diseño de hardware

3.1 Especificación Funcional y Técnica

Requisito Funcional 1

- **Medición de EMG:** el dispositivo debe medir las señales de EMG provenientes de los músculos utilizando electrodos de contacto mediante una arquitectura bipolar (amplificación diferencial). La señal ingresará al dispositivo y será acondicionada según parámetros que son definidos en posteriores requisitos funcionales. Luego la señal debe ser digitalizada y transmitida a una PC por medio de conexión USB o Puerto Serie. La información deberá estar disponible para la visualización y análisis mediante un software de interfaz de usuario que muestre simultáneamente los dos canales de adquisición.

Requisito Funcional 2

- **Arquitectura Doble Canal:** el sistema debe incluir los medios necesarios para la adquisición y acondicionamiento simultáneo de las señales provenientes de dos complejos musculares. Ambos canales contarán con ganancia ajustable. Dado que el requerimiento funcional 1 define una arquitectura bipolar se deberá contar con dos conectores de tipo bipolar (o estéreo) y un tercer conector para conectar el electrodo de referencia.

Requisito Funcional 3

- **Ajuste de Ganancia:** el diseño del dispositivo debe contemplar la adición de dos potenciómetros en la parte frontal de la carcasa que permita regular la ganancia de cada canal.

Requisito Funcional 4

- **Respuesta Plana en la Banda de Interés:** debido a que el contenido espectral de las señales de **EMG** se encuentra concentrado en la

banda que va de 20 Hz a 500 Hz es necesario que cualquier amplificación en dicha zona sea de respuesta plana.

Requisito Funcional 5

- Frecuencia de Muestreo: analizando el contenido frecuencial de las señales de EMG, para obtener una representación adecuada de la señal en el dominio del tiempo, será necesario contar con una frecuencia de muestreo de al menos 2 kHz. Con el fin de no sobrecargar innecesariamente la unidad de procesamiento se define como cota superior una frecuencia de muestreo de 10 kHz.

Requisito Funcional 6

- Aislación del Paciente: para lograr la aislación eléctrica del paciente con respecto a la red domiciliaria el sistema será alimentado con baterías de 9V y la PC utilizada para el registro, visualización y análisis durante las pruebas deberá ser una Notebook desconectada también de la red.

3.2 Diagrama de Bloques

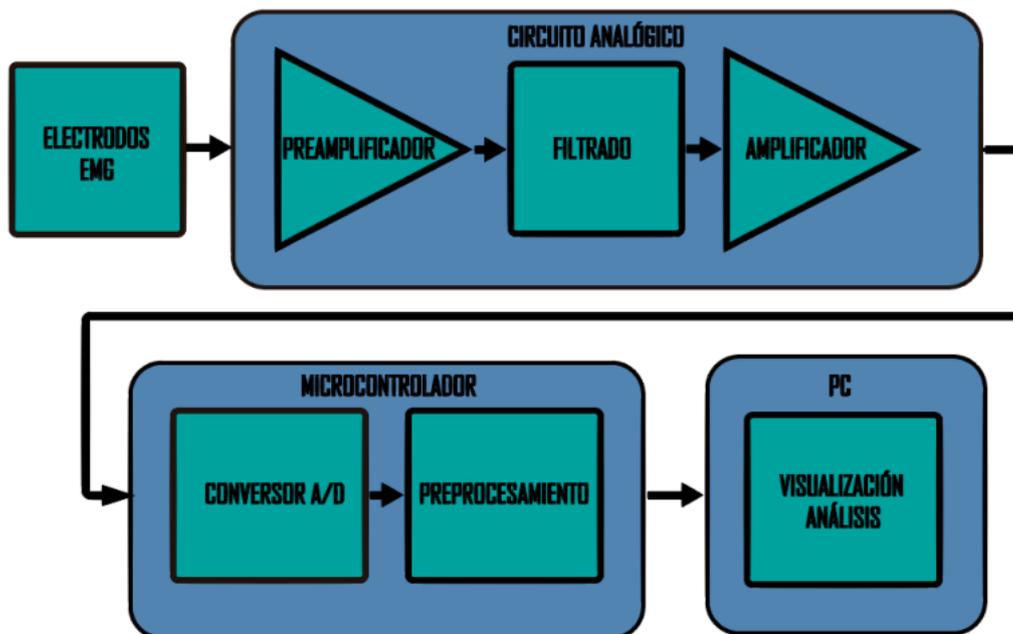


Figura 3.1 Diagrama en bloques completo del sistema.

3.3 Electrodo y cables de interconexión

3.3.1 Electrodo utilizados

Como se mencionó en el capítulo 1 se utilizan como elementos transductores electrodos de contacto de plata/cloruro de plata con adhesivo geloso electrolítico. Su elección se debió a su disponibilidad en el mercado local y prestaciones que lo hacen apto para el presente desarrollo.

El modelo equivalente de la interfaz electrodo piel se muestran en la figura 3.2

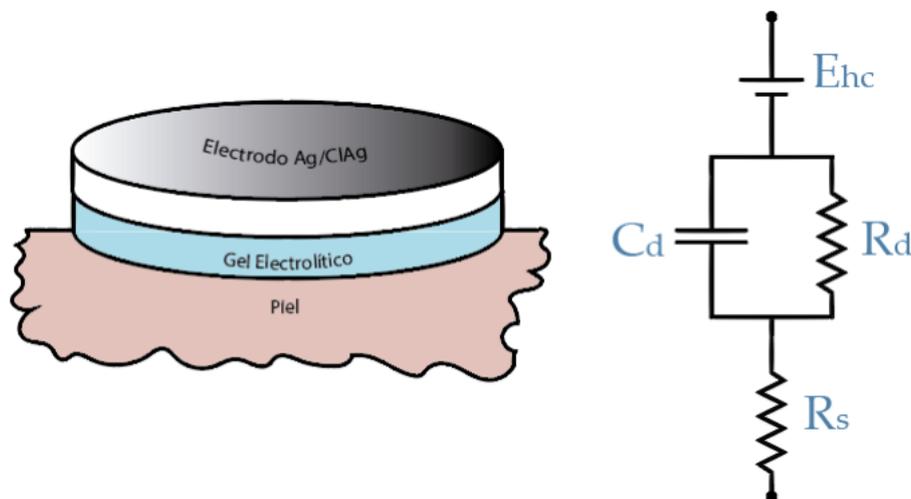


Figura 3.2 Modelo eléctrico equivalente de la interfaz electrodo piel.

El potencial de media celda (E_{hc}) representa la diferencia de potencial entre la piel, el electrolito (gel o sudor) y el electrodo, el cual es el resultado de los iones que residen entre la piel y el electrodo [9]. La capacidad de las cargas alojadas entre el electrodo y la capa de piel es representada por C_d . La resistencia que puede llegar a permitir la transferencia de cargas entre la piel y el electrodo es representada por R_d . La resistencia en serie R_s representa la resistencia del gel electrolítico y el sudor. La resistencia de los tejidos a menudo es muy pequeña comparada con el valor de la impedancia de la interfaz electrodo-piel [9]. Se ha determinado que el valor de impedancia del tejido sano del brazo suele ser menor a 500Ω [9], en contraste con el valor de impedancia de la interfaz electrodo-piel que puede ser tan grande como $1 M\Omega$ [9]. Por lo tanto, se considerará que el valor de la impedancia de la piel estará incluido en R_s .

A continuación, se presentan los valores promedios estimados de los componentes circuitales del modelo equivalente (R_d , R_s y C_d) para tres tipos de electrodos distintos [10]

Tabla 1. Valores de R_d promedios ($k\Omega$).

Electrode Type	Mean Values ($k\Omega$)	$k\Omega/cm^2$
Ag/AgCl	215.82	215.82
Orbital	299.4	187.13
Stainless Steel	3289.4	2130.98

Tabla 2. Valores de C_d promedios (nF).

Electrode Type	Mean Values (nF)	$k\Omega/cm^2$
Ag/AgCl	18.9	18.9
Orbital	9.3	5.2
Stainless Steel	4.9	3.45

Tabla 3. Valores de R_s promedios (Ω).

Electrode Type	Mean Values (Ω)	Ω/cm^2
Ag/AgCl	399.7	399.7
Orbital	626.8	391.8
Stainless Steel	856.4	121.1

3.3.2 Cable de interconexión

Para la interconexión de los electrodos y el equipo de adquisición se utilizará un cable bipolar trenzado y doblemente blindado, modelo TB-9999 de la fábrica Conduplast. Este cable está compuesto por hilos de alambre de cobre electrolítico recocido de alta pureza, aislados en PVC; recubiertos bajo pantalla de foil de aluminio; el conjunto blindado con malla de cobre estañado; envoltura de PVC ignífugo gris.



Figura 3.3 Cables de interconexión

Presenta las siguientes características eléctricas:

Tabla 4. Características del conductor TB-9999

Impedancia Nominal	78 Ω
Capacidad por unidad de longitud	67.9pF/m
Resistencia por unidad de longitud	0,013 Ω /m
Factor de velocidad	0.66

El blindaje proporciona protección contra el acoplamiento del campo eléctrico y el trenzado protege contra el acoplamiento del campo magnético [11].

A baja frecuencia, los blindajes de los cables apantallados multiconductor, en los que el blindaje no es el conductor de retorno de las señales, a menudo se conecta en un solo extremo. Si el blindaje se conecta en los dos extremos, pueden circular corrientes de interferencia electromagnética por el blindaje debido a la posible diferencia de potencial entre las masas de los dos extremos del cable.

La conexión a masa del blindaje del cable en un solo extremo para eliminar el acoplamiento de **EMI** de la línea de red permite, sin embargo, que el cable actúe como una antena a alta frecuencia y sea vulnerable a la captación de **EMI** de alta frecuencia. Los transmisores de radio en AM o FM pueden inducir corrientes de

RF de alta frecuencia en la pantalla del cable. Si la pantalla del cable está conectada a la masa del circuito, estas corrientes de RF podrían entrar en el equipo y podrían causar interferencias. Por lo tanto, la forma correcta de conectar la pantalla del cable a masa, es conectarla al recinto blindado del equipo, no a la masa del circuito. Esta conexión debe tener la impedancia más baja posible y debe ser hecha en la parte exterior del recinto blindado [11].

3.4 Circuito Analógico

3.4.1 Diagrama en bloques

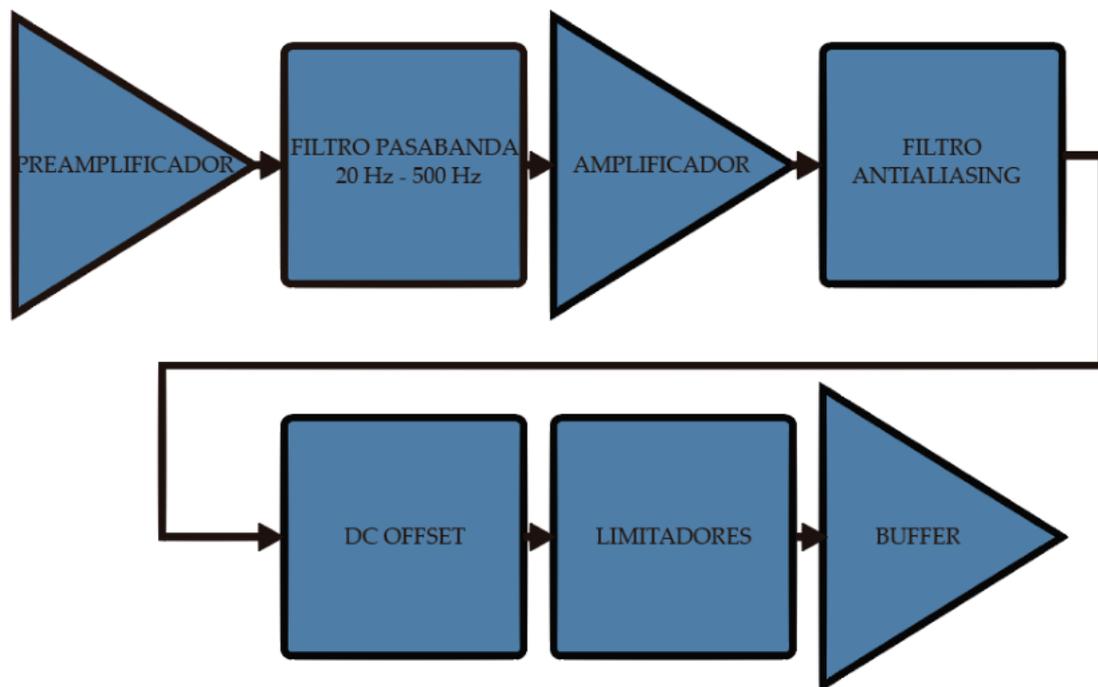


Figura 3.4 Diagrama en bloques del circuito analógico

3.4.2 Preamplificador

Como se ha mencionado en capítulos anteriores, para medir señales bioeléctricas se utilizan amplificadores de instrumentación. Teniendo en cuenta las especificaciones técnicas se optó por el circuito integrado (IC, por *integrated circuit*) INA 2128 de Texas Instruments.

El INA 2128 es un amplificador de instrumentación dual de propósito general de baja potencia, que ofrece excelente precisión. Su pequeño tamaño y diseño versátil basado en 3 operacionales lo hace ideal para un amplio rango de aplicaciones [12]. Como características principales se pueden citar:

1. Baja deriva: 0.5 V/°C máxima.
2. Baja corriente de *bias* de entrada: 5 nA máxima.
3. Alto CMRR: 120 dB mínimo
4. Protección de entrada: Hasta 40V
5. Amplio rango para la alimentación: 2.25V a 18V
6. Baja corriente en estado inactivo: 700 V/IA

El mismo viene tanto en encapsulado **DIP** (*dual in-line package*) como en **SOIC** (*Small Outline Integrated Circuit*) de 16 pines, con el objetivo de ahorrar espacio y lograr un diseño compacto se optó por el modelo **SOIC** que es de montaje superficial.

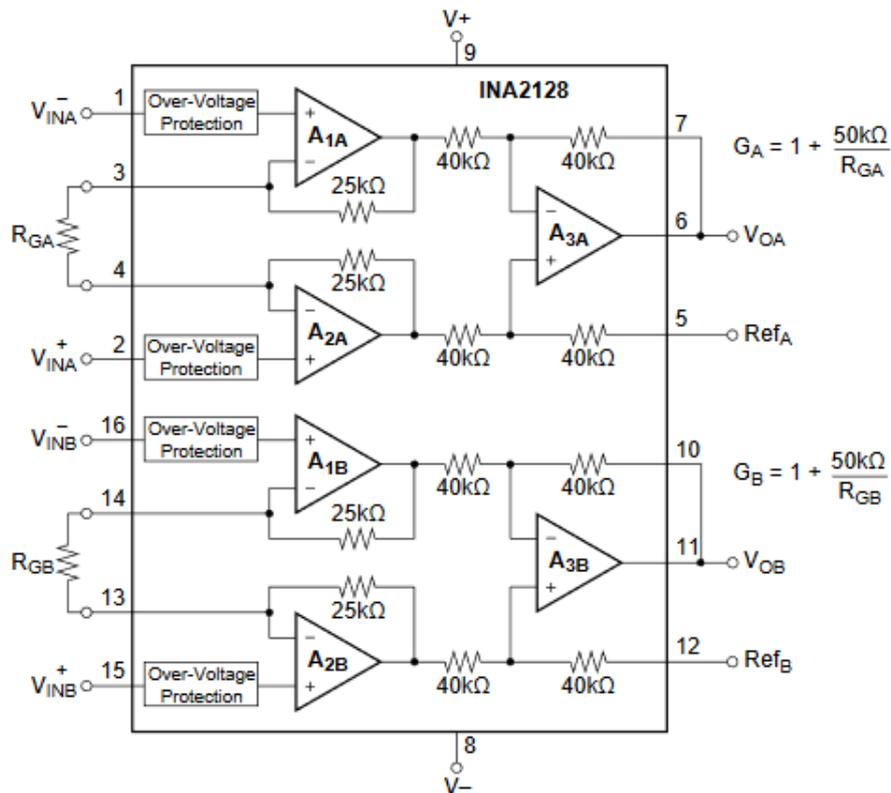


Figura 3.5 INA 2128 esquemático simplificado [12].

Con solo un resistor externo se puede setear la ganancia desde 1 a 10.000 V/V. La señal de salida está referida a la tensión en el terminal de referencia (Ref_A para el primer canal y Ref_B para el restante). La ganancia está determinada por la siguiente relación:

$$G = 1 + \frac{50k\Omega}{R_g}$$

La respuesta del integrado en el dominio frecuencial muestra que el dispositivo es apto para la amplificación de las señales de **EMG** dado que las componentes frecuenciales de las mismas no exceden los 500 Hz (figura 3.5).

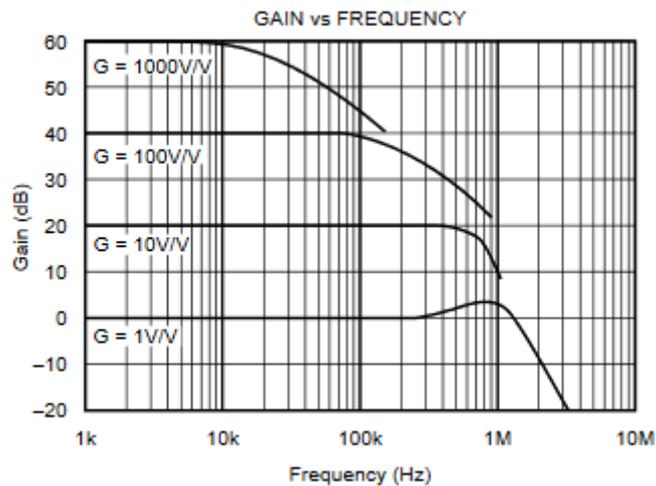


Figura 3.6 Respuesta en frecuencia del INA2128 [12]

Presenta un alto **CMMR** el cual es función de la ganancia y la frecuencia de operación (figura 3.6).

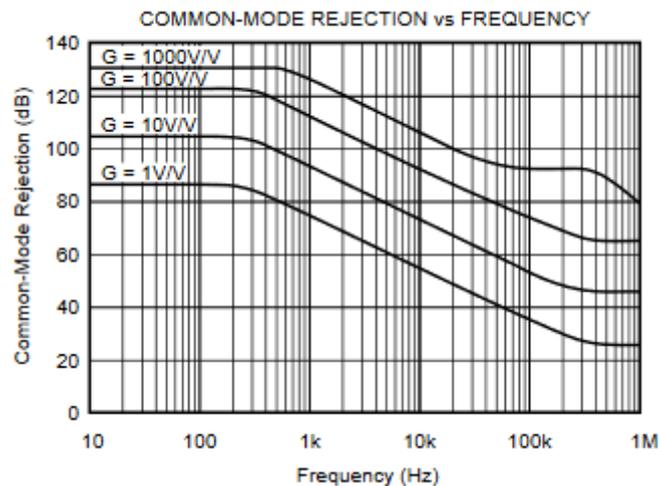


Figura 3.7 Rechazo de modo común del INA2128 [12]

En la figura 3.7 se muestra el esquemático correspondiente al preamplificador de uno de los canales.

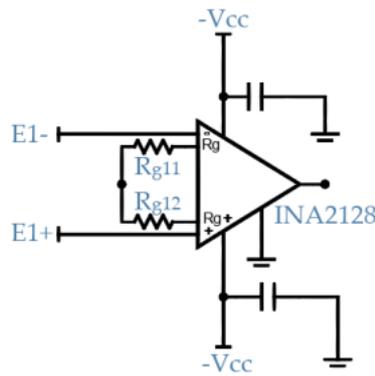


Figura 3.8 Esquemático de un canal correspondiente a la etapa de pre amplificación

La ganancia estará determinada por la suma de las resistencias R_{g11} y R_{g12} . Debido a que la señal bioeléctrica a medir tiene un *offset* de continua, debido al potencial de media celda causado por la interfaz electrodo piel se debe mantener la ganancia a un valor que evite la saturación del equipo. Las señales electromiográficas tienen valores que oscilan entre los 0 y 10 *mV* (ver 1.3), las mismas están montadas sobre el *offset* que cuyo valor típico para electrodos de Ag-AgCl es de 220 *mV* [13]. Se optará por un criterio conservador asumiendo que la suma de las señales antes mencionadas es de 0.5 *V* y considerando además una tensión alimentación de ± 9 *V* DC.

$$G_{max} = \frac{9 \text{ V}}{0.5 \text{ V}} = 18$$

3.4.2.1 Shield Drive

Debido a la adición de los cables de interconexión blindados para proteger las señales a medir de interferencias en el medio, una capacidad parásita aparece entre el blindaje metálico y los conectores interiores que degrada el **CMRR** debido al efecto divisor. Para reducir esta capacidad se lleva el blindaje interior del cable a un potencial que será el promedio de las tensiones observadas en los terminales de entrada del amplificador de instrumentación (V_m) mediante un buffer implementado con el IC OPA2604 el cual es estable a ganancia unitaria [14]. La figura 3.8 muestra el esquemático para uno de los canales.

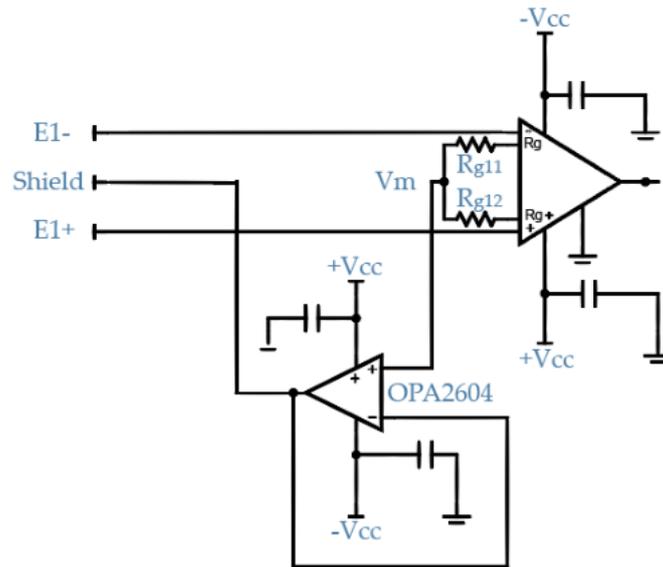


Figura 3.9 Esquemático shield drive para uno de los canales.

Con esta configuración se logra una reducción virtual de la capacidad parásita debido a que la diferencia de potencial entre los conectores que llevan las señales y la malla de aislamiento es prácticamente nula y por consiguiente no circulan corrientes de fuga (ver 2.4.2).

3.4.2.2 Driven Right Leg

Como se detalló en el capítulo 2, la adición de una realimentación conocida como *Driven Right Leg* reduce activamente la tensión de modo común. El circuito fue implementado con un amplificador operacional OPA2604. La figura 3.9 muestra el esquemático de la implementación.

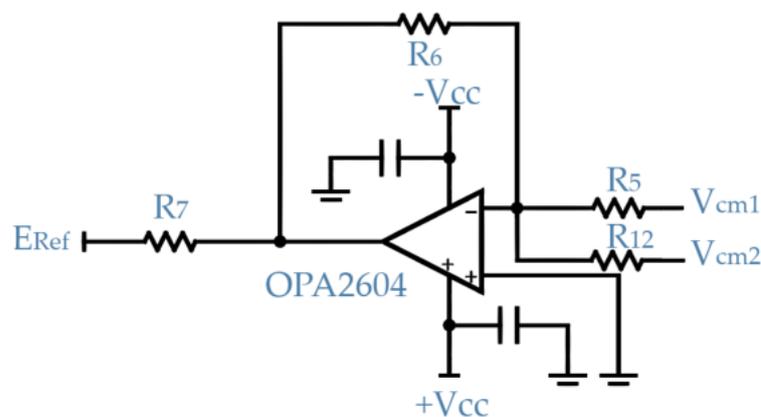


Figura 3.10 Esquemático de la implementación del Driven Right Leg.

3.4.3 Filtro Pasabanda

Para la segunda etapa se implementó un filtro pasabanda pasivo con banda de paso entre 20 Hz y 500 Hz con el propósito de eliminar señales no deseadas por fuera de la banda de interés.

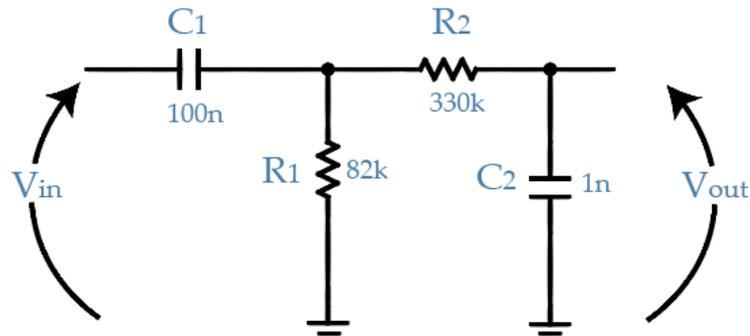


Figura 3.11 Diseño del filtro pasabanda

En la figura 3.12 se muestra la función transferencia del sistema en un diagrama de Bode de amplitud.

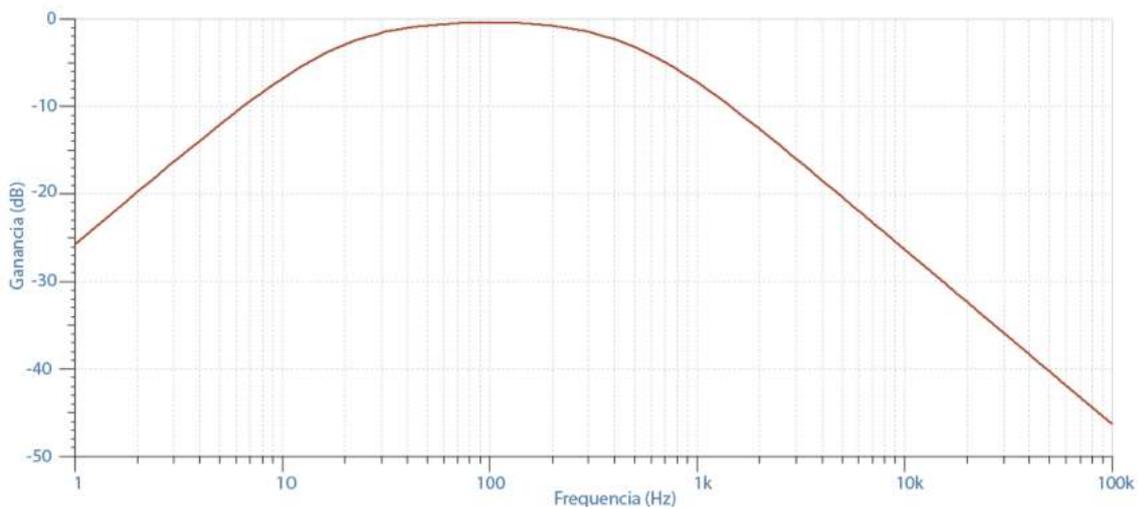


Figura 3.12 Diagrama de Bode del filtro pasabanda

3.4.4 Amplificador y Filtro Antialiasing

Esta etapa se diseñó para proporcionar la ganancia necesaria para aprovechar el rango dinámico ADC a la vez que auspicia como filtro *antialiasing*. Se optó por

un amplificador de ganancia variable con frecuencia de corte de 500 Hz. Para su implementación se utilizó el IC TL074.

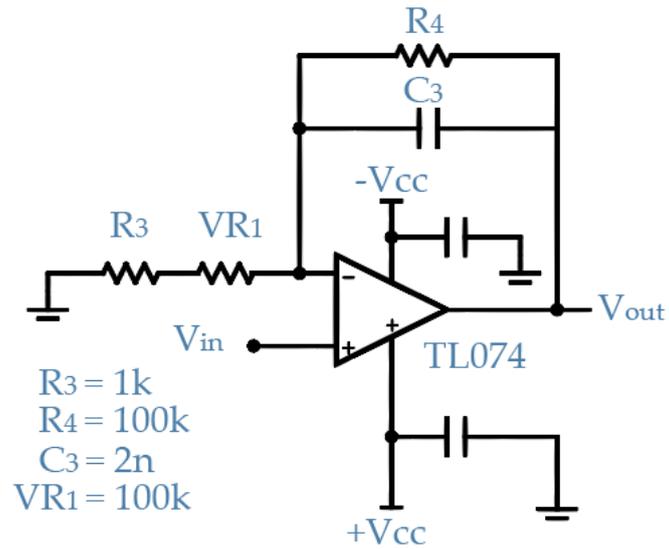


Figura 3.13 Amplificador y filtro antialiasing activo

En la figura 3.14 se muestra el diagrama de bode de amplitud de esta etapa para los valores máximo, mínimo y un valor intermedio de ganancia. La transferencia presenta una ganancia plana dentro de la banda de interés con un polo en 500 Hz.

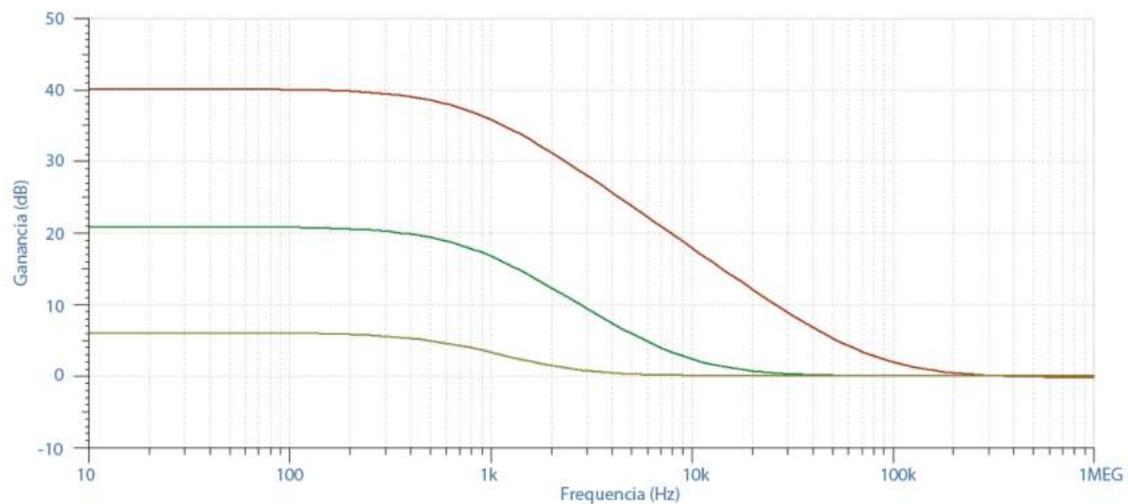


Figura 3.14 Diagrama de Bode del amplificador y filtro antialiasing para diferentes condiciones de ganancia

3.4.5 DC Offset

Esta etapa es la encargada de adicionar una componente de continua en la señal electromiográfica amplificada para que su valor medio de tensión coincida con la del ADC. Para ello se utiliza el circuito de la figura 3.15.

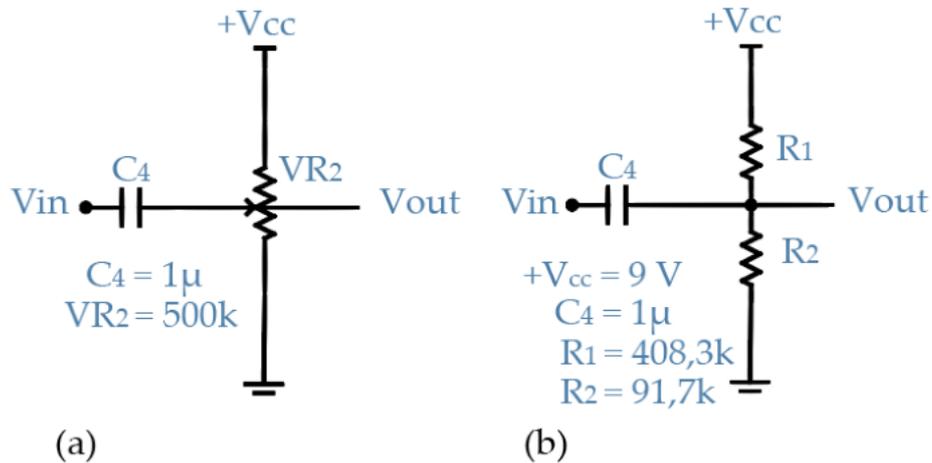


Figura 3.15 (a) implementación del circuito que proporciona el DC offset. (b) Condiciones de trabajo para el diseño actual

Esta configuración a la vez que sirve para ajustar el DC offset auspicia de filtro pasa altos por lo que se tuvo en cuenta en el diseño que la frecuencia de corte esté lo suficientemente baja para que no modifique las características de la señal. El conversor analógico digital admite tensiones entre 0 V y 3.3 V. Se utiliza en el diseño un potenciómetro de 500 k Ω y un capacitor de 1 μ F. Si se ajusta el preset del potenciómetro y se ajusta la tensión DC en 1.65 V el circuito toma la forma de la figura [3.14.b]. La función transferencia para este caso se muestra en la figura 3.16.

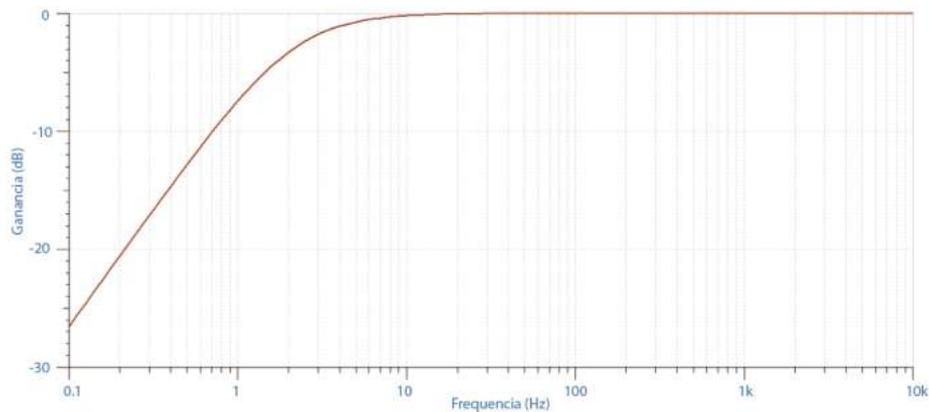


Figura 3.16 Respuesta en frecuencia del DC offset para las condiciones de operación

3.4.6 Limitadores

Con la finalidad de proteger las entradas del ADC se implementó una etapa de limitadores que previene que la señal de salida supere las tensiones máxima y mínima admisibles por el conversor. La figura 3.17 muestra el esquemático correspondiente al bloque de limitadores.

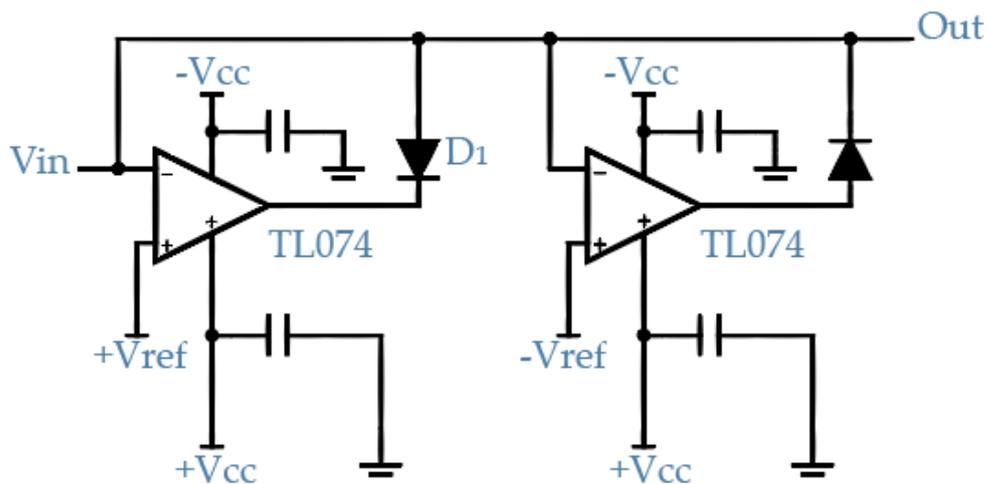
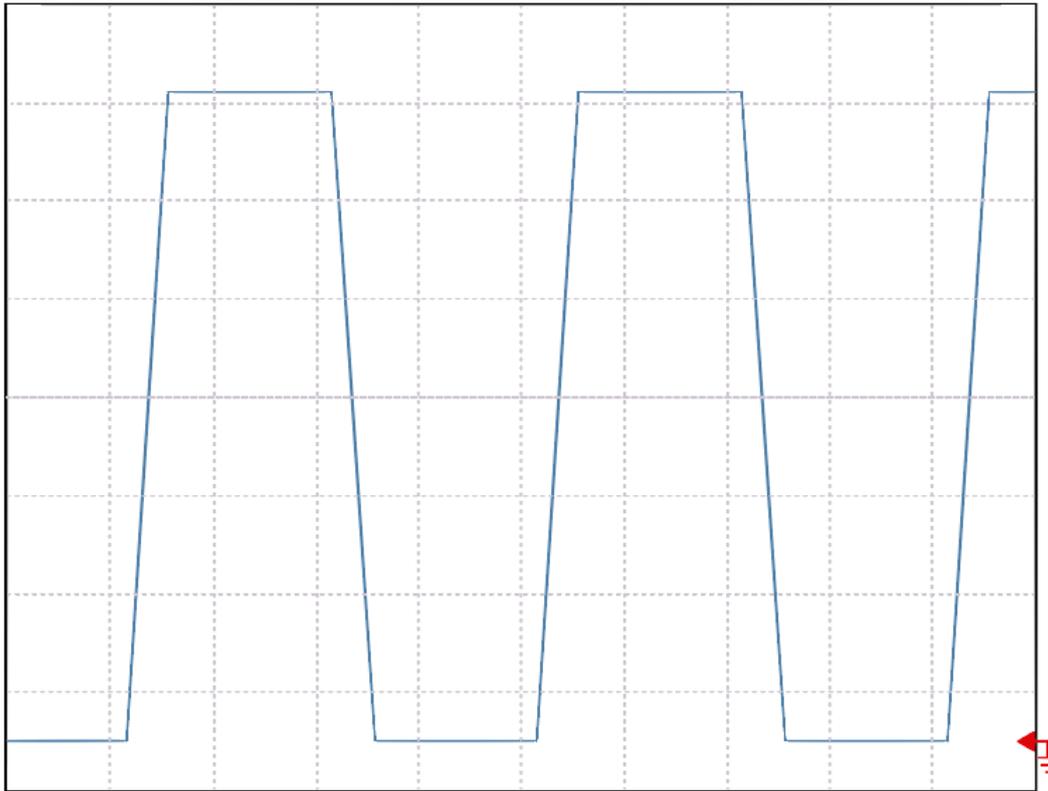


Figura 3.17 Esquemático del circuito limitador

Este circuito limitador está implementado con el IC TL074 que permite el control preciso de los voltajes máximos y mínimos admisibles. Las cotas son definidas por las tensiones de referencia $+V_{ref}$ y $-V_{ref}$. Cuando la tensión de entrada V_{in} es menor que la referencia el diodo D_1 queda polarizado en inversa, por lo que la señal sigue su camino por el riel superior sin ser alterada hasta V_{out} . En cambio, si la tensión de entrada supera la referencia positiva el diodo queda polarizado en directa y cierra el lazo y convierte el circuito en un seguidor de ganancia unitaria de $+V_{ref}$. El segundo operacional realiza la tarea complementaria impidiendo que la señal de entrada caiga por debajo de $-V_{ref}$. En la figura 3.18 se observa la respuesta del temporal del circuito limitador ante una entrada de tipo senoidal con una tensión pico mayor a V_{ref} .



Vertical: 500 mV/Div Horizontal: 5 ms/Div

Figura 3.18 Respuesta temporal de los limitadores cuando a su entrada ingresa una senoidal que supera los niveles de referencia.

3.4.6 Buffer

Debido a que ciertos [ADC](#) deben ser cargados con bajas impedancias para funcionar de forma adecuada (ver 3.5.1) se agregó un Buffer separador. Este circuito no es más que un seguidor de ganancia unitaria con una impedancia de salida determinada por el amplificador operacional la cual es muy baja [15]. La implementación se realizó con un amplificador operacional TL074.

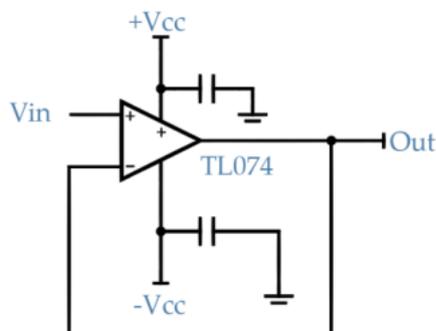
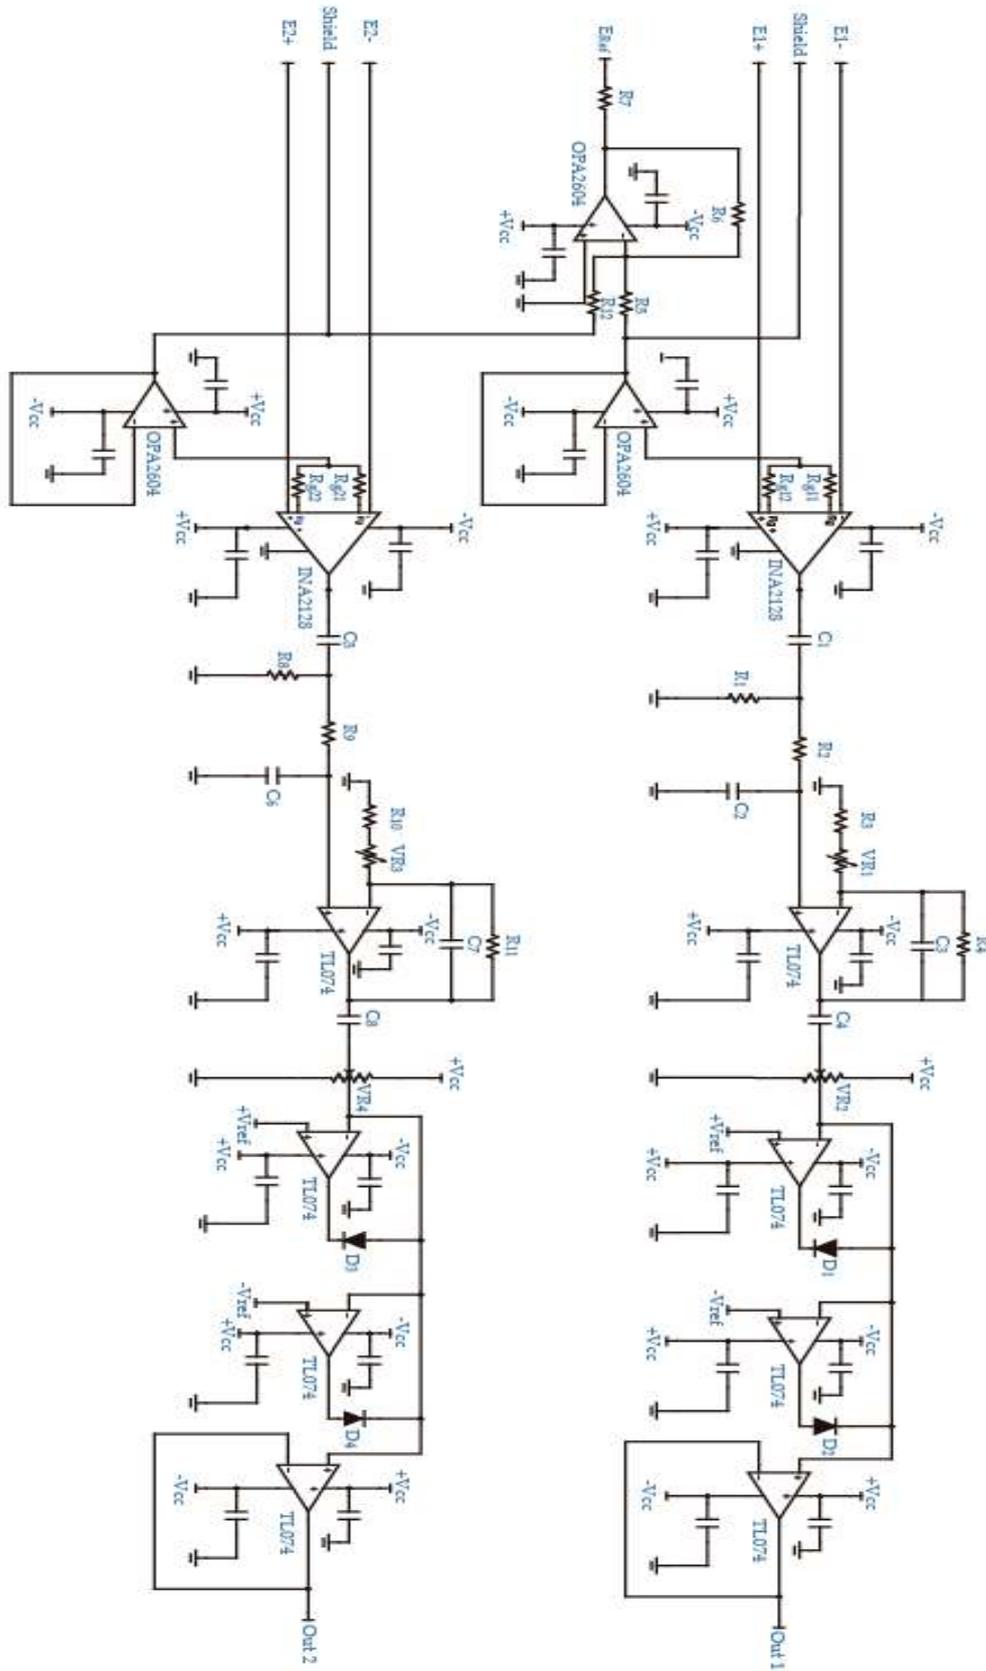


Figura 3.19 Implementación del buffer con un IC TL074

3.4.7 Esquemático completo



3.4.8 Alimentación del circuito

Para alimentar el circuito se utilizan dos baterías de 9 V conectadas según el diagrama de la figura 3.20, obteniendo así los valores de tensión de alimentación requeridos, +9V, -9V y 0V.



Figura 3.20 Diagrama de conexión de baterías de alimentación

3.4.9 Selección de componentes

3.4.9.1 componentes discretos

Con el objetivo de realizar un diseño compacto la resistencias y capacitores utilizados son de montaje superficial (SMD) en el tamaño 1206.



Figura 3.21 Resistencia a capacitor SMD 1206

Se utilizaron diodos 1n4148w también [SMD](#).



Figura 3.22 Diodo 1n4148w

Potenciómetros RV09 para ajustar la ganancia.



Figura 3.23 Potenciómetros RV09

Potenciómetros multivuelta 3296w para regular el offset de continua.



Figura 3.24 Potenciómetros multivuelta 3296w

Para la entrada de señal se utilizan conectores hembra *miniplug* estéreo de 5 pines con *switches* integrados que permiten que cuando el *plug* de entrada se desconecta conectar la señal de entrada a masa evitando así que el canal de entrada quede al aire introduciendo altos niveles de ruido innecesario al equipo.



Figura 3.25 Conector hembra estéreo con switch

Para la salida del electrodo de referencia se utiliza un conector *mono* con *switch* que permite llevar la señal de salida a masa cuando no está conectada.



Figura 3.26 Conector hembra mono con switch

3.4.9.2 Circuitos integrados

En todos los casos se utilizan [IC SOIC](#).

En la figura 3.27 se muestra el amplificador de instrumentación el INA2128.



Figura 3.27 INA2128

Para la guarda y el circuito *drive leg* se utiliza un OPA2604 por canal

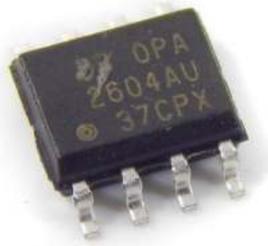


Figura 3.28 OPA2604

Para el resto del circuito se utiliza un TL074 por canal



Figura 3.29 TL074

3.4.10 Diseño del PCB

Para el correcto montaje de los componentes se utiliza el software *Altium Designer* y se diseña una placa **PCB** (*printed circuit board*) doble faz. Como consideraciones de diseño se tuvo en cuenta reducir lo más posible la longitud de los caminos de señal, especialmente los de entrada a fin de minimizar los efectos de la interferencia. En las figuras 3.30 y 3.31 se observa el PCB resultante y en la figura 3.32 el circuito impreso.

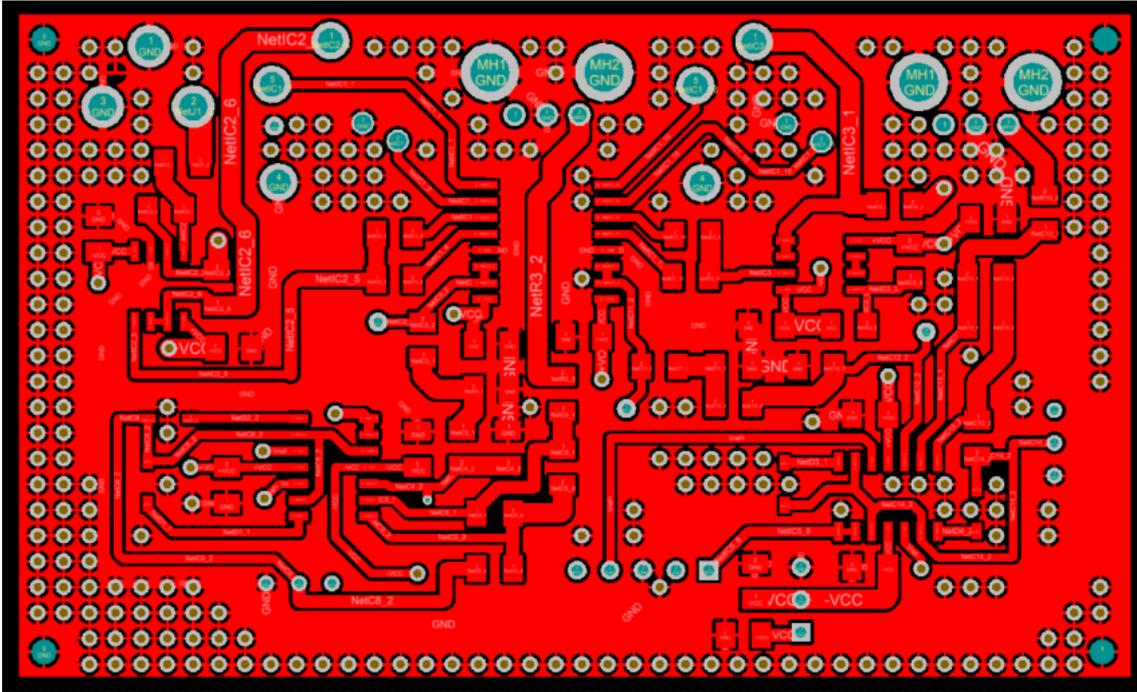


Figura 3.30 PCB Capa superior

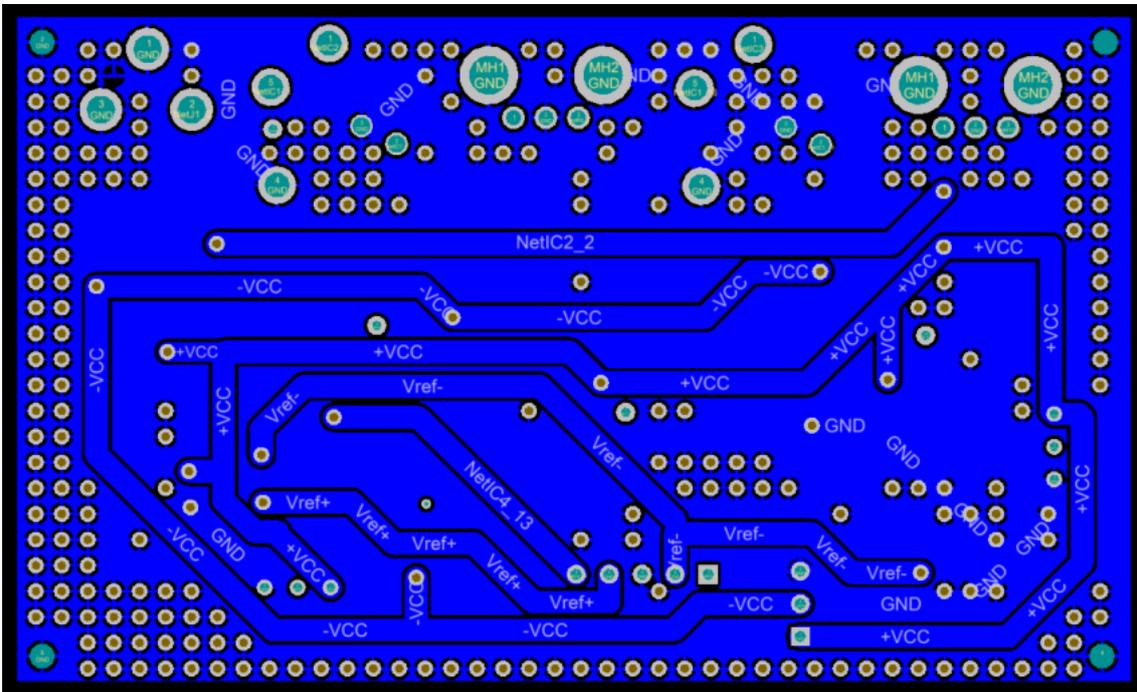


Figura 3.31 PCB Capa inferior

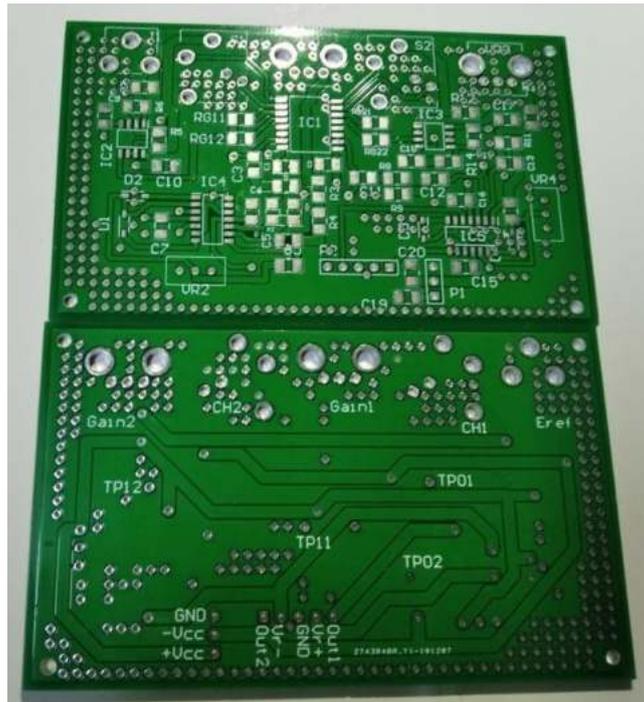


Figura 3.32 PCB Impreso

3.4.11 Montaje y resultado final

Una vez impreso el [PCB](#) se soldaron los componentes a la placa. El resultado se muestra en la figura 3.33.

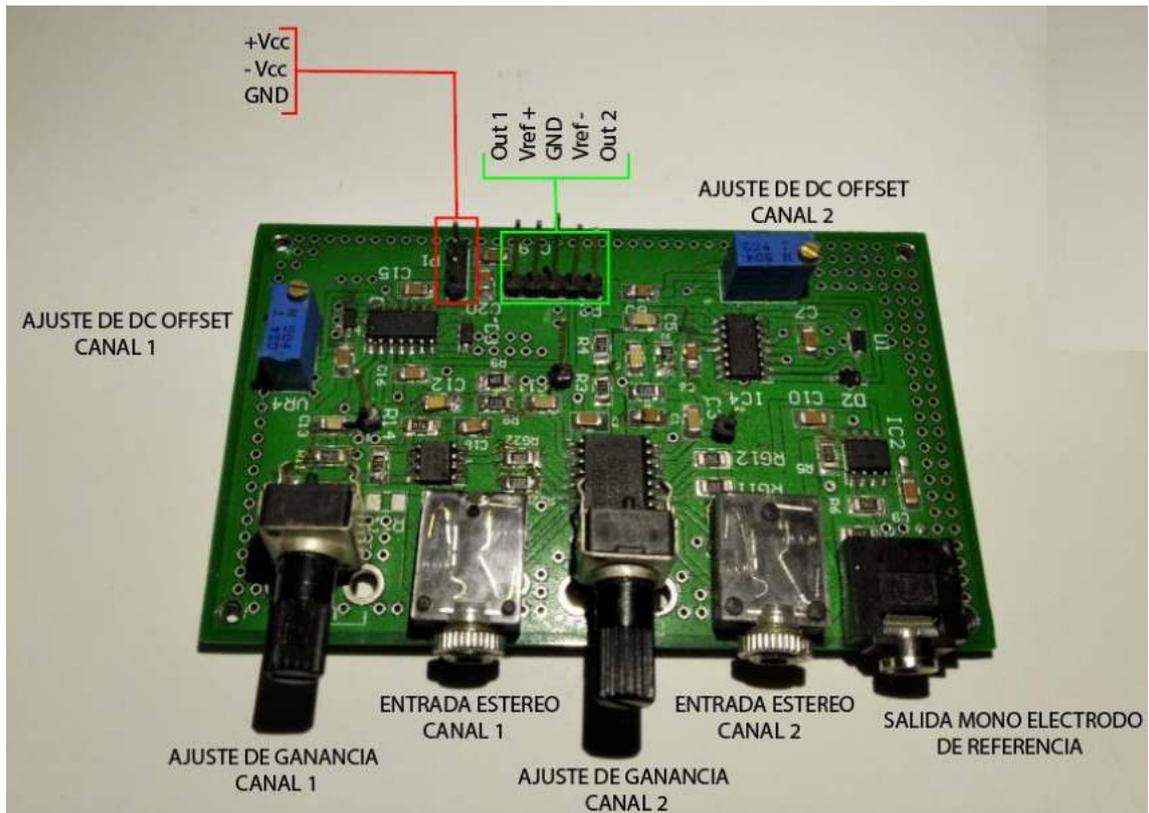


Figura 3.33 Placa con los componentes montados

3.5 Microcontrolador

Para las tareas de conversión analógico digital, pre procesamiento y transmisión de datos a la PC se utiliza la placa de desarrollo STM32F407G-Discovery (figura 3.34) de la empresa STMicroelectronics. Está basada en un procesador de 32 bits Cortex M4 de ARM el cual cuenta con unidad de punto flotante (FPU) que le permite realizar cálculos de manera rápida y eficiente. Puede ser alimentada vía USB o de manera externa. Cuenta con numerosos periféricos integrados tales como sensores de audio MEMS, un DAC de audio con drivers tipo D para parlantes, conversores analógico digital etc.



Figura 3.34 Placa de desarrollo STM32F407 Discovery [16]

La funcionalidad de los pines puede ser configurada vía software , un mismo pin puede ser configurado como salida, entrada, [ADC](#) y/o cualquier otra función para la cual haya sido diseñado. El software utilizado para la configuración y desarrollo del programa es [STM32Cube IDE](#). STM32Cube es una plataforma de desarrollo integrada que incluye un apartado para configuración de los periféricos de la placa. Está basada en el *framework* de Eclipse, utiliza como lenguaje de programación C.



Figura 3.35 STM32CubeIDE

3.5.1 Conversor Analógico Digital

La placa STM32 Discovery cuenta con múltiples pines que pueden ser configurados como ADC y que pueden realizar mediciones en modo único, continuo, escaneo o discontinuo. Estos usan el principio de conversión por aproximaciones sucesivas, es decir la digitalización se realiza en varios pasos. El número de pasos es igual al número de bits de resolución en el conversor. Cada paso es comandado por el reloj del ADC cuya frecuencia es configurable vía software. El diseño interno del ADC está basado en la técnica de conmutación de capacitores.

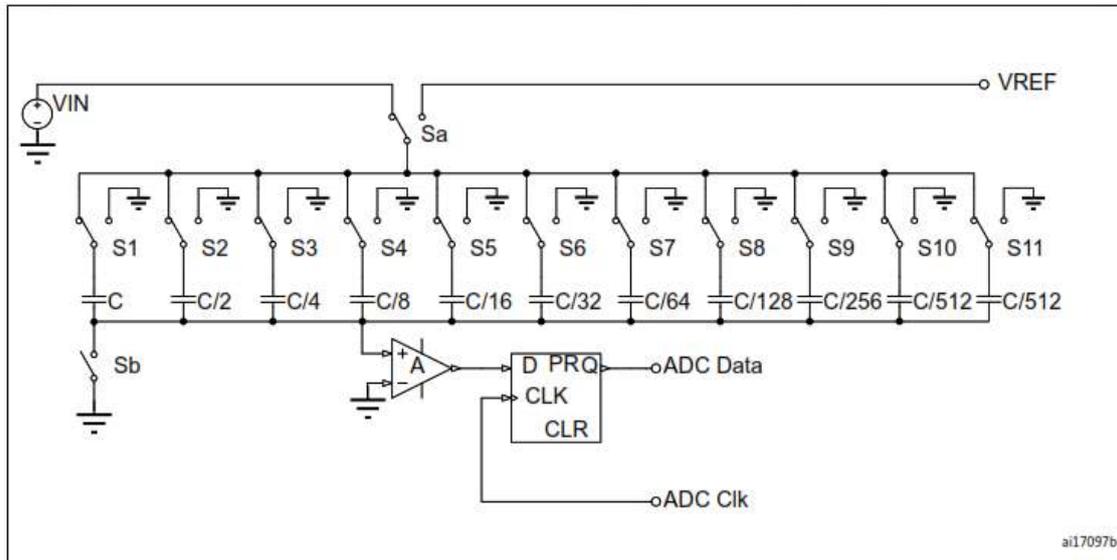


Figura 3.36 Esquema básico del ADC [17]

En el estado de muestreo los capacitores se cargan a la tensión V_{in} . S_a conectado a V_{in} y S_b cerrado figura 3.37.

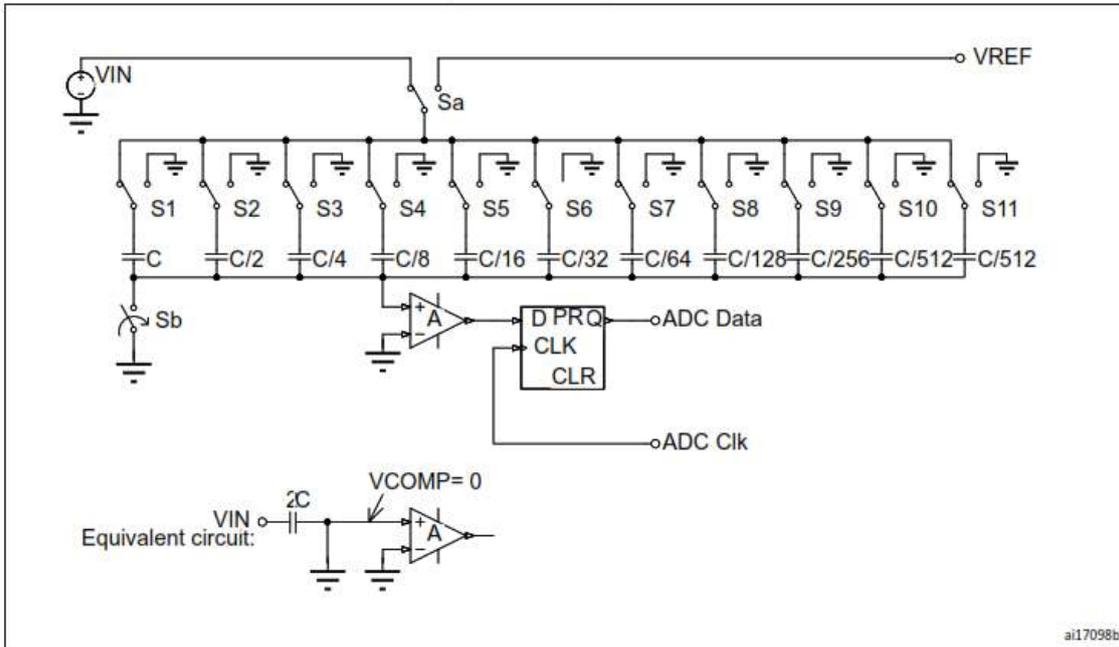


Figura 3.37 Estado de muestreo [17]

Cuando cambiamos la S_a a V_{ref} , los capacitores estarán cargados a la tensión de entrada, la llave S_b está abierta, luego $S_1 - S_{11}$ se conectan a tierra ver figura 3.38.

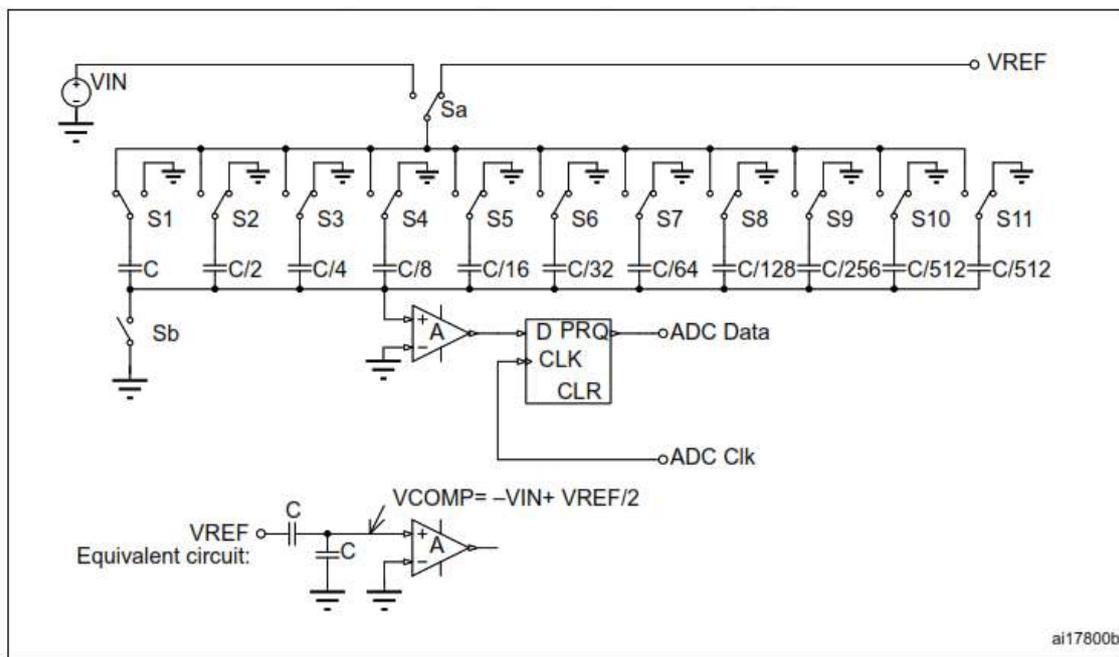


Figura 3.38 Estado de hold [17]

Para el caso del **MSB** (bit más significativo) se coloca las llaves como se muestra en la figura 3.39, quedando determinado el circuito equivalente que se muestra en la parte inferior izquierda. Si la tensión que almacena el capacitor supera a la

mitad de la tensión de referencia entonces el comparador dará como salida un "1" lógico. Repitiendo el proceso para las distintas llaves obtenemos secuencialmente todos los bits que componen la conversión.

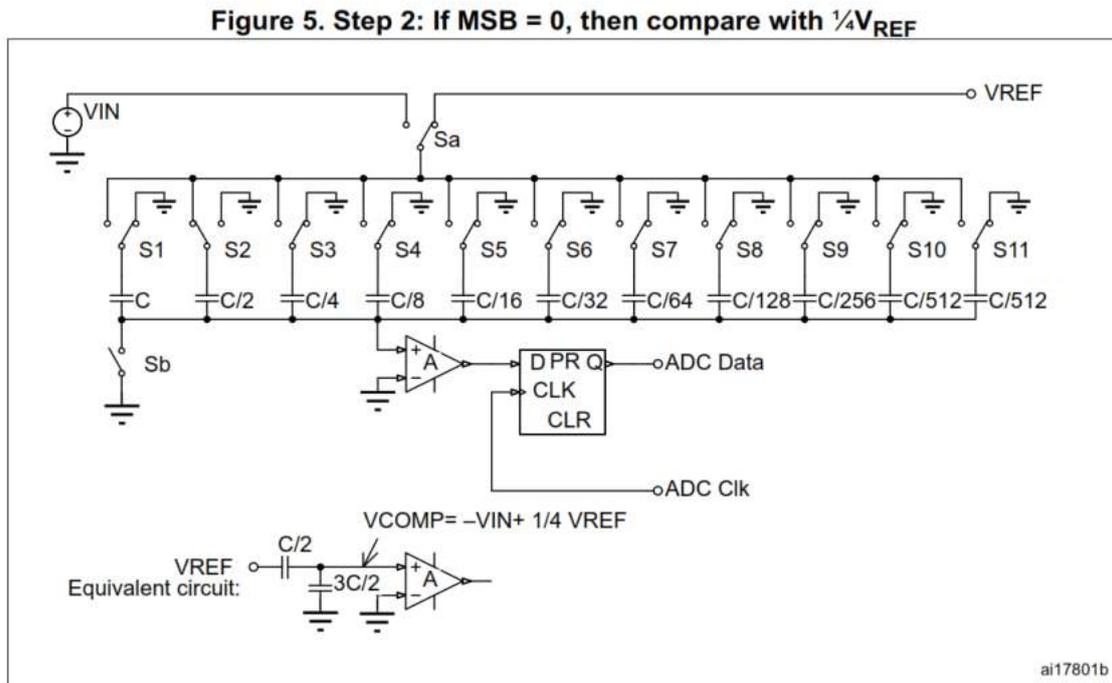


Figura 3.39 Determinación del MSB [17]

El **ADC** muestrea la señal de entrada un número de veces ciclos que dependen de la frecuencia de reloj del periférico. Tanto la frecuencia de reloj como el número de ciclos pueden ser configurados vía software.

El tiempo de conversión total se calcula como:

$$T_{conv} = \text{Tiempo de muestreo} + 12 \text{ ciclos}$$

Para obtener una buena representación temporal de la señal vamos a utilizar una frecuencia de muestreo de 5 kHz y utilizaremos como frecuencia del **ADC** 21 MHz.

$$\frac{21 \text{ MHz}}{5 \text{ kHz}} = \text{Tiempo de muestreo} + 12 \text{ ciclos}$$

$$\text{Tiempo de muestreo} = 4188 \text{ ciclos}$$

3.5.1.1 Efecto de la resistencia de la fuente de señal analógica

La impedancia del dispositivo encargado del acondicionamiento de la señal electromiográfica presentará una impedancia en el pin de entrada del ADC que por simplicidad en el análisis consideraremos que es puramente resistiva y de valor R_{AIN} . Sobre esta resistencia se produce una caída de tensión debido a la corriente que fluye hacia el ADC. La carga del capacitor de muestreo C_{ADC} va a depender ahora no solo de R_{ADC} (resistencia de los switches del ADC) sino también R_{AIN} .

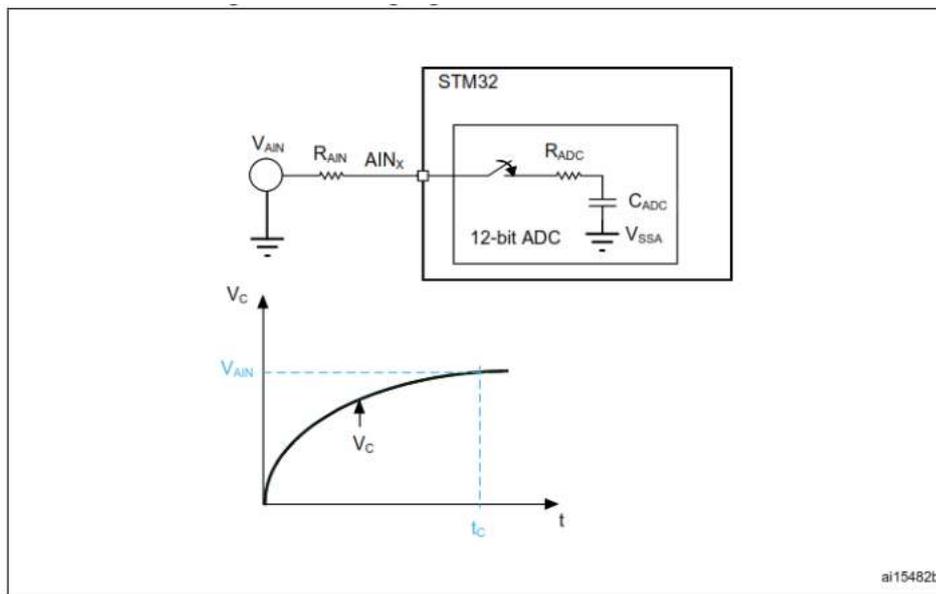


Figura 3.40 Ciclo de carga del capacitor del ADC [17]

$$T_c = (R_{ADC} + R_{AIN}) C_{ADC}$$

Si el periodo de muestreo es menor al tiempo requerido para cargar el capacitor el valor medido será erróneo. Si establecemos que el máximo error permitido es igual a $\frac{1}{2}$ LSB (Bit menos significativo) podemos calcular el valor máximo de resistencia que la etapa anterior debe presentarle al ADC.

$$Error = V_{AIN} - V_c = \frac{1}{2} LSB$$

El peor caso se presenta cuando $V_{AIN} = V_{REF}$

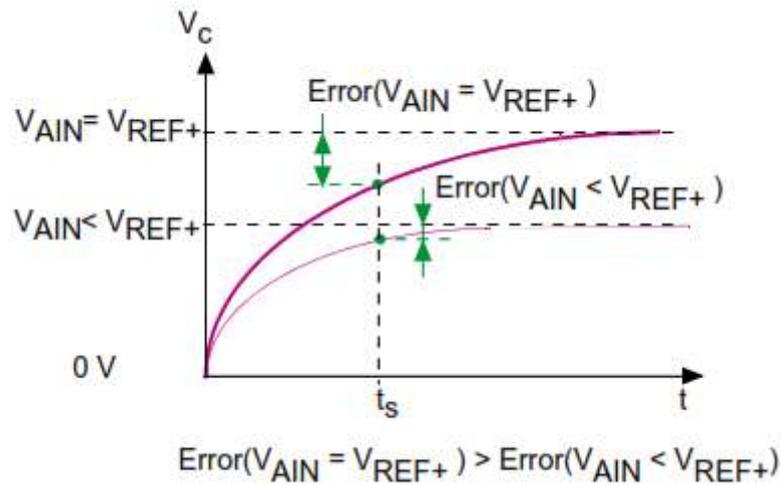


Figura 3.41 Error en el peor caso [17]

Donde t_s es el periodo de muestreo evaluado en ciclos de muestreo.

$$\text{Error} = V_{REF} - V_{REF} \left(1 - e^{-\frac{t_s}{R_{max} C_{ADC}}}\right) = \frac{1}{2} \frac{V_{REF}}{2^N}$$

Donde $R_{max} = (R_{AIN} + R_{ADC})_{MAX}$ y N es la resolución del ADC (en este caso 12).

Despejando de la ecuación R_{max} y tomando como frecuencia de muestreo 20 MHz, $C_{ADC} = 8\text{pF}$, $R_{ADC_{max}} = 6\text{ k}\Omega$, $T_s = 4000$.

$$R_{max} = \frac{T_s}{f_{ADC} C_{ADC} \ln(2^{N+1})} - R_{ADC_{max}} \cong 2.7\text{ M}\Omega$$

De este análisis queda claro que este requisito está satisfecho por la etapa anterior dado que la misma cuenta con un buffer separador a la salida y por consiguiente le presenta a la entrada del ADC una muy baja impedancia. Esto permite, de ser necesario incrementar la frecuencia de muestreo.

3.5.2 Filtrado digital

Como se ha mencionado en los capítulos anteriores la principal fuente de interferencia a la hora de medir las señales proviene de la red domiciliaria, la cual tiene una frecuencia bien definida (50 Hz en Argentina) se implementa, entonces, un filtro *notch* digital de respuesta al impulso infinita (IIR) que mitigue la presencia de esta componente frecuencial que no haya podido ser eliminada en etapas anteriores. Para esto se utilizan varias características que este microcontrolador posee.

Se utiliza lo que se conoce como **DMA** (*Direct Memory Access*). **DMA** se refiere a la capacidad con la que cuentan los periféricos (**ADC**, **USART**, etc.) de escribir y/o leer los datos de la memoria **RAM** de manera directa, es decir sin utilizar el microprocesador. En la figura 3.42 se detalla el diagrama de flujo del proceso.

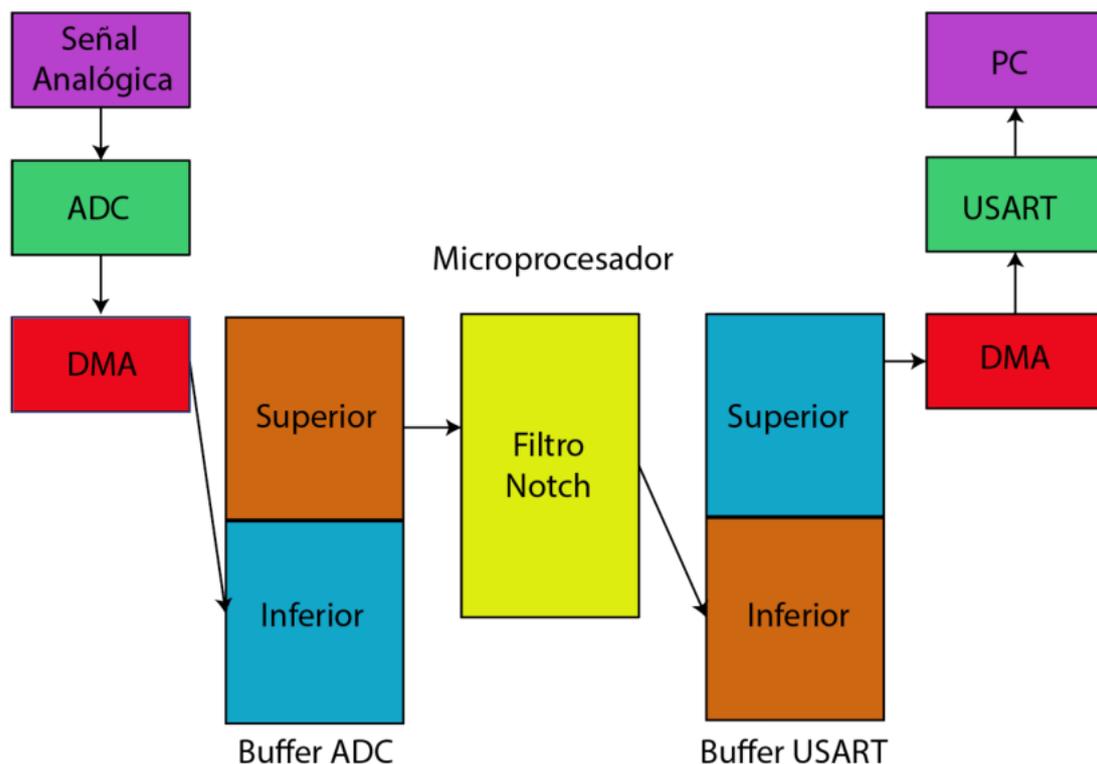


Figura 3.42 Diagrama de flujo del filtrado digital [17]

La señal analógica es digitalizada por el **ADC** y vía **DMA** la información se guarda en un buffer circular, lo que significa que cuando este se completa las nuevas muestras se guardan al inicio del buffer sobrescribiendo las muestras más

antiguas. Cuando la mitad del buffer se completa el microcontrolador genera una interrupción que ejecuta una función que puede ser modificada por el usuario. Es aquí donde las muestras son filtradas y luego enviadas al buffer de salida el cual también es circular. En simultáneo las muestras que ya fueron filtradas con anterioridad están siendo transmitidas vía **USART** (*Universal Asynchronous Receiver-Transmitter*) por **DMA**. De igual manera cuando el **ADC** termina de cargar la otra mitad del buffer repite el mismo proceso.

3.5.2.1 Filtro Notch

Un filtro notch se caracteriza por rechazar una banda de frecuencia determinada, en este caso necesitamos que sea altamente selectivo para eliminar la componente de 50 Hz tratando de no modificar demasiado las frecuencias adyacentes que contienen información relevante de la **EMG**. El microprocesador cuenta con una longitud de palabra de 32 bits por lo que al momento de realizar el cálculo de los coeficientes utilizaremos "single precision". Se utilizan estructuras bicuadradas las cuales son menos sensibles a la cuantización de los coeficientes que un único filtro **IIR** de mayor grado, especialmente en frecuencias de corte bajas. En particular la forma directa II transpuesta (figura 3.43) la cual es considerada la más numéricamente precisa cuando se utiliza representación de números en punto flotante [18].

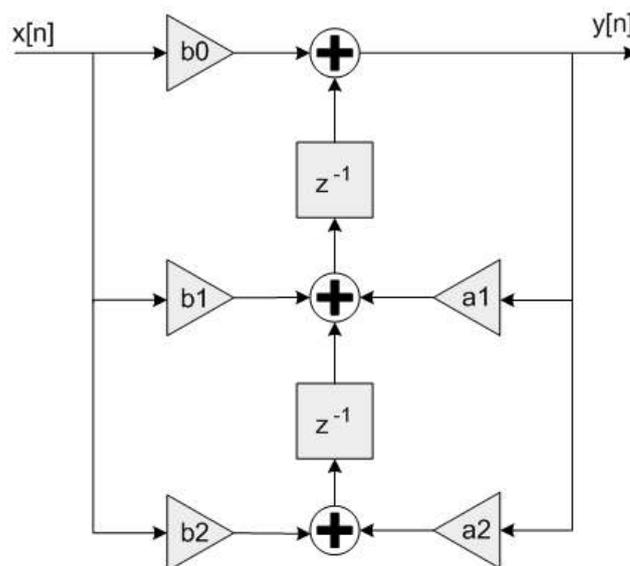


Figura 3.43 Estructura bicuadrada forma directa II transpuesta

$$y[n] = b_0x[n] + b_1x[n - 1] + b_2x[n - 2] - a_1y[n - 1] - a_2y[n - 2]$$

Para el diseño utilizaremos la herramienta Filter Designer de Matlab. En la figura 3.44 se observa su interfaz. Configuramos el tipo de filtro en **IIR Single Notch**. $f_{muestreo} = 5000 \text{ Hz}$, $f_{notch} = 50 \text{ Hz}$, ancho de banda 1 Hz y con 1 dB de ganancia en la banda de paso. En la figura 3.45 se muestra la respuesta en frecuencia del filtro diseñado.

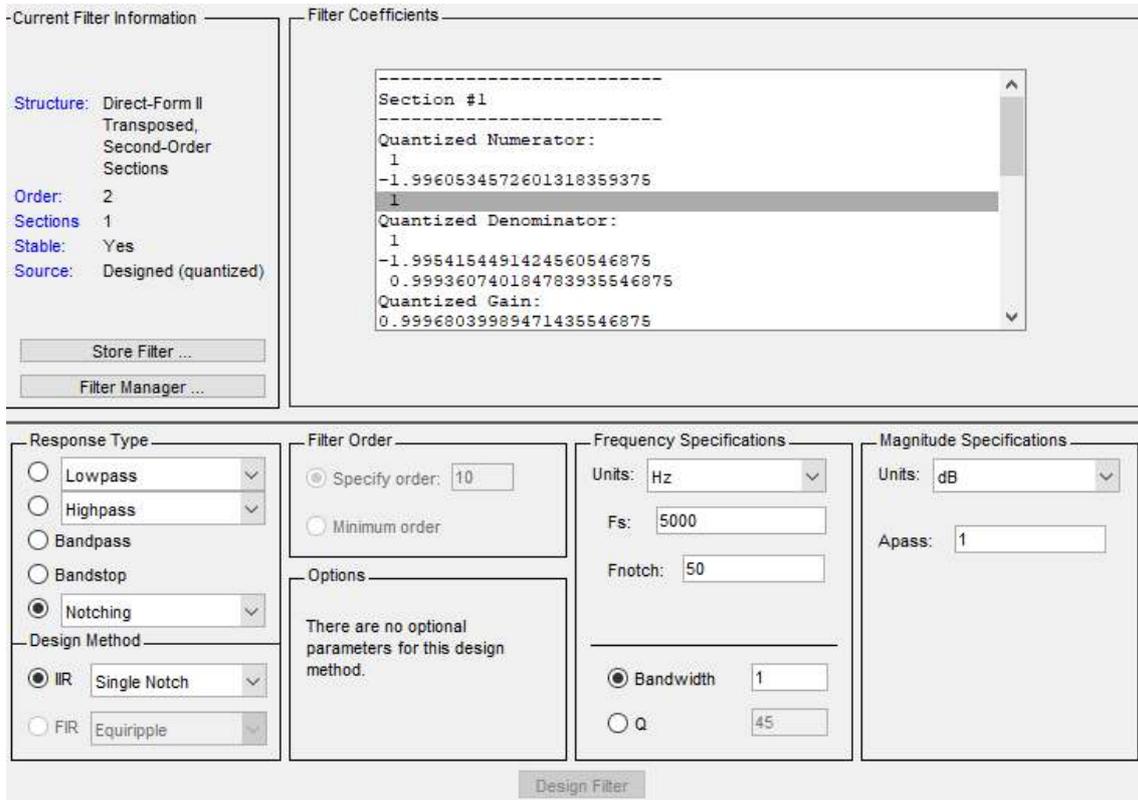


Figura 3.44 Configuración del filtro en el ToolBox de Matlab

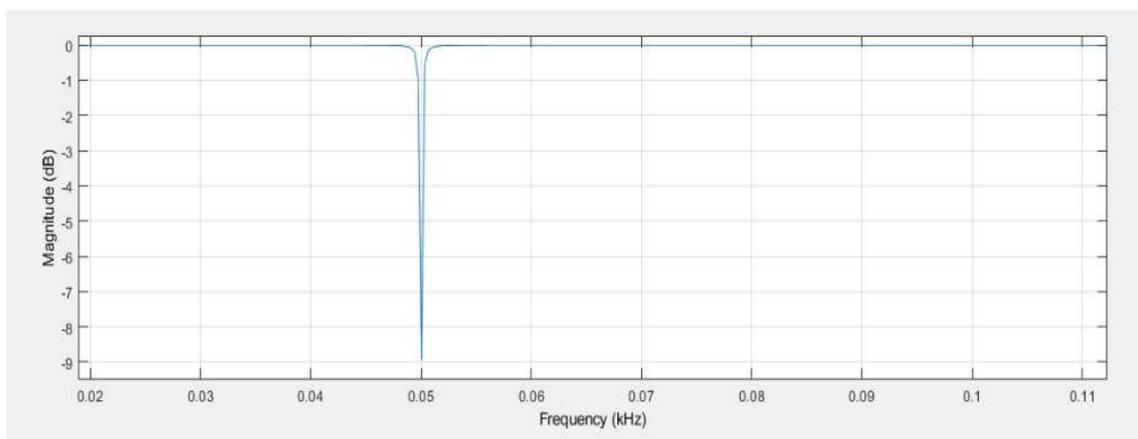


Figura 3.45 Respuesta en frecuencia del filtro diseñado

Para la implementación del filtro digital se utilizó la librería CMSIS-DSP. Esta librería cuenta con un conjunto de funciones especializadas en el procesamiento digital de señales tales como filtro FIR, filtros IIR, convoluciones, etc. Está optimizada para maximizar el rendimiento de los procesadores de la familia Cortex de ARM aprovechando la FPU. Para ello debemos definir los coeficientes que en este caso son los proporcionados por la toolbox específica de MATLAB y la función de filtrado toma el buffer de entrada realiza el filtrado y lo coloca en el buffer de salida como se explicó en la figura 3.42.

3.5.3 Transmisión de datos

Para la transmisión de los datos se utilizaron dos pines de salida configurados en modo USART). Esta configuración permite el intercambio de datos en modo *full duplex* con equipamiento externo utilizando el estándar industrial NRZ. Es posible el envío en un amplio rango de tasa de baudios (*baud rates*). De manera similar que con el ADC es posible la configuración de los parámetros del periférico. El acceso a los datos a ser transmitidos será por intermedio de DMA y el baud rate 115200 baudios, con longitud de palabra de 8 bits, sin bit de paridad. La señal se transmite a un adaptador Serial a USB como el de la figura 3.46.



Figura 3.46 Adaptador Serial a USB

3.6 Conexión y operación del sistema

En la figura 3.47 se muestra el esquema de conexión del sistema completo.

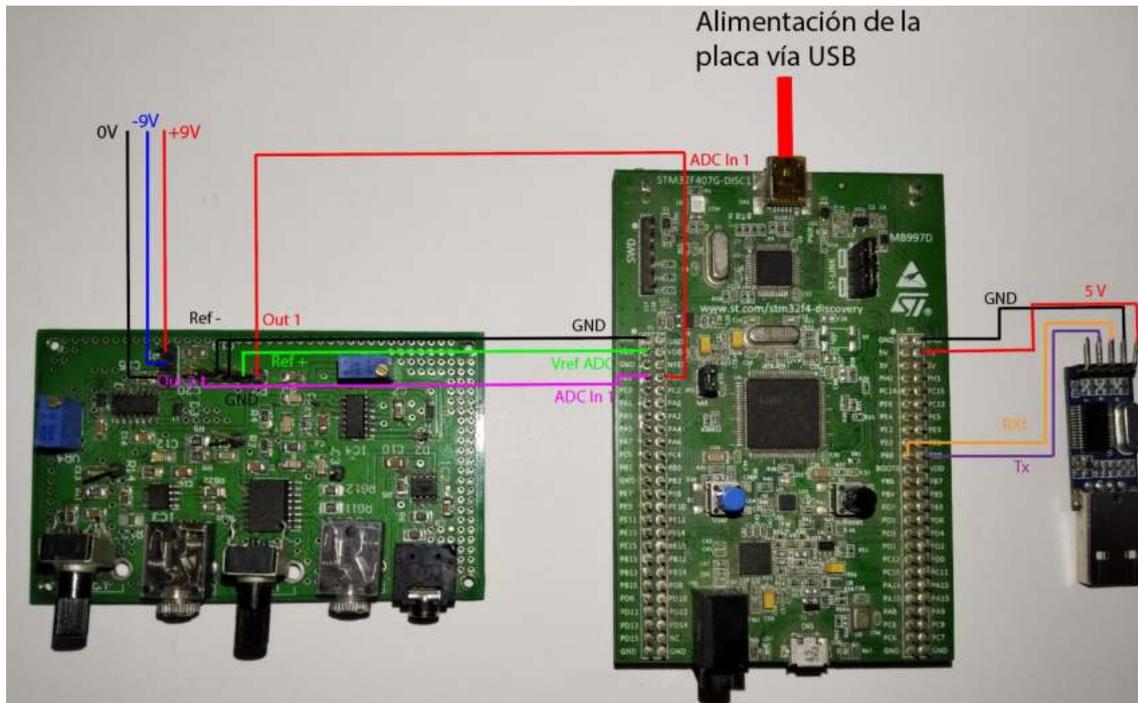


Figura 3.47 Esquema de conexión del sistema

Ref_+ se conecta a V_{DD} que corresponde a la tensión de referencia del ADC del microcontrolador. Ref_- y GND del dispositivo analógico se conectan a GND de la placa Discovery. Las salidas analógicas Out_1 y Out_2 se conectan a las entradas de ADC, en este caso P_{A0} y P_{A1} .

La interconexión entre el adaptador serial a USB y el microcontrolador se conecta de la siguiente manera. Se alimenta el adaptador con los pines 5V y GND de la Discovery. Los pines de salida Rx y Tx de la USART (P_{B9} y P_{B8} respectivamente) se conectan a Tx y Rx del adaptador respectivamente.

Luego el adaptador se conecta a la PC vía USB donde se reciben los datos por puerto serie.

La placa Discovery será alimentada vía USB como se muestra en la figura 3.47. En la figura 3.48 se muestra la conexión de los cables al dispositivo analógico.



Figura 3.48 Conexión de los cables al dispositivo

Con los dos potenciómetros frontales controlamos la ganancia de cada uno de los canales mientras que con los presets multivuelta ajustamos el nivel de offset de continua.

Capítulo 4

Simulaciones

4.1 Objetivo y herramientas utilizadas

Con el fin de conocer la factibilidad del diseño se realizaron distintas simulaciones. El software utilizado fue el TINA-TI V9 de Texas Instrument. Es un simulador de circuitos electrónicos basado en SPICE (*Simulation Program with Integrated Circuits Emphasis*). Cuenta con las herramientas básicas de este tipo de softwares (análisis DC, transitorios, análisis frecuencial, etc.) y agregando funcionalidades que lo hacen adecuado para el desarrollo de nuevos diseños. Cuenta con una librería integrada de circuitos integrados comerciales y permite además crear modelos propios.

4.1.1 Ganancia y rechazo en modo común

Para la primera simulación se analizará simultáneamente los niveles de amplificación del INA2128 con respecto al valor del resistor R_g (el cual determina la ganancia) y el rechazo en modo común. El esquema utilizado se muestra en la figura 4.1.

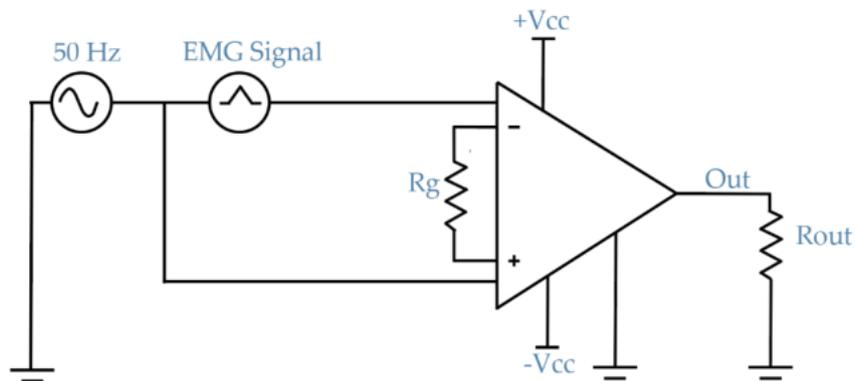


Figura 4.1 Conexión de los cables al dispositivo

La señal interferente ingresa en modo común, con una amplitud de $2 V_{pp}$ y frecuencia $50 Hz$ con el objeto de emular el ruido provocado por la radiación electromagnética proveniente de la red eléctrica el cual como se ha señalado en capítulos anteriores es la más importante. Como señal de entrada utilizaremos una señal real de **SEMG** extraída de PhysioBank en formato .csv la cual fue convertida a formato .wav dado que el software de simulación admite que este tipo de archivos sea utilizado como señal de entrada. PhysioBank es un extenso y creciente archivo de registro de señales fisiológicas digitalizadas e información relacionada para el uso en investigación de la comunidad biomédica (citar página, preguntar). En este caso la información proviene de un paciente sin ninguna patología. La muestra fue digitalizada con una frecuencia de muestreo de $4000 Hz$. La amplitud máxima de la misma fue configurada en $5 mV_{pp}$.

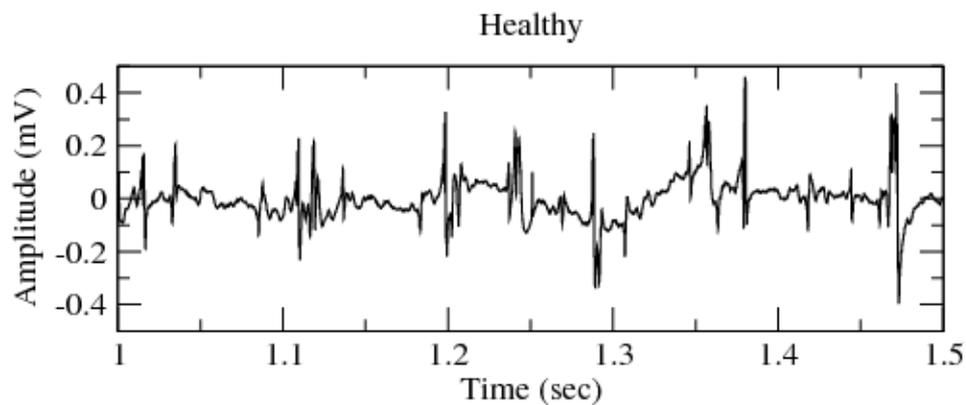
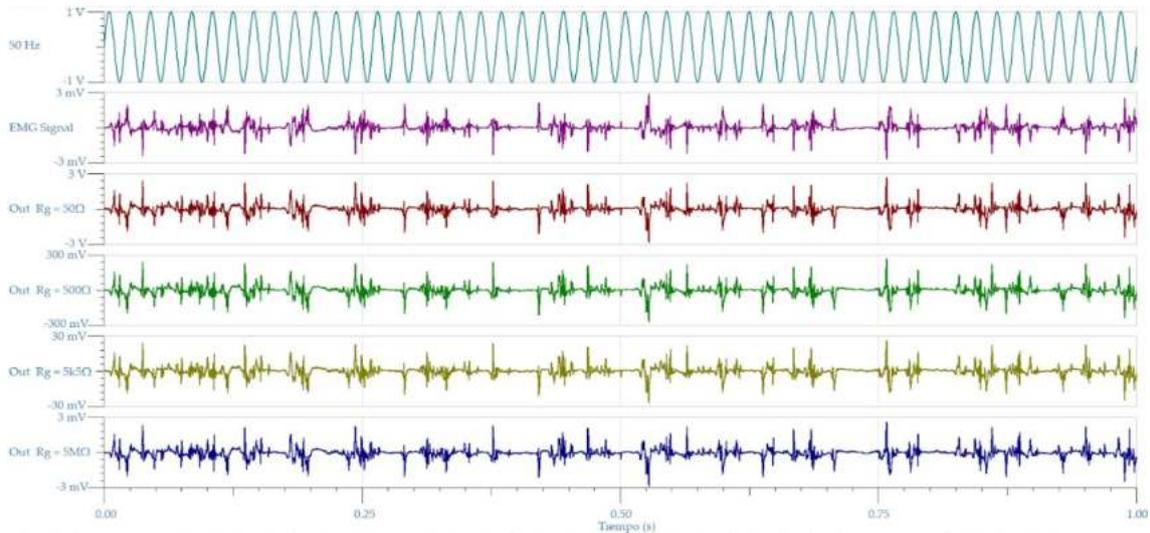


Figura 4.2 Conexión de los cables al dispositivo [19]

En la figura 4.3 se observan las señales de entrada ($50 Hz$ y la señal de **EMG**) y las salidas para distintos valores de R_g .



Para este caso y todos los siguientes que impliquen la comparación entre la señal de entrada de EMG y la salida luego del INA ha de notarse una inversión de fase debido a que al momento de la simulación se conectó el generador con la polaridad opuesta a las entradas INA.

Figura 4.3

4.1.2 Influencia del filtro pasabanda.

Como se señaló en el capítulo 1, la información relevante de la señal está contenida en la banda de 20 Hz – 500 Hz. Teniendo en cuenta este requerimiento es que se diseñó el filtro pasivo pasabanda. Para medir la influencia a la hora de atenuar señales fuera de la banda de interés se ensayó la siguiente simulación.

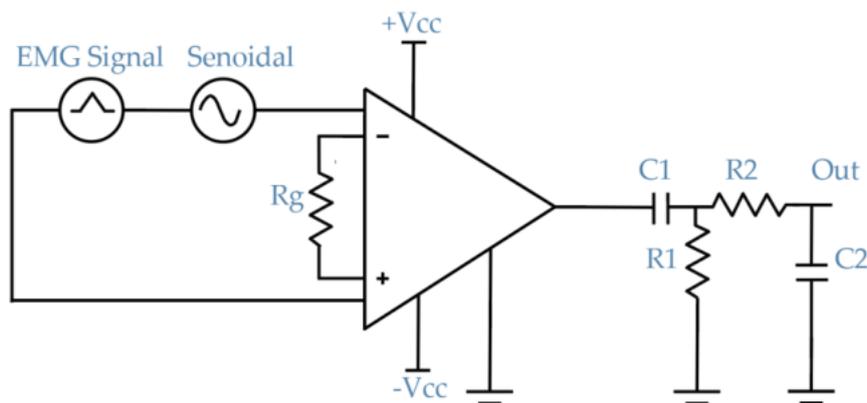


Figura 4.4 Esquema de simulación para el filtrado pasabanda

En un primer ensayo se sumó en modo diferencial un tono senoidal de frecuencia 10 kHz y amplitud 10 mVpp a la señal de SEMG. Se puede observar (figura 4.5)

que antes del filtrado la señal útil queda enmascarada por la señal interferente mientras que luego del filtrado la situación mejora notablemente.

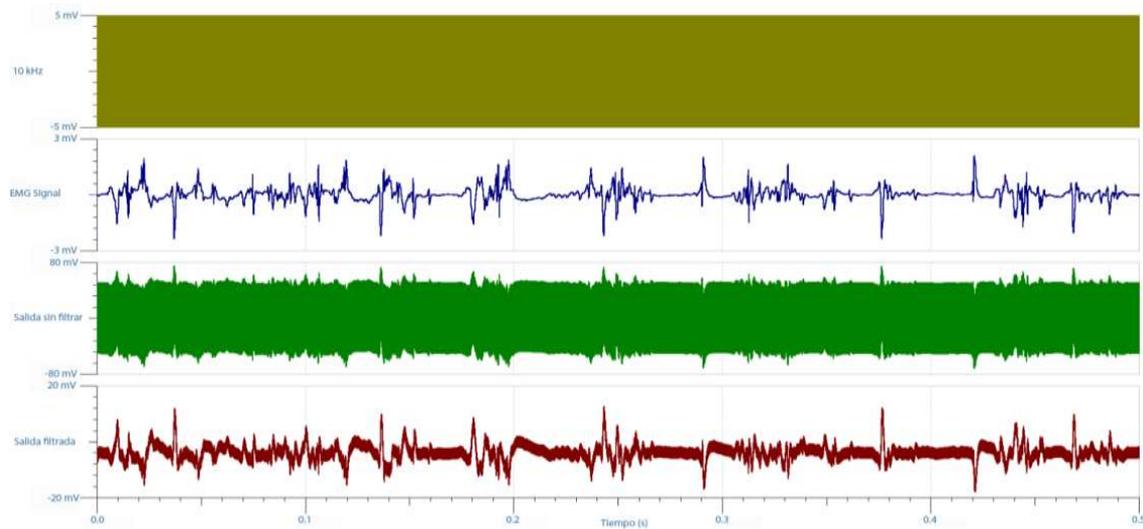


Figura 4.5

De la misma manera se repitió la simulación, pero esta vez el tono con frecuencia de 1 Hz.

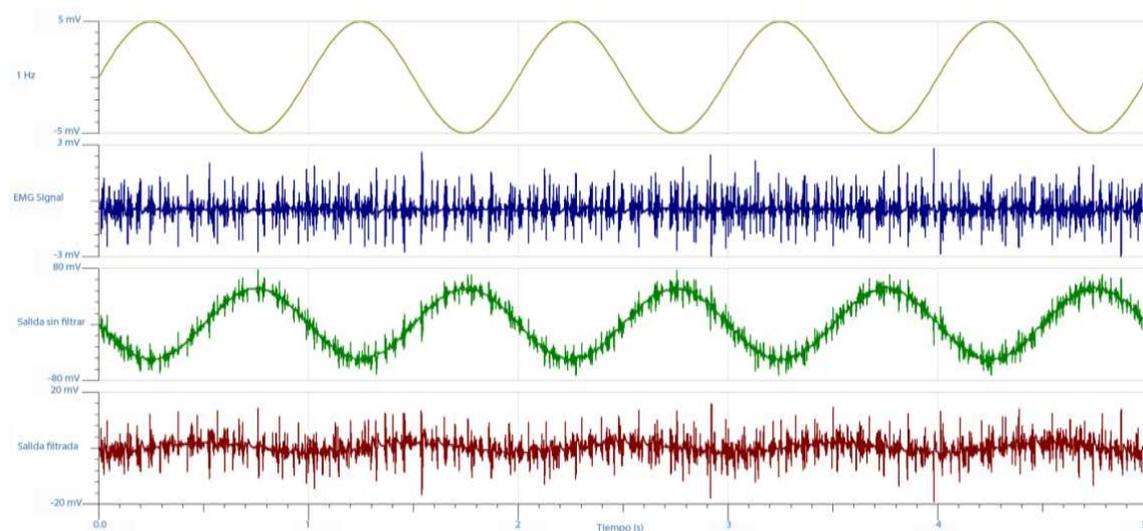


Figura 4.6

4.1.3 Amplificador variable

En esta sección se simuló el comportamiento del amplificador de ganancia variable para la condición de ganancia mínima y máxima (figura 4.7). Se utilizó

la misma señal de entrada que en el ejemplo anterior. Los resultados se exhiben en la figura 4.8.

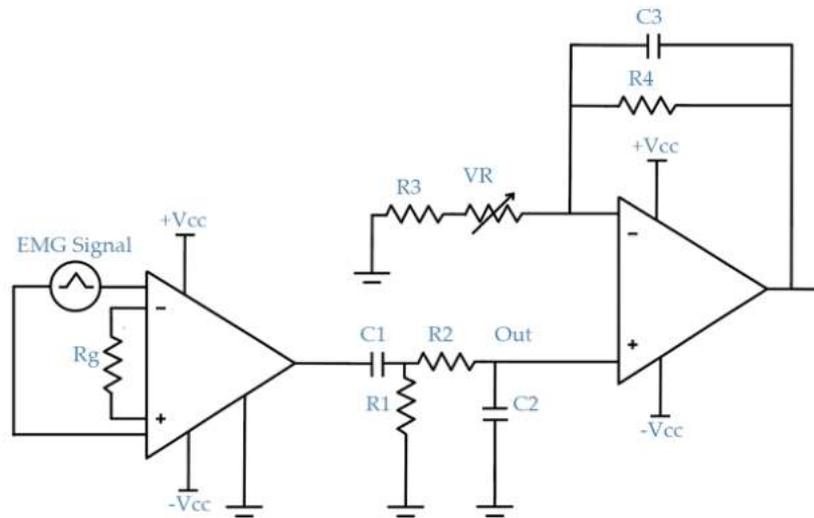


Figura 4.7

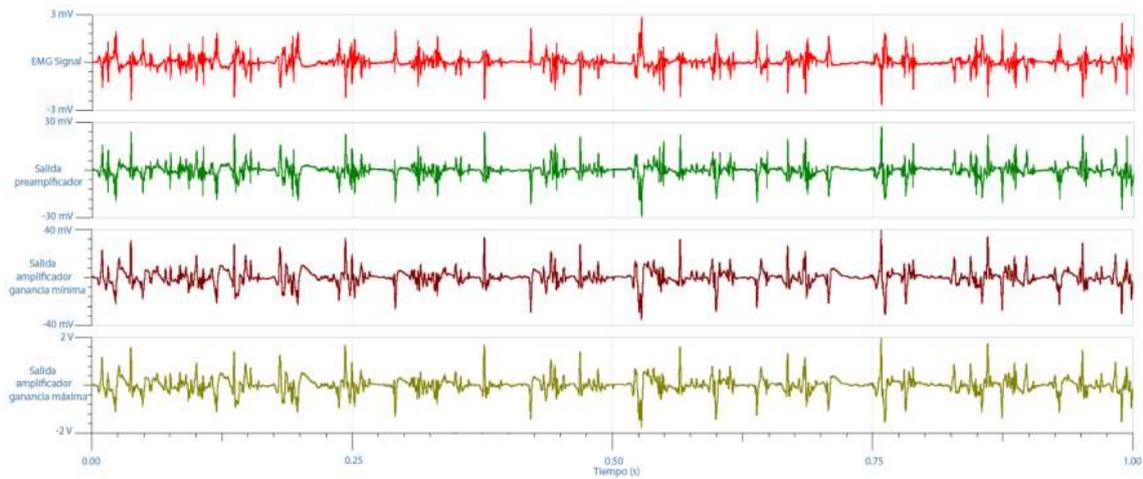


Figura 4.8

4.1.3 DC Offset

En esta simulación se ajusta el valor del *preset* multivuelta para producir un *offset* de 1.65 V . El esquema se muestra en la figura 4.9. $R_6 = 408,3\text{ k}$ y $R_5 = 91,7\text{ k}$ y los correspondientes resultados en la figura 4.10

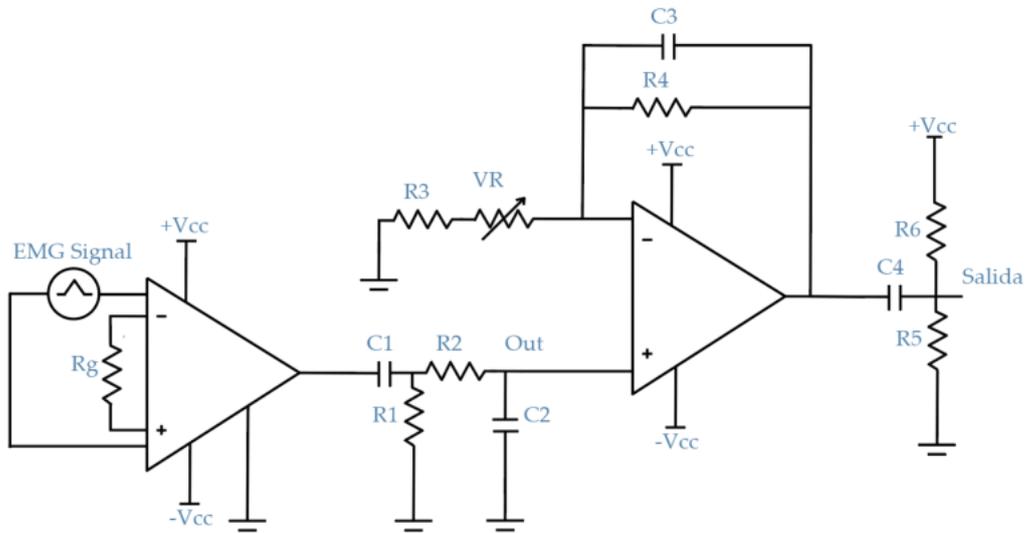


Figura 4.9

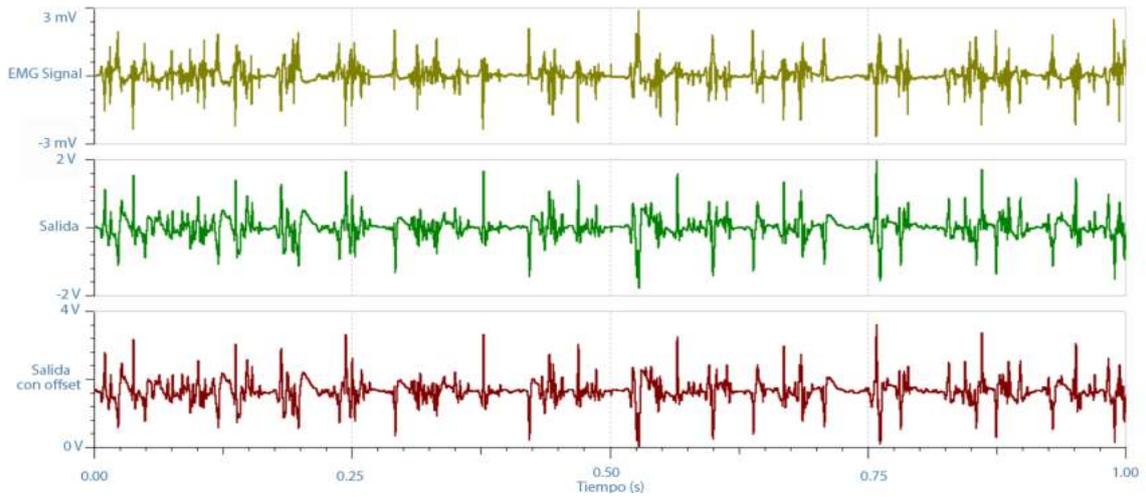


Figura 4.10

4.1.4 Limitadores

Se simuló el comportamiento de los limitadores. Para ellos se amplificó la señal de entrada a niveles que produzcan el recorte de la señal. Se puede apreciar en la señal de salida (figura 4.12) que la misma está contenida entre 3.3V y 0V que son las tensiones de referencia.

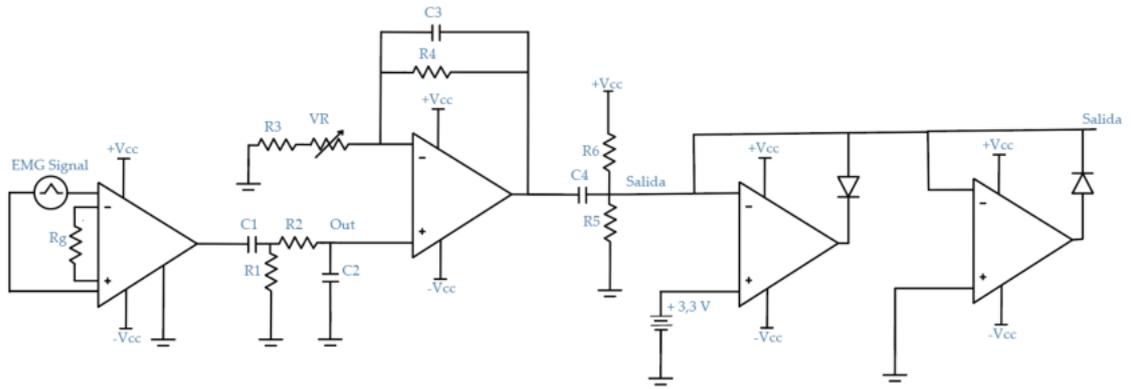


Figura 4.11

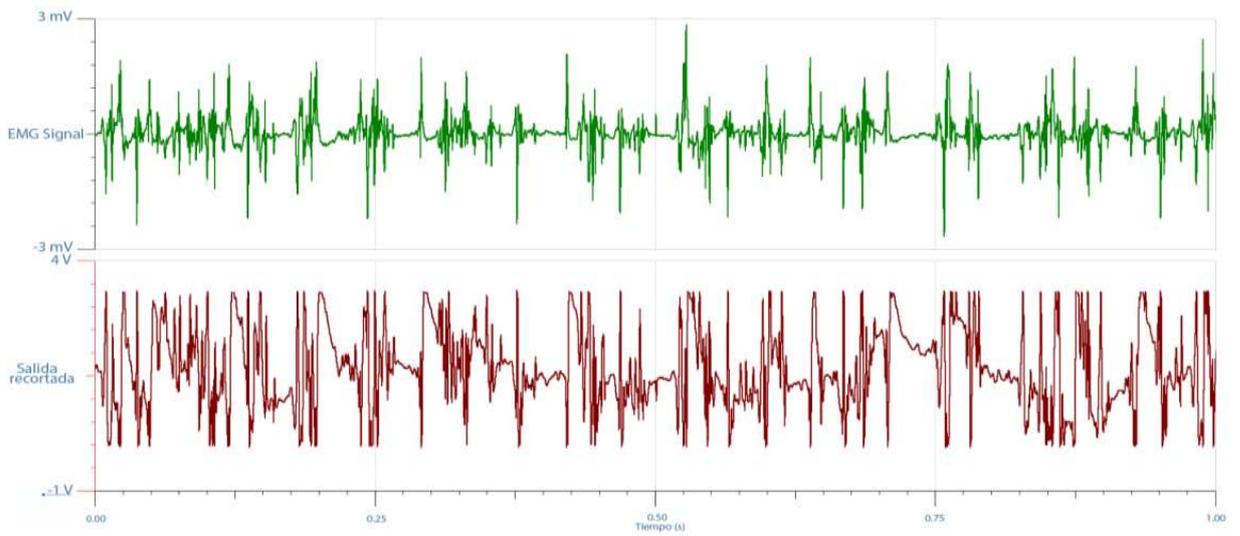


Figura 4.12

Capítulo 5

Conclusiones

Durante el desarrollo de este trabajo final, se puso en práctica y se profundizaron los conocimientos adquiridos durante la etapa de formación en la carrera de Ingeniería Electrónica. Se utilizaron conceptos y herramientas para la investigación, análisis, desarrollo, diseño e implementación de un dispositivo que se aplicará en una situación real de investigación. Los desafíos propios del proyecto hicieron necesario reforzar y aplicar conceptos adquiridos previamente, así como también incursionar en nuevos conocimientos y herramientas. A continuación, se listarán algunos de ellos:

- Diseño de un circuito electrónico en base a requerimientos previamente establecidos.
- Simulación de circuitos en softwares especializados (TINA TI) para evaluar la factibilidad del diseño.
- Mediciones eléctricas sobre los equipos desarrollados con instrumental propio de la disciplina electrónica para evaluar el funcionamiento y detectar posibles fallas.
- Procesamiento digital de señales, en particular, filtros.
- Montaje de componentes [SMD](#)
- Utilización de microcontroladores para la adquisición, filtrado, y transmisión digital de la información. Para ello fue necesario familiarizarse con la lectura de manuales de usuario y notas de aplicación, el aprendizaje de un software propietario para la configuración de este y el manejo del lenguaje de programación (C).
- Utilización de la herramienta *Altium Designer* para el diseño del [PCB](#)
- Manejo de Toolbox de MATLAB para el cálculo de los coeficientes del filtro digital

Por otro lado, el proyecto requirió el trabajo en áreas temáticas que no son propias de la carrera, como lo son la Bioingeniería y las Ciencias de la Salud, que permitieron una comprensión global de la problemática a resolver. El contacto con literatura académica resultó muy valioso para enriquecer los conocimientos adquiridos.

Se diseñó un prototipo funcional que cumple con los objetivos planteados y deja abierta la puerta para implementar mejoras para optimizar el funcionamiento del dispositivo.

Gestionar un proyecto en todas sus etapas, tratando de resolver las complicaciones propias de un desarrollo resulta una experiencia invaluable de cara al futuro. En la misma línea, poder darle un sentido práctico a lo aprendido resulta muy gratificante y logra disminuir la brecha entre el estudiante y el futuro profesional.

Por los motivos expuestos, se consideran cumplidos los objetivos planteados en este proyecto.

Referencias

- [1] N. Massó, F. Rey y D. Romero, «Surface electromyography applications in the sport,» *Medicina de L'Esport*, 2010.
- [2] A. C. Guyton y H. J. E, *Tratado De fisiología médica*. Elsevier, España: Elsevier, 2016.
- [3] M. Zahak, «Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis,» *INTECH Open Access Publisher*, 2012.
- [4] C. J. De Luca, «Surface Electromyography: Detection and recording,» *DELSYS*, 2002.
- [5] Huhta, J. C. and Webster, J. G, «60-Hz Interference in Electrocardiography,» *IEEE Transactions on Biomedical Engineering*, 1973.
- [6] J. j. Almasi y S. O. H, «Automated measurement of bioelectric impedance at very low frequencies,» *Computers and biomedical research, an international journal*, Vols. %1 de %27,5, pp. 449-56, 1974.
- [7] M. v. R. Alber, P. Abraham y G. C. A, «High-quality recording of bioelectric events,» *Medical & Biological Engineering & Computing*, 1990.
- [8] W. Weineng, W. Zhiqiang y P. Xiao, «Effects of the Earth Current Frequency and Distortion on Residual Current Devices Archived 2014-11-08 at the Wayback Machine,» *Scientific Journal of Control Engineering*, vol. 3, nº 6, pp. 417-422, 2013.
- [9] J. Rosell, J. Colominas y R. P, «Skin impedanance from 1 Hz to 1 Mhz,» *IEEE Transactions on Biomedical Engineering*, vol. 35, 1998.
- [10] A. Albulbul, «Evaluating Major Electrode Types for Idle Biological Signal Measurements for Modern Medical Technology,» *MDPI*, 2016.
- [11] F. Luna Daura, «El mito de las conexiones de los cables blindados,» *Revista Española de Electrónica*, 2016.
- [12] Texas Instruments, *INA 2128 Dual, Low Power Instrumentation Amplifier*, 2007.

- [13] B. R. Eggins, «Skin contact electrodes for medical applications,» *Analyst*, vol. 118, pp. 439-442, 1993.
- [14] T. Instruments, *OPA2604 Dual FET-Input, Low-Distortion Operational Amplifier*, 2015.
- [15] D. L. Terrel, *OP Amps Second Edition*, Elsevier Inc., 1996.
- [16] STMicroelectronics, *Discovery kit with STM32F407VG MCU*, 2016.
- [17] STMicroelectronics, *AN2834*, Application note.
- [18] ASN Advanced Soltuions Nederland B.V, *Designing and implementing biquead IIR filters with the ASN filter Designer: a tutorial review*, 2016.
- [19] R. Seward, «Physionet,» 28 Octubre 2016. [En línea]. Available: <https://archive.physionet.org/physiobank/database/emgdb/?C=D;O=A>. [Último acceso: 2 Octubre 2020].



Facultad de
Ingeniería
Universidad Nacional de Mar del Plata

Trabajo Final

Ingeniería Electrónica

**Reconocimiento de patrones
en videos de ultrasonido
con técnicas de inteligencia artificial**

Autor:
Rodrigo AZPILCUETA

Directores:
Gustavo Javier Meschino
Lucía Isabel Passoni

Resumen

La ecografía ha emergido como una técnica de relevancia en el campo de la anestesia y los cuidados críticos. El ultrasonido pulmonar (UP) constituye una herramienta diagnóstica dinámica, no invasiva, apta para pacientes bajo ventilación mecánica. La anestesia general se asocia al colapso total o parcial del pulmón (atelectasia) en un alto porcentaje de pacientes. Las maniobras de reclutamiento (MR) son procesos dinámicos y fisiológicos de re-aireación de una región pulmonar sin gas, con ventilación con presión positiva. Para realizar la evaluación con imágenes de UP del resultado de un reclutamiento, se identifican patrones ecográficos que permiten el diagnóstico de las distintas patologías pleuro-pulmonares.

Este trabajo avanza en la dirección de desarrollar una herramienta de soporte a la monitorización durante las MR, ayudando a la interpretación de la dinámica de los patrones ecográficos que se registran durante las mismas. Se propone el procesamiento de secuencias de video de UP, alimentando con ellas una red neuronal artificial con arquitectura de aprendizaje profundo, entrenada con el paradigma de transferencia de aprendizaje.

Se procesaron videos de UP adquiridos en diferentes pacientes a los que se les aplicaron maniobras de reclutamiento, resultando en videos correspondientes a diferentes situaciones pulmonares. Dos médicos especialistas en imágenes ecográficas de pulmón etiquetaron imágenes de los videos para formar así información de entrenamiento del sistema. Con el sistema desarrollado, para cada imagen se obtienen valores de pertenencia a las diferentes clases. A su vez, se obtiene un análisis resumen de cada video.

A pesar de la complejidad propia de las imágenes ecográficas, las redes utilizadas son capaces de detectar con gran eficiencia y eficacia los diferentes estados. El sistema constituye un aporte en el procesamiento de videos de ultrasonido pulmonar, contribuyendo a los análisis visuales y cuantitativos que hasta el momento se han propuesto.

Contenidos

Introducción	4
Materiales y Métodos	6
A. Aprendizaje profundo	6
B. Fuentes de datos	8
C. Métodos propuestos	10
Resultados	13
Comparación de resultados para MobileNet y VGG-19 con 3 clases	13
Comparación de resultados para MobileNet y VGG-19 con 4 clases	14
Ensamble de clasificadores	15
Resultados en casos reales	16
Cálculo de Scores	25
Promedio de <i>scores</i>	26
Mediana de los <i>scores</i>	26
<i>Score</i> probabilístico	26
Algoritmo <i>Fuzzy</i>	26
Diseño de la interfaz de usuario	29
Conclusión	35
Referencias	36

Introducción

En la última década, la ecografía ha emergido como una técnica de relevancia en el campo de la anestesia y los cuidados críticos [1], [2]. El ultrasonido pulmonar (UP) constituye una herramienta diagnóstica dinámica, no invasiva, que puede ser realizada a la cabecera del paciente que se encuentra bajo ventilación mecánica [3]. La anestesia general se asocia a la aparición del colapso total o parcial del pulmón (atelectasia) en un alto porcentaje de pacientes [4]. Las técnicas de visualización de masa pulmonar han permitido observar atelectasias después de la inducción de una anestesia general, llegando a incidencias globales de hasta el 90% de los pacientes anestesiados.

El reclutamiento es un proceso dinámico y fisiológico de re-aireación de una región pulmonar previamente sin gas con ventilación con presión positiva. En pacientes adultos existen diferentes protocolos para su aplicación tanto en el síndrome de dificultad respiratoria aguda (SDRA) como en la lesión pulmonar aguda (LPA). Las maniobras de reclutamiento (MR) consisten en incrementos transitorios de la presión media en la vía aérea con el fin de reclutar unidades alveolares colapsadas, mediante la aplicación continua o repetitiva del aumento de los niveles de presión de distensión. El aumento del volumen pulmonar con MR puede hacer que la ventilación sea más homogénea, lo cual mejora el intercambio gaseoso y limita la distensión de las unidades alveolares sanas [5] [6] [7] [8] [9] [10]. Este procedimiento necesita un monitoreo del estado pulmonar. En ese sentido, la conveniencia de la utilización de ultrasonido en pulmones para evaluar el resultado de MR en pacientes internados en unidades de cuidados intensivos (UCI) ha sido ampliamente estudiada [11].

Las imágenes ecográficas del pulmón se obtienen a partir de la interacción del haz de ultrasonido con las estructuras torácicas y el parénquima pulmonar, en función de la reflexión y reverberación de los ecos sobre las interfaces de los tejidos con distinta impedancia acústica. Las imágenes que se generan en tiempo real permiten la identificación de variaciones del contenido de aire y fluidos en los pulmones [12]. En consecuencia, el UP permite valorar la efectividad de la maniobra de reclutamiento alveolar a través de una monitorización dinámica, optimizando la estrategia ventilatoria. Para realizar dicha evaluación con imágenes de UP se identifican una serie de patrones ecográficos [11] [13] :

- líneas A, patrones hiperecogénicos (oscuros), con una geometría horizontal y paralela a la línea pleural, asociadas a un pulmón normalmente aireado,

- líneas B, hiperecogénicas verticales (claras), que parten desde la pleura y alcanzan el final de la pantalla, asociadas a pérdida de aireación pulmonar,
- patrón de consolidación pulmonar con broncogramas aéreos, que se asocia a la pérdida completa de aireación.

Los diferentes signos ecográficos que permiten el diagnóstico de las distintas patologías pleuro-pulmonares en pacientes adultos se encuentran también en neonatos y niños críticamente enfermos [2].

Este trabajo avanza en la dirección de desarrollar una herramienta de soporte a la monitorización durante las MR, ayudando a la interpretación de la dinámica de los patrones ecográficos que se registran durante las mismas.

En un trabajo previo, se desarrolló un proceso que permitía analizar los cambios en la aireación pulmonar evaluando una secuencia ecográfica de video. Se emplearon técnicas de análisis temporal con Computación Granular a la que se le sumó un proceso de evaluación espacial de los resultados temporales [14].

Si bien se lograron algunos resultados alentadores en el diseño de potenciales indicadores de aireación en maniobras de reclutamiento, este método conlleva la limitación de la definición a priori de la región de interés a evaluar por parte del especialista. En particular, se procura abarcar la zona debajo de la línea pleural donde se generan las líneas A o B según el estado pulmonar correspondiente.

Con el fin de superar las limitaciones de la propuesta anterior, en este trabajo se procesa la secuencia de video directamente, sin un recorte de imagen previo más que delimitar la imagen ecográfica del resto de información que brindan los equipos, y se alimenta un proceso con redes neuronales artificiales con una arquitectura de aprendizaje profundo o *Deep Learning*.

El paradigma del *Deep Learning* cambia el abordaje clásico del Reconocimiento de Patrones en el que en la primera etapa se extraen y seleccionan características y en una segunda etapa se diseña el clasificador, donde el uso de las redes neuronales era frecuente. En *Deep Learning* la etapa de extracción de características se halla integrada en un único modelo conexionista [15].

En consecuencia, el objetivo del presente trabajo es la evaluación del nivel de aireación pulmonar utilizando las secuencias de ecografías capturadas en una ventana temporal (video) bajo el supuesto de que durante la misma existe un estado factible de identificarse. Para este fin, se clasifican una a una las imágenes de la secuencia y se genera un nivel de probabilidad de pertenencia de la secuencia a una clase predefinida de interés para quien monitorea el proceso.

Como resultado, se visualiza en colores en la totalidad de la secuencia de imágenes la probabilidad de la existencia de un tipo de patrón en cada una, facilitando la identificación del estado de aireación presente en la mayoría de las imágenes de la secuencia. Esta visualización ayuda a la interpretación rápida de secuencias de imágenes de UP, que tienen como característica una alta variabilidad y requiere gran experiencia y entrenamiento de recursos humanos para su diagnóstico.

Materiales y Métodos

A. Aprendizaje profundo

Las redes neuronales y el aprendizaje profundo han mostrado su eficacia como un marco de aprendizaje unificado para la extracción de características y el modelado de datos. El aprendizaje profundo, que es una rama del aprendizaje automático (*Machine Learning*), se considera un enfoque de aprendizaje de representación que puede procesar directamente y aprender automáticamente características abstractas de nivel medio y alto adquiridas de datos sin procesar (por ejemplo, imágenes de US). Se considera que, en relación con la caracterización de fenómenos espacio-temporales, se ha logrado con esta técnica un progreso significativo [15].

El aprendizaje profundo se ha convertido recientemente en la herramienta de aprendizaje automático líder en varios campos de investigación, y especialmente en el análisis de imágenes y la visión por computadora. Desde que *AlexNet* [16], una red neuronal convolucional profunda, ganó el desafío de reconocimiento visual a gran escala *ImageNet 2012* (ILSVRC), el aprendizaje profundo comenzó a llamar la atención en el campo del aprendizaje automático.

Un año más tarde, el aprendizaje profundo fue seleccionado como una de las diez tecnologías más avanzadas [17], lo que consolidó aún más su posición como la herramienta de aprendizaje automático líder en varios dominios de investigación, y particularmente en el análisis de imágenes en general (incluido el análisis de imágenes médicas y naturales) y visión por computadora.

El *Deep Learning* evidencia un gran potencial para varias tareas automáticas de análisis de imágenes de ultrasonido. Estas imágenes presentan desafíos únicos para el reconocimiento de patrones, como la baja calidad de imagen causada por el ruido y los artefactos, la dependencia de la experiencia de quien realiza el diagnóstico, y la alta variabilidad inter- e intra-observadores. Para abordar estos desafíos, es esencial desarrollar métodos automáticos avanzados de análisis de

imágenes de ultrasonido para el diagnóstico, como así también para el guiado por imágenes de intervenciones y/o terapias, logrando que sean más objetivas, precisas e inteligentes [18].

Las arquitecturas de aprendizaje profundo que se utilizan en la mayoría de los trabajos actuales en este campo se pueden clasificar en tres clases principales: a) redes neuronales supervisadas, b) redes no supervisadas y c) redes híbridas. Los modelos básicos o arquitecturas aplicadas en el análisis médico actual de ultrasonido son, principalmente, redes neuronales convolucionales (CNN), redes neuronales recurrentes (RNN), redes de creencias profundas (RDB), autocodificadores y variantes de estas arquitecturas de aprendizaje profundo. El término "híbrido" como tercera categoría se refiere a la arquitectura profunda que comprende o hace uso de componentes del modelo supervisado y no supervisado [18].

El éxito de este tipo de aprendizaje se basa en la disponibilidad de una cantidad grande de muestras de entrenamiento (en este caso, imágenes de UP) etiquetadas para lograr un excelente rendimiento. Sin embargo, este requisito es difícil de lograr en aplicaciones del campo del UP, donde el etiquetamiento experto es costoso y donde algunas enfermedades (por ejemplo, lesiones o nódulos) son escasas en los conjuntos de datos.

La cuestión de cómo entrenar un modelo de este tipo utilizando una muestra de entrenamiento limitada se ha convertido en un desafío abierto en el análisis de imágenes de US. Uno de los problemas más comunes cuando se usan muestras de entrenamiento limitadas es que es altamente probable el sobre-entrenamiento del modelo, hecho que conlleva a bajar el error de entrenamiento y aumenta el error en los casos de uso. Para abordar este problema, se propone el uso del denominado aprendizaje por transferencia (*Transfer Learning*), utilizado con éxito en casos de imágenes de US. Este método evita costosos esfuerzos de etiquetado de datos en la aplicación de un dominio específico.

Supongamos que la tarea T1 (de origen) es identificar objetos en imágenes dentro de un dominio restringido D1 (de origen). Dado el conjunto de datos para esta tarea T1, se entrena un modelo y se lo ajusta para que funcione correctamente (*i.e.*, que generalice) en casos no presentados durante el entrenamiento, suponiendo que estos casos pertenecen al mismo dominio D1. Supongamos que ahora se requiere detectar objetos de imágenes pertenecientes a otro dominio D2 (de destino), tarea T2 (de destino). Idealmente, sería factible aplicar el modelo entrenado para la tarea de origen T1, pero, en realidad, se lograría una degradación del rendimiento y el modelo no generalizaría bien. Esto sucede

debido al sesgo del modelo en función de los datos y tareas provistas para su entrenamiento [19].

El aprendizaje por transferencia es un paradigma que permite utilizar el conocimiento de las tareas aprendidas previamente y aplicarlas a otras nuevas relacionadas con aquellas. Si se tienen significativamente más datos para la tarea de origen T1, podemos utilizar su aprendizaje y generalizar este conocimiento (características, pesos) para la tarea de destino T2 (que tiene significativamente menos datos). En el caso de problemas en el dominio de la visión por computadora, ciertas características de bajo nivel, como bordes, formas, esquinas e intensidad, se pueden compartir entre tareas y, por lo tanto, permiten la transferencia de conocimiento entre ellas.

Según Pan y Yang [19], el aprendizaje por transferencia se clasifica en tres entornos:

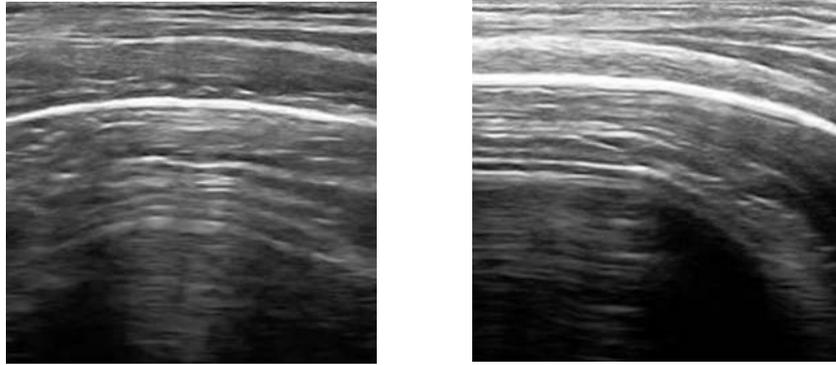
- aprendizaje de transferencia **inductivo**, en el que las tareas de destino (T2) y de origen son diferentes (T1), independientemente de si los dominios de destino (D2) y de origen (D1) son iguales o no;
- aprendizaje de transferencia **transductiva**, en el que la tarea de destino es la misma que la tarea de origen, mientras que los dominios de destino son diferentes de los dominios de origen;
- el aprendizaje de transferencia **no supervisado**, que es similar al aprendizaje de transferencia inductivo, excepto que la tarea objetivo difiere, pero está relacionada con la tarea de origen.

En la presente propuesta se aborda el enfoque de aprendizaje de transferencia inductivo, utilizando las redes *AlexNet*, *MobileNet* y *VGG19* que permitirán extraer características de una nueva tarea de dominio, utilizando conocimiento de una tarea de dominio fuente. Este es uno de los métodos más utilizados para realizar el aprendizaje de transferencia utilizando redes neuronales profundas [20].

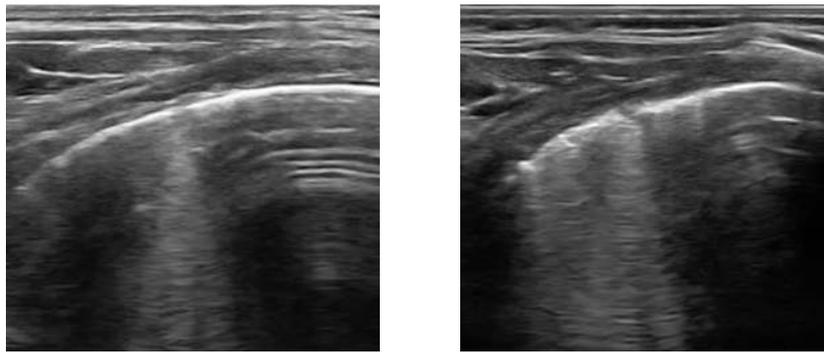
B. Fuentes de datos

Se dispone de videos de ecografías pulmonares adquiridas en diferentes pacientes a los que se les aplicaron maniobras de reclutamiento, resultando en videos correspondientes a diferentes situaciones de reclutamiento (variación de la PEEP, presión positiva al final de la espiración). Para el presente trabajo, los médicos especialistas seleccionaron pacientes de los que se disponía de información clínica y patologías previas, contando con al menos 2 estados para cada uno. Se procesaron 212 videos hasta el momento.

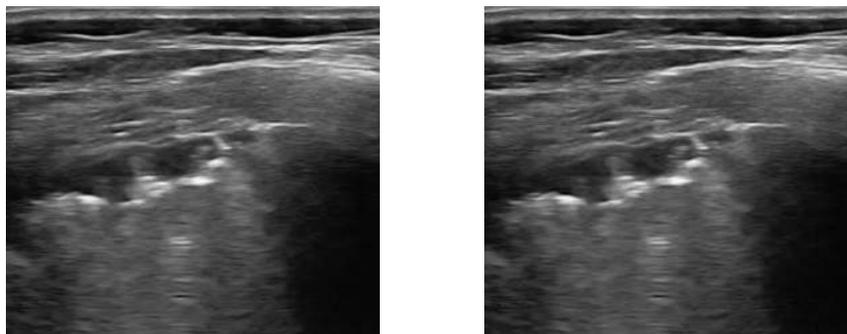
Para la etapa del entrenamiento del sistema propuesto se pidió a dos expertos, médicos especialistas en imágenes ecográficas de pulmón, que etiquetaran imágenes de algunos de los videos, al azar, con alguna de las denominaciones (clases): “Normal”, “Líneas B” o “Consolidación”, que, como se describió en la sección anterior, corresponden al estado de aireación pulmonar total, colapso (aireación parcial) o ausencia de aireación, respectivamente.



Casos con etiqueta “Normal”



Casos con etiqueta “Lineas B”



Casos con etiqueta “Consolidación”

Fig. 1: Ejemplos de imágenes provenientes de diferentes secuencias, etiquetadas por expertos, correspondientes a las clases por detectar.

Este etiquetado no es trivial, pues hay estados intermedios en que no es sencillo asignar la clase, y, además, es altamente demandante de tiempo y esfuerzo visual

por parte del experto. Solo se tomaron imágenes con patrones relativamente bien definidos. Así se armó un conjunto de 553 imágenes etiquetadas: 127 de la clase “Normal”, 286 de la clase “Líneas B” y 140 de la clase “Consolidación”. Este aparente desbalanceo en los datos se debe a que la clase “Líneas B” contiene una diversidad de situaciones muy superior a la observada en las otras clases. En la Fig. 1 se muestran dos ejemplos para cada una de las clases.

Debe destacarse que, a diferencia de trabajos previos, las imágenes no han sido procesadas por ningún tipo de filtrado o mejora de contraste o brillo, delegando toda la tarea de la etapa de extracción de características (imagen a vector) y la etapa de clasificación (vector a clase) en el algoritmo de clasificación.

En una segunda etapa se consideró el desafío, aún no totalmente resuelto automáticamente en la literatura, de la diferenciación de dos posibles estados de “Líneas B”, que denotan diferentes condiciones de aireación. Se las denominó “Líneas B1” y “Líneas B2”. Estos patrones han sido definidos con precisión y se utilizan en forma corriente en el diagnóstico visual, subjetivo, mediante la observación de la imagen de UP.

En esta segunda etapa, los especialistas tomaron nuevas imágenes para tener ahora cuatro estados (clases) a reconocer: “Normal”, “Líneas B1”, “Líneas B2” y “Consolidación”. Como se puede observar en la Fig. 2, los patrones B1 y B2 son complejos de reconocer, aun visualmente.

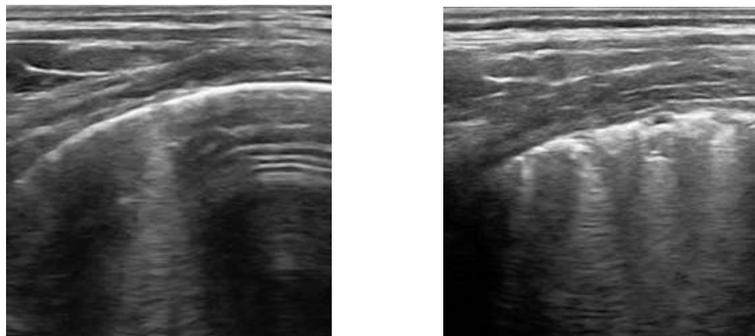


Fig. 2: Ejemplos de imágenes provenientes de diferentes secuencias, etiquetadas por expertos, correspondientes a las clases con etiquetas Líneas B1” (izquierda) y “Líneas B2” (derecha).

C. Métodos propuestos

Transfer learning con AlexNet

Se partió de la red *AlexNet*, a la cual se le reemplazó el clasificador (últimas 3 capas) para que se adapten al presente conjunto de datos. Estas consisten en una capa de 50 neuronas totalmente conectadas a la capa de características, una capa de tipo *Softmax*, y una capa final de clasificación. La capa *Softmax* es de relevancia

en este trabajo, puesto que se utilizan sus salidas (probabilidades de las diferentes clases), además de la decisión final de la asignación de una clase. Se trabajo

Aplicando el paradigma de aprendizaje por transferencia, solo se entrenó la sección del clasificador con el primer conjunto de imágenes que contiene 3 clases de pertenencia. Los pesos de las capas convolucionales permanecen fijos.

Se cambió el tamaño de las imágenes para que queden del tamaño que requiere *AlexNet*, esto es, 227x227 píxeles. Como las imágenes de US son en escala de gris y *AlexNet* espera imágenes RGB, se repitieron las intensidades en los tres canales. Así, cada caso de entrenamiento queda compuesto por un tensor de 227x227x3 elementos y su respectiva etiqueta.

Se entrenó la red durante 10 épocas, valor fijado luego de comprobar la estabilidad del error de entrenamiento y el consecuente error de validación, minimizando la entropía cruzada. Se utilizaron 15 lotes parciales (*minibatches*) para el algoritmo de aprendizaje por descenso por el gradiente calculado en el *minibatch*, separando aleatoriamente los datos en 70% para entrenamiento y 30% para validación, repitiendo este proceso 50 veces. Esto permitió estimar el error de validación (método de validación cruzada *Hold-out*).

Se obtuvo entonces la red entrenada final (utilizando la totalidad de los datos, entrenando con idénticas condiciones a las realizadas en el proceso de *Hold-out*). Se hallaron los valores de salida, es decir, los valores de pertenencia (interpretados como probabilidades) a cada una de las tres clases, para cada *frame* de cada video seleccionado para este estudio.

Finalmente, para extraer una conclusión de cada video, se extrae la mediana de los valores de las pertenencias a cada clase y se efectúa un test de hipótesis no paramétrico (Kruskal-Wallis) para cuantificar la confiabilidad de la clasificación efectuada, si se etiquetara al video como la clase más probable.

A pesar de obtener resultados muy prometedores (como se mostrará más adelante) cuando se intentó hacer la expansión del modelo a un clasificador con 4 categorías (normal, líneas B1, líneas B2, consolidación) el comportamiento estuvo por debajo de lo aceptable. Por esta razón se decidió explorar otras arquitecturas de RNN.

Transfer learning con MobileNet

Se describe en esta sección lo realizado partiendo de la red de dominio público denominada *MobileNet*. Utilizando la misma metodología que se usó con la *AlexNet*, se reemplazó el clasificador. El mismo consiste en una capa de *Max Average Pooling* que calcula el promedio de cada mapa de características de la

capa anterior. A continuación, dos capas de 1024 neuronas totalmente conectadas y finalmente la capa de clasificación con neuronas de activación tipo *Softmax* como las utilizadas en *AlexNet*.

Nuevamente, solo se entrenó el clasificador que se agregó. Se utilizó el mismo conjunto de imágenes conservando los pesos de las capas convolucionales.

Se cambió el tamaño de las imágenes a 224x224 píxeles y los valores de intensidad de los píxeles fueron escalados para que estén contenidos entre -1 y 1 como lo requiere el modelo.

Se entrenó la red durante 50 épocas, con un tamaño de lotes de 64 muestras, valor establecido luego de ensayos con diferentes cantidades de épocas y tamaño de lotes. El algoritmo de aprendizaje utilizado fue *Adam* el cual está basado en el gradiente estocástico [21]. Se separaron los datos aleatoriamente en dos subconjuntos conteniendo el 85% para entrenamiento y 15% para validación. Se repitió el proceso 100 veces y se estimó el error de validación (método de validación cruzada *Hold-out*). Al final de cada entrenamiento se calcularon y almacenaron las métricas *accuracy* (precisión) y *loss* (pérdidas) así como también la predicción sobre cada uno de los ejemplos (validación y entrenamiento) para un posterior análisis.

Accuracy se puede interpretar como el porcentaje de aciertos del modelo al predecir una clase:

$$Accuracy = \frac{\text{cantidad de imágenes correctamente clasificadas}}{N}$$

donde N es la cantidad de imágenes de entrenamiento. La clase asignada a la imagen es la que presenta mayor probabilidad.

Loss es la función de costo que la red procura minimizar durante el entrenamiento. A lo largo de todo este trabajo se utilizó la función entropía cruzada, definida como:

$$Loss = -\frac{1}{N} \sum_n \sum_{j=1}^K [t_j \ln y_j^L + (1 - t_j) \ln(1 - y_j^L)]$$

K es la cantidad de salidas de la red, coincidente con la cantidad de clases, t_j son los valores deseados o *targets* (en este tipo de aplicaciones son siempre 0 o 1), y_j^L son las salidas de la red (última capa, denotada genéricamente como L).

Luego del proceso de estimación del error, se obtuvo la red entrenada final utilizando la totalidad de los datos, entrenando con idénticas condiciones a las realizadas en el proceso de *Hold-out*.

Transfer learning con VGG19

El proceso utilizado con la red VGG19 es idéntico al utilizado con *MobileNet*, se utilizó la misma estructura para el clasificador y las mismas imágenes de entrenamiento. La única diferencia está en el preprocesamiento en las imágenes, la intensidad de los píxeles se centra a 0 sin reescalado.

El entrenamiento se realiza bajo las mismas condiciones que en *MobileNet* y se extrae la misma información.

Resultados

Comparación de resultados para *MobileNet* y *VGG-19* con 3 clases

De los datos recogidos de los 100 ciclos de *Hold-Out* de cada modelo se calculó la matriz de confusión en base a todas las imágenes (entrenamiento y validación) obteniéndose los siguientes resultados:

	MobileNet				VGG-19		
	Normal	Lineas B	Consolidación		Normal	Lineas B	Consolidación
Normal	5454	46	0	Normal	5381	98	21
Lineas B	45	2541	214	Lineas B	83	2542	175
Consolidación	15	184	2601	Consolidación	80	233	2487
Normal	0.989	0.017	0.000	Normal	0.971	0.034	0.008
Lineas B	0.008	0.917	0.076	Lineas B	0.015	0.885	0.065
Consolidación	0.003	0.066	0.924	Consolidación	0.014	0.081	0.927

Fig. 3: Matrices de confusión correspondientes a la red *MobileNet* y *VGG-19* para 3 clases.

La matriz de confusión muestra la cantidad de ejemplos que perteneciendo a la clase mostrada en la fila que fueron clasificados como la clase perteneciente a la columna. Por ejemplo, en la red *MobileNet* la primera fila pertenece a la clase "Normal", en dicha clase 5454 imágenes que eran normales fueron clasificadas correctamente como normales, 46 clasificadas erróneamente como "Líneas B". Es decir, sobre la diagonal principal se agrupan todas las clasificaciones correctas mientras que fuera de la misma las imágenes erróneamente clasificadas. La

segunda matriz muestra la misma relación, pero en este caso como una proporción de las imágenes totales. En el caso de *MobileNet* “Líneas B” el 91.7% de las imágenes de esta categoría fueron correctamente clasificadas mientras que el 0.8% fueron clasificadas erróneamente como “Normal” y el 7.6% erróneamente como “Consolidación”.

Para realizar un análisis de la precisión del clasificador se construyó el *BoxPlot* que se muestra en la figura 4 correspondiente a los 100 ciclos. Se separó el análisis en datos de entrenamiento y de validación para los dos modelos (para información acerca de la interpretación de *boxplot* véase https://en.wikipedia.org/wiki/Box_plot).

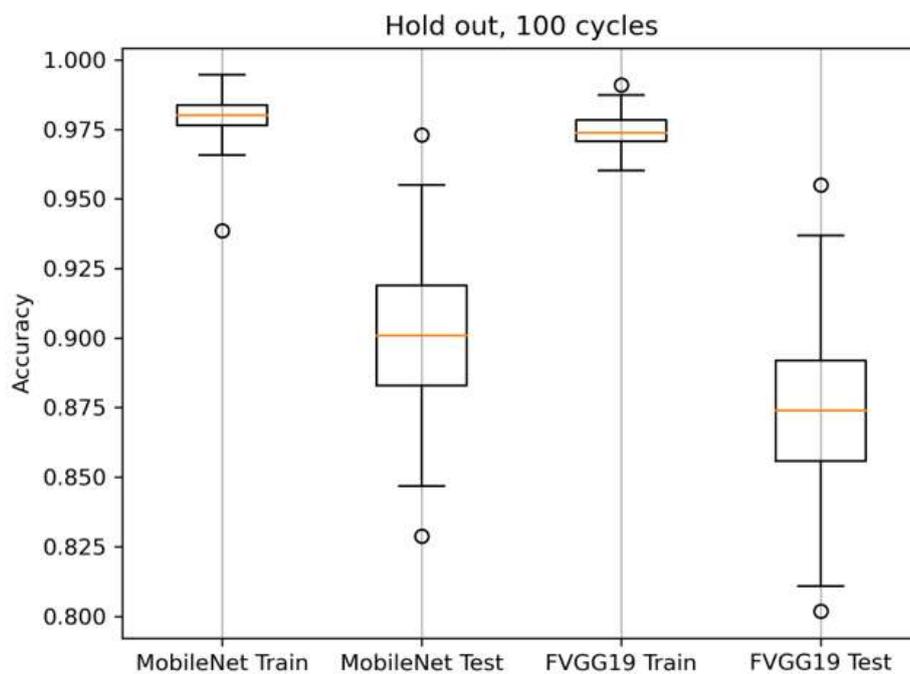


Fig. 4: BoxPlot para MobilNet y VGG-19 con 3 clases

De ambos resultados surge la conclusión de para el caso analizado MobilNet tiene un comportamiento superior frente a VGG-19

Comparación de resultados para *MobileNet* y *VGG-19* con 4 clases

Observando la matriz de confusión y el *Boxplot* nuevamente se puede apreciar la superioridad de *MobileNet* frente a *VGG-19* para el análisis de este tipo de imágenes.

MobileNet					VGG-19				
	Normal	Lineas B1	Lineas B2	Consolidación		Normal	Lineas B1	Lineas B2	Consolidación
Normal	2479	19	0	2	Normal	2443	16	0	41
Lineas B1	1	2440	441	18	Lineas B1	24	2366	479	31
Lineas B2	2	419	2377	102	Lineas B2	2	554	2273	71
Consolidación	10	17	77	2696	Consolidación	110	5	82	2603
Normal	0.995	0.007	0.000	0.001	Normal	0.947	0.005	0.000	0.015
Lineas B1	0.000	0.842	0.152	0.006	Lineas B1	0.009	0.804	0.169	0.011
Lineas B2	0.001	0.145	0.821	0.036	Lineas B2	0.001	0.188	0.802	0.026
Consolidación	0.004	0.006	0.027	0.957	Consolidación	0.043	0.002	0.029	0.948

Fig. 5: Matrices de confusión correspondientes a la red MobileNet y VGG-19 para 4 clases

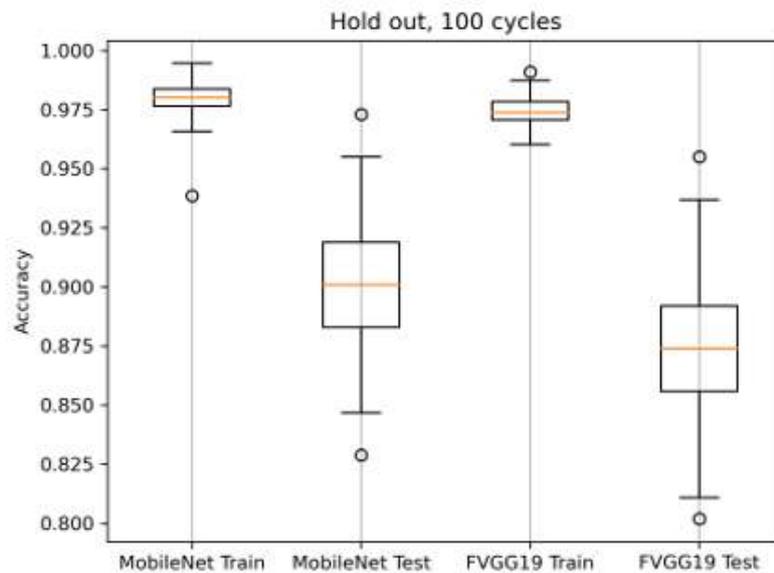


Fig. 6: BoxPlot para MobilNet y VGG-19 con 4 clases

Del análisis de los datos recogidos se concluyó que *MobileNet* presentó una precisión del orden del 90% sobre imágenes nuevas (que no fueron usadas durante el entrenamiento); por esta razón se continuó profundizando la investigación sobre esta red.

Ensamble de clasificadores

Para otorgarle robustez a la decisión de un clasificador se utiliza un ensamble de clasificadores. En este caso se entrenan cinco redes *MobileNet* con la totalidad de los datos, los cuales son mezclados antes de cada entrenamiento. Esto, sumado a

la inicialización aleatoria de los parámetros de entrenamiento (los pesos y de las conexiones entre neuronas del clasificador), resulta en modelos diferentes.

Cuando una nueva imagen es ingresada para ser clasificada, cada uno de los modelos hace una predicción independiente, otorgando las probabilidades de pertenencia a las diferentes clases. El resultado final está dado por el promedio de las probabilidades de cada modelo por clase (Figura 7). Como decisión final, igual que si utilizáramos un solo modelo, obtendremos un valor entre 0 y 1 para cada clase, que representa el grado de pertenencia a las mismas. Si se quiere asignar una clase concretamente, la clase que obtuvo la probabilidad o pertenencia más alta se toma como la clase predicha por el clasificador.

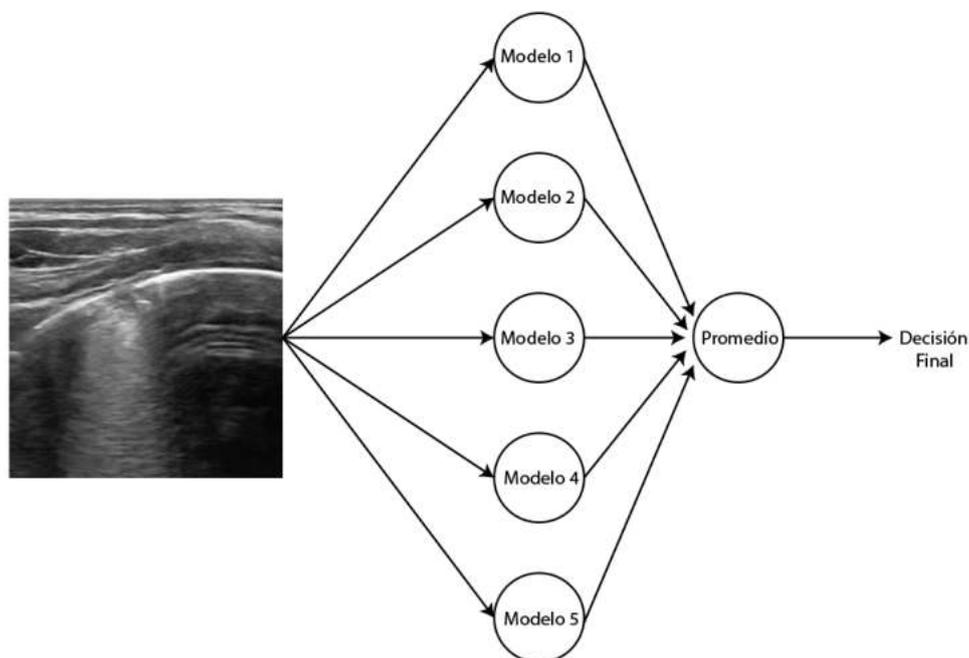


Fig. 7: Esquema genérico del ensamble de clasificadores

Otra manera de obtener la clase de pertenencia es por *polling* (votación). Cada modelo elige la clase más probable (máxima pertenencia). La clase más frecuente entre todos los modelos es la elegida como clasificación del ensamble.

Resultados en casos reales

Se realizó el análisis de más de 200 videos registrados en pacientes reales, utilizando el ensamble de clasificadores. Los videos fueron analizados *frame a frame*.

Luego se diseñó una visualización temporal que muestra *frame a frame*, en forma apilada, las probabilidades de pertenencia a las 4 posibles clases. También se muestran algunos *frames* de ejemplo, para facilitar su evaluación con una sola vista.

A continuación, se muestran los resultados de forma gráfica con esta visualización en un caso de ejemplo.

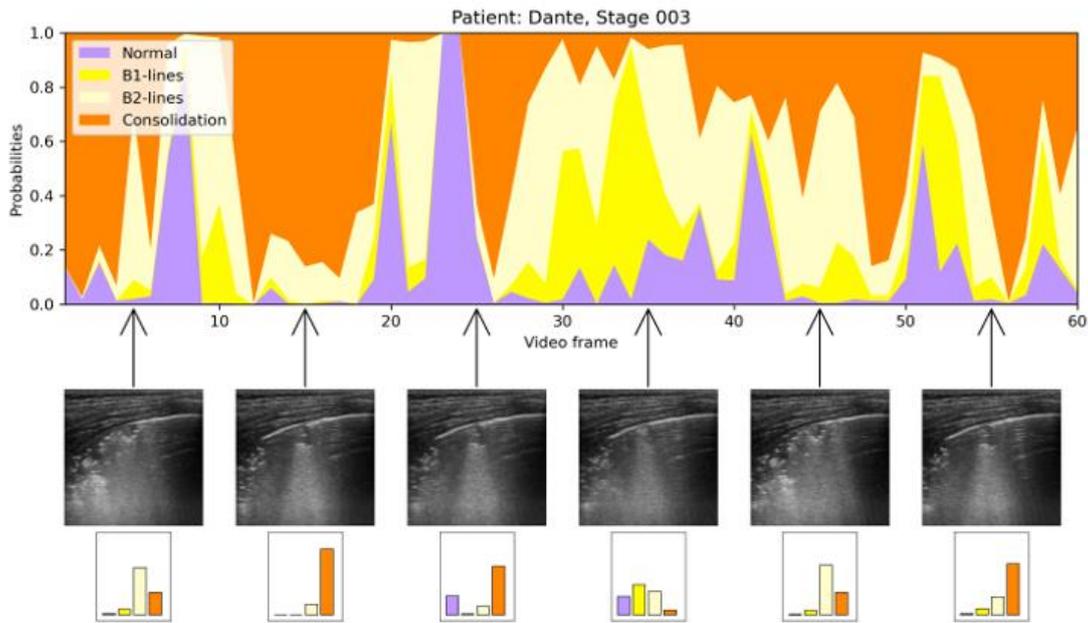


Fig. 8: Análisis del video "Stage 003" del paciente "Dante".

Para ayudar a la vista del video en contexto, se realizaron *boxplots* de las cuatro clases a lo largo de todos los *frames*. Esto permite ver si una clase predomina con otras.

Posteriormente, estos gráficos fueron mejorados utilizando *violin-plots*, que dan una visualización más clara de esta situación. En esta versión de este documento se mostrarán como ejemplo al introducir el desarrollo de una interfaz gráfica.

Se muestra a continuación la visualización con *boxplots* para el caso presentado anteriormente. Se observa la mediana más alta en la clase Consolidación, pero también hay presencia de las otras.

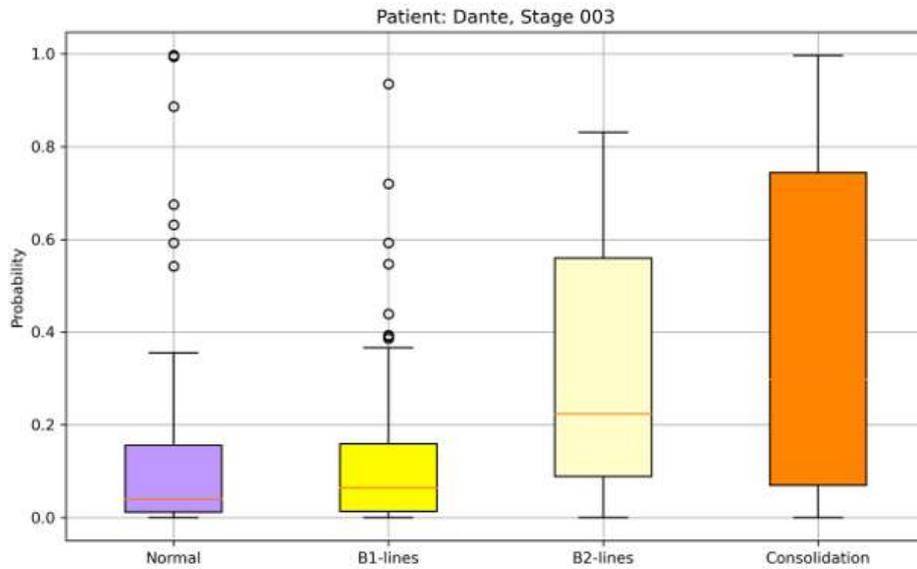


Fig. 9: Boxplot del video "Stage 003" del paciente "Dante".

En lo que sigue se dan ejemplos de estas dos visualizaciones para otros casos.

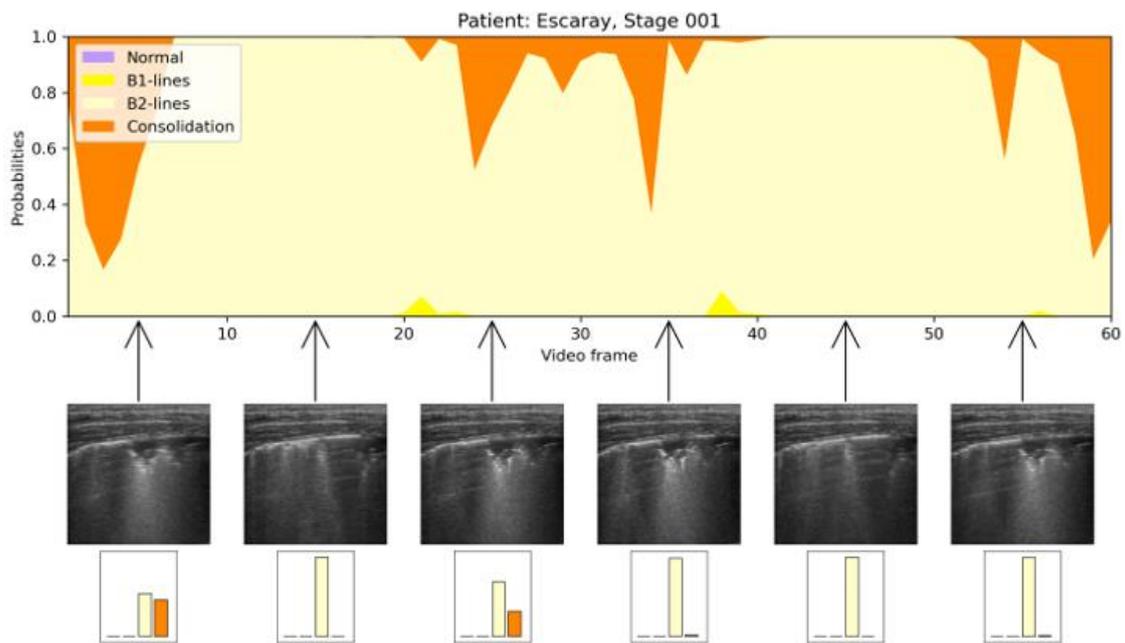


Fig. 10: Análisis del video "Stage 001" del paciente "Escaray".

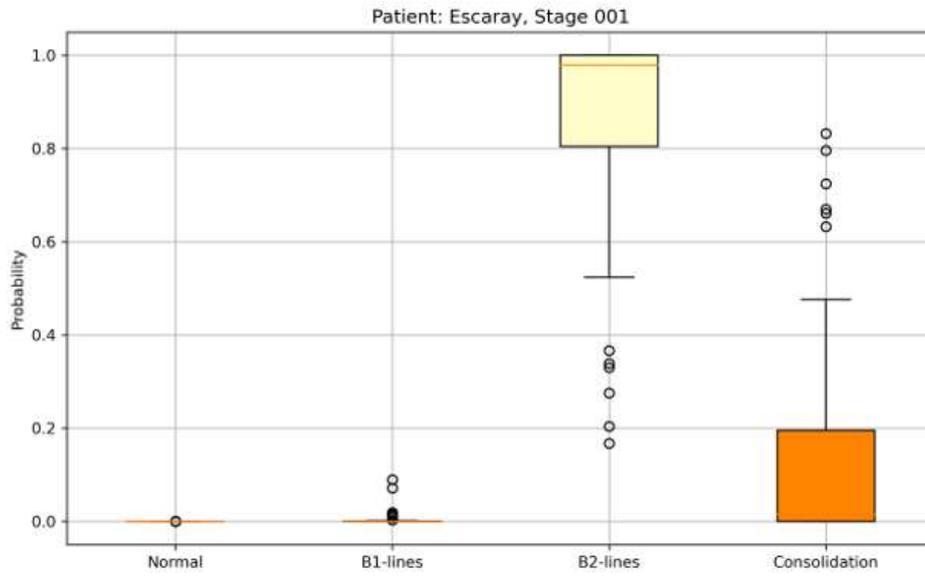


Fig. 11: Boxplot del video "Stage 001" del paciente "Escaray".

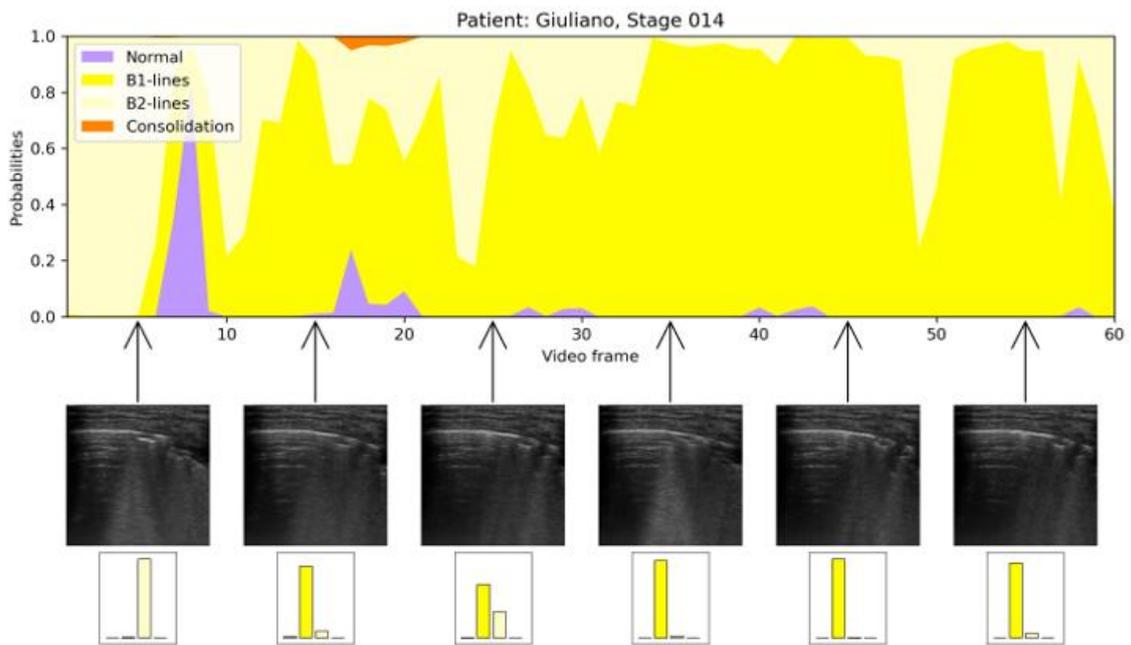


Fig. 12: Análisis del video "Stage 014" del paciente "Giuliano".

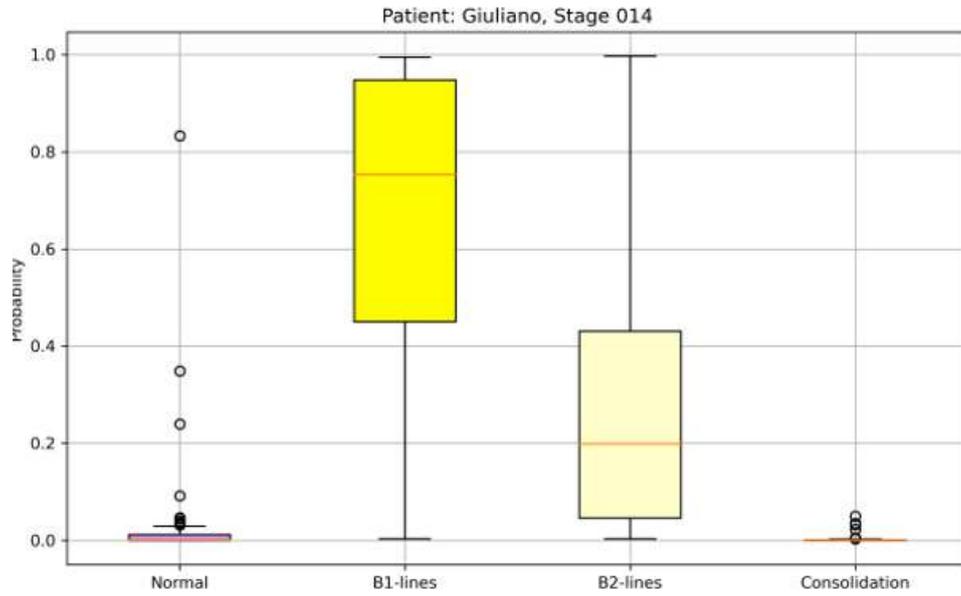


Fig. 13: Boxplot del video "Stage 014" del paciente "Giuliano".

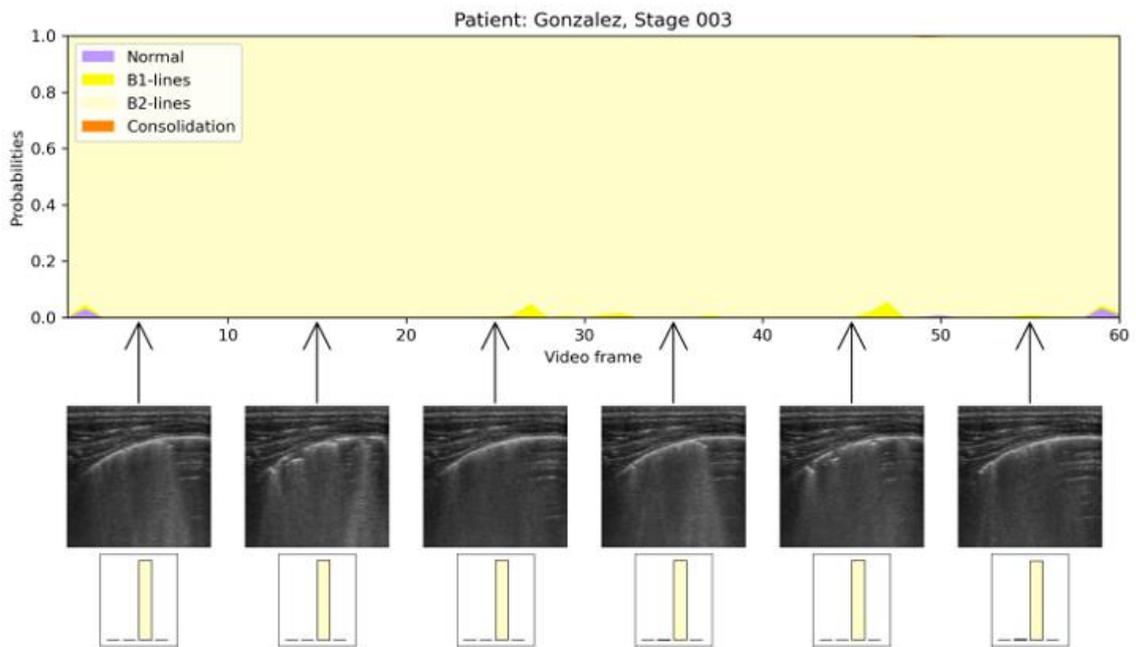


Fig. 14: Análisis del video "Stage 003" del paciente "Gonzalez".

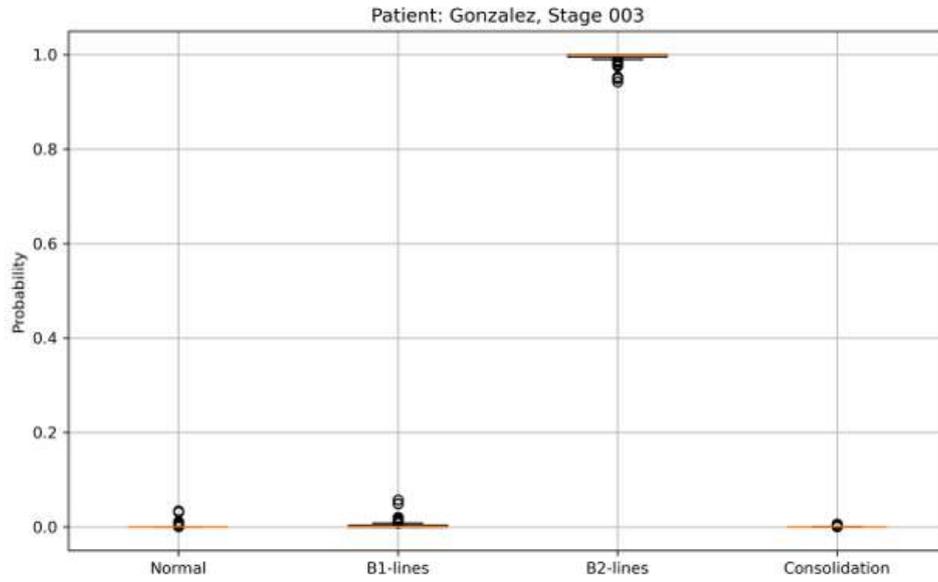


Fig. 15: Boxplot del video "Stage 003" del paciente "Gonzalez".

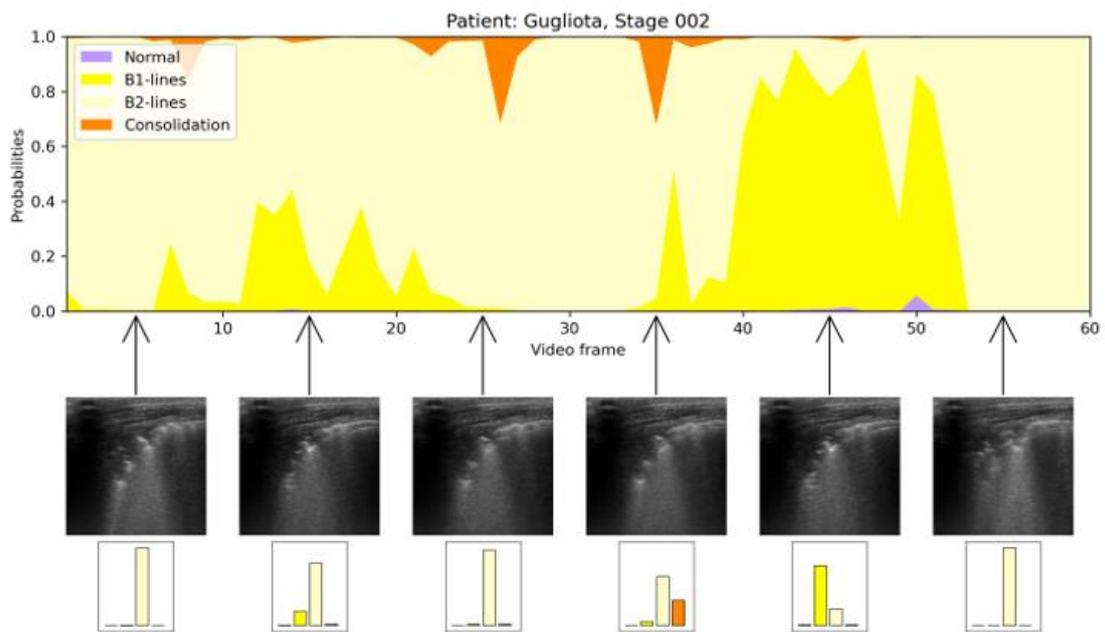


Fig. 16: Análisis del video "Stage 002" del paciente "Gugliota".

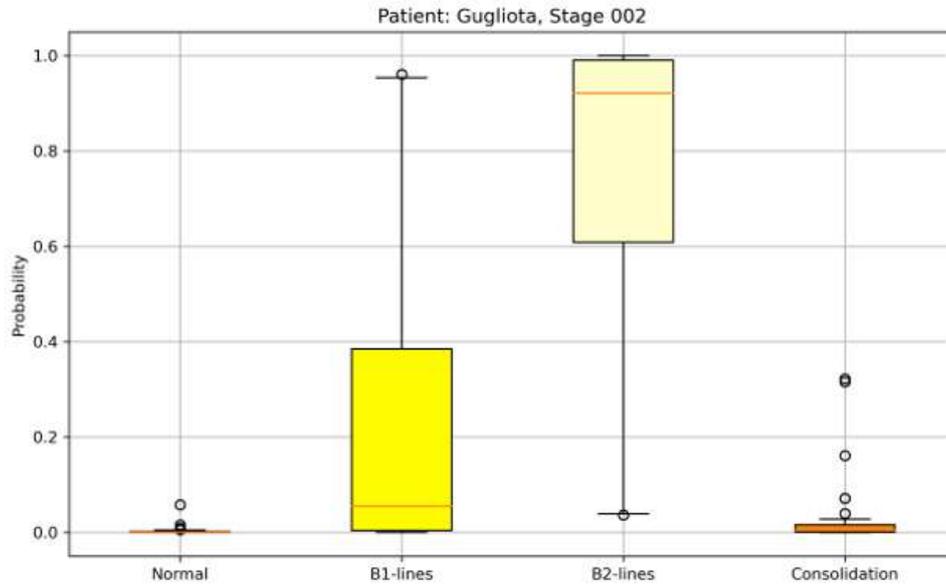


Fig. 17: Boxplot del video "Stage 002" del paciente "Gugliota".

En el ejemplo de la Figura 18 se analizó un paciente con condición normal (según los expertos consultados) y se puede apreciar el modelo realiza una predicción correcta en todos los *frames* y con un nivel de pertenencia alto.

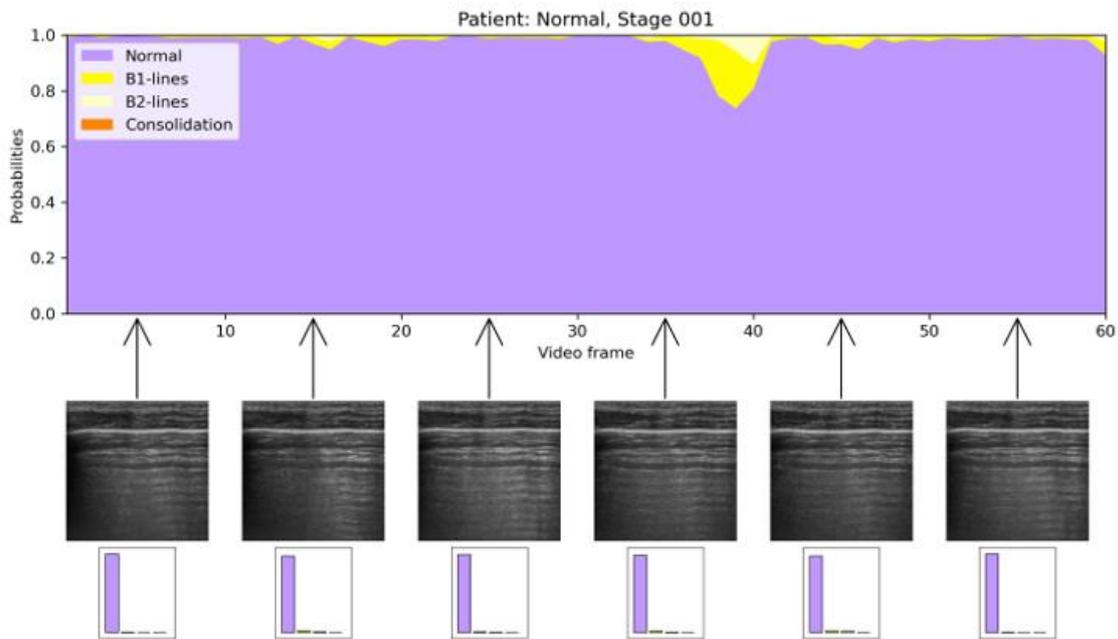


Fig. 18: Análisis del video "Stage 001" de un paciente cuya condición determinada por los expertos es "Normal".

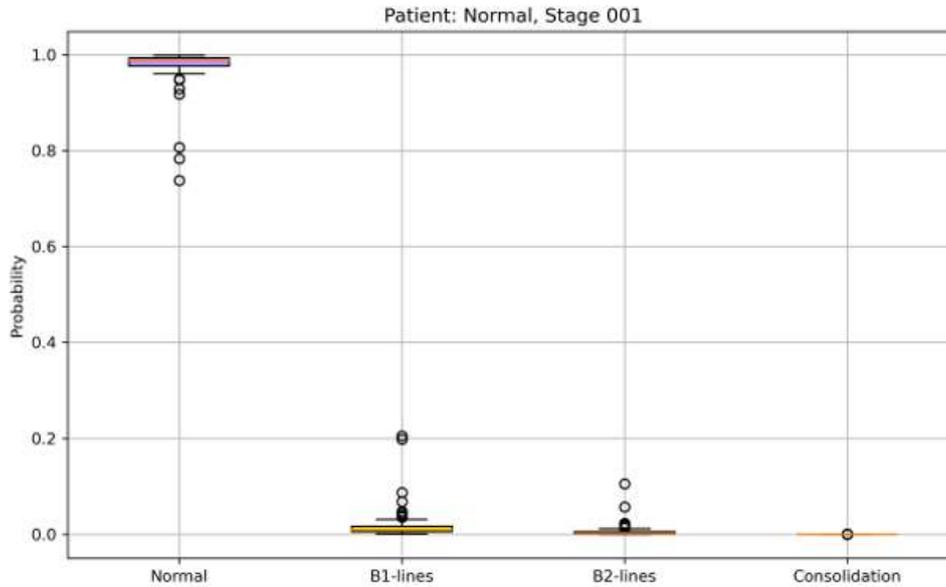


Fig. 19: Boxplot video "Stage 001" de un paciente cuya condición determinada por los expertos es "Normal".

Se detectaron en algunos casos, particularmente cuando el estado era "Consolidación", clasificaciones erróneas del modelo, como se muestra en la Figura 20. De una inspección visual con los expertos médicos y el resto del equipo de investigación se especuló que estos errores podían deberse a la poca cantidad de datos de entrenamiento, que hacen que el modelo no pueda generalizar apropiadamente cuando se le presenta variaciones que son diferentes con respecto a las que se usaron en el entrenamiento. Como solución, se plantean dos alternativas no mutuamente excluyentes:

- en conjunto con el equipo médico, etiquetar más imágenes para contar con una base de datos más amplia, considerando casos genéricos.
- espejar horizontalmente las imágenes, duplicando de manera computacional la cantidad de imágenes de entrenamiento. Esto se sustenta en el hecho de que este reflejo en el eje horizontal produce una imagen que podría haber sido registrada en una ecografía real, variando la posición del transductor ecográfico.

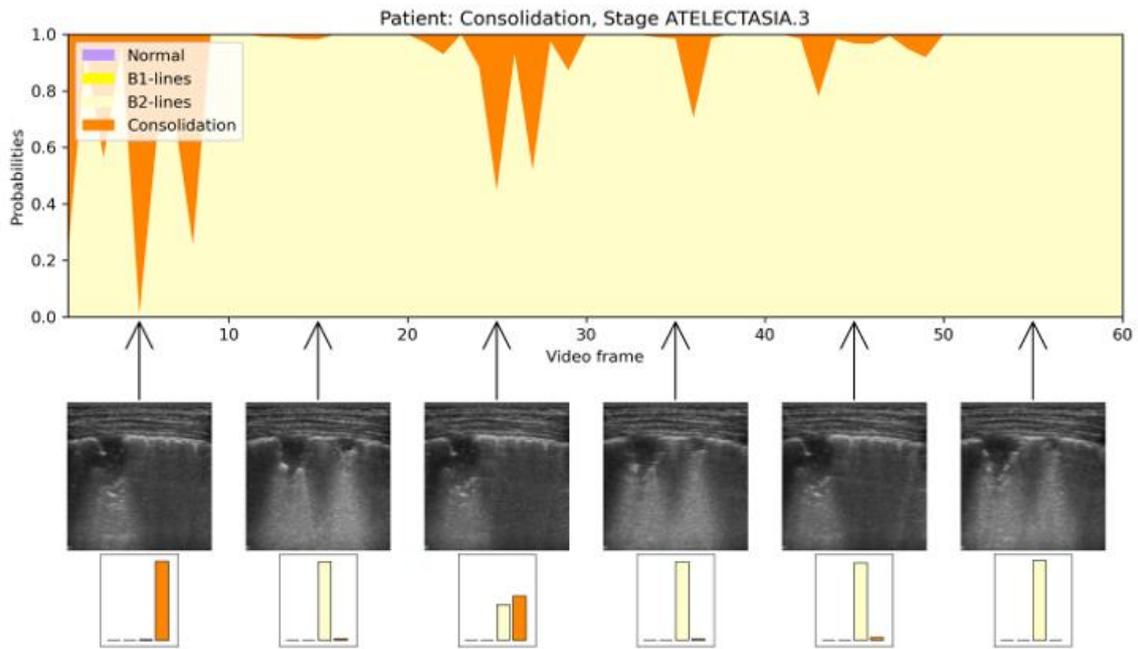


Fig. 20: Análisis del video "Stage ATELECTASIA.3" de un paciente cuya condición determinada por los expertos es "Consolidación".

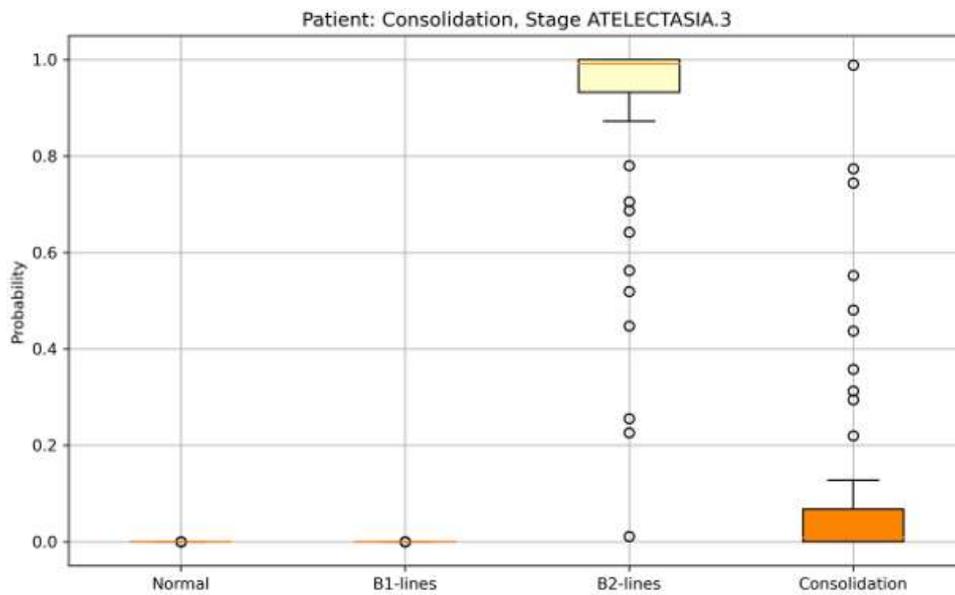


Fig. 21: Boxplot "Stage ATELECTASIA.3" de un paciente cuya condición determinada por los expertos es "Consolidación".

Cálculo de Scores

El procedimiento empleado actualmente como estándar para evaluar la condición del paciente bajo examinación se conoce como *Lung Ultrasound Score* (LUS). En esta propuesta, aplicada a pacientes que son invasivamente ventilados, el experto debe observar las imágenes ultrasónicas y valorar la condición según los patrones ecográficos reconocidos, asignándole a la adquisición (lo que en este trabajo hemos considerado “un video”) un *score* en el rango de 0 a 3, método que ya ha sido validado en el campo del estudio de ultrasonido pulmonar.

El score se asigna según el siguiente criterio [22]:

Estado pulmonar	Patrón observado	Clase	Score asignado
Normal	Líneas A horizontales, deslizándose.	Normal	0
Pérdida de aireación moderada	Múltiples Líneas B irregularmente espaciadas.	B1	1
Pérdida de aireación severa	Múltiples Líneas B coalescentes.	B2	2
Pérdida de aireación completa (consolidación pulmonar)	Imagen ecográfica típica de tejido sin aireación.	Consolidación	3

Como se puede deducir, la asignación de este *score* a un video es un proceso que requiere entrenamiento visual del operador, lo que lo transforma en operador-dependiente, incluso con cierto grado de subjetividad.

Para determinar computacionalmente este proceso se utilizó la probabilidad de clase *frame a frame* para generar un *score* que permita evaluar la condición del paciente de manera similar a como se hace en LUS. En esta propuesta se pretende:

- Mantener la interpretación del score como lo vienen haciendo los especialistas de todo el mundo hasta el momento.
- Lograr scores que no sean valores enteros en el rango 0 a 3, sino utilizar todo el rango numérico entre los mismos límites.

Se abordaron distintos enfoques para el cálculo, con el fin de contrastar, de manera determinística, las diferencias entre los valores dados por los especialistas por observación directa y lo obtenido computacionalmente.

Partiremos de las probabilidades de pertenencia a las cuatro clases (Normal, B1, B2 y Consolidación) en cada *frame* i , que denominaremos $p_0(i), p_1(i), p_2(i), p_3(i)$, respectivamente.

Promedio de scores

Se procede primero al cálculo de un *score* por *frame*, de la siguiente manera:

$$score(i) = p_1(i) + 2p_2(i) + 3p_3(i)$$

y luego se calcula el **promedio** de *scores* a lo largo de todos los *frames*:

$$score = \frac{1}{N} \sum_{i=1}^N score(i)$$

donde N es la cantidad de *frames* que componen el video.

Mediana de los scores

Se procede al cálculo por *frame* como en la propuesta anterior:

$$score(i) = p_1(i) + 2p_2(i) + 3p_3(i)$$

pero ahora se considera la **mediana** de los *scores* a lo largo de todos los *frames*:

$$score = mediana[score(i)], \quad i = 1, 2, \dots, N$$

donde N es la cantidad de *frames* que componen el video.

Como puede deducirse, los valores obtenidos en los dos casos anteriores no son enteros, sino que abarcan el rango $[0,3] \in \mathbb{R}$. Se pueden así obtener condiciones intermedias entre los casos establecidos en el sistema LUS.

Score probabilístico

En esta propuesta se asigna una clase a cada *frame*, denotada como $C(i)$, según la que presenta la probabilidad máxima.

Luego se busca la clase mayoritaria en todos los *frames* que componen el video y se informa el *score* correspondiente según la tabla anterior. En este caso también se informa el porcentaje de *frames* que presentaron esa clase, como información adicional de confiabilidad del *score* calculado.

Algoritmo Fuzzy

En este caso se aplican conceptos de lógica difusa. Se define una proposición por cada clase detectable y se evalúa luego el valor de verdad de estas.

$P_0(i) =$ "El frame corresponde a la clase Normal",

$P_1(i) = \text{"El frame corresponde a la clase B1"}$,

$P_2(i) = \text{"El frame corresponde a la clase B2"}$,

$P_3(i) = \text{"El frame corresponde a la clase Consolidación"}$.

Se asigna el valor de verdad de cada una de estas proposiciones según la probabilidad obtenida por la red neuronal. Cabe destacarse que, de utilizarse este paradigma, no sería necesaria la capa *Softmax* al final, puesto que los valores de verdad no tienen por qué sumar 1.

Luego se evalúa el predicado general que propone:

$P_0(\text{video}) = \text{"El video corresponde a la clase Normal"}$;

$P_1(\text{video}) = \text{"El video corresponde a la clase B1"}$;

$P_2(\text{video}) = \text{"El video corresponde a la clase B2"}$;

$P_3(\text{video}) = \text{"El video corresponde a la clase Consolidación"}$.

Estos casos se pueden expresar utilizando el operador "para todo", proponiendo que el video corresponde a una determinada clase cuando todos los *frames* corresponden a esa clase:

$$P_{CLASE}(\text{video}) = \bigvee_{i=1}^N P_{CLASE}(i)$$

Así se obtienen las pertenencias (ya no hablamos de "probabilidades") a las clases. Finalmente, el *score* se calcula con una expresión similar a la presentada al asignar los *scores* a los *frames*:

$$\text{score}(\text{video}) = \mu[P_{B1}(\text{video})] + 2\mu[P_{B2}(\text{video})] + 3\mu[P_{CONSOLIDACIÓN}(\text{video})]$$

denotando el operador $\mu(P)$ como "el valor de verdad de la proposición P ".

Si se utilizan los operadores de la lógica compensatoria, que ha sido empleada con gran éxito en este tipo de aplicaciones, la operación a realizar sería:

$$\mu[P_{CLASE}(\text{video})] = \sqrt[N]{\prod_{i=1}^N p_{CLASE}(i)}$$

siendo $p_{CLASE}(i)$ la probabilidad asignada por la red neuronal para el *frame* i de pertenecer a la clase *CLASE*.

Esta última forma de calcular el *score* falla cuando alguna de las probabilidades es nula absolutamente. Se seguirá trabajando en este sentido. Se experimentará asignando un infinitésimo para estos casos, pero estas pruebas exceden el objetivo de este informe.

A continuación, se da un ejemplo para 3 *frames*, para poder observar los resultados obtenidos:

Frame	$p_0(i)$	$p_1(i)$	$p_2(i)$	$p_3(i)$	CLASE	SCORE propuesto
#1	0,1	0,6	0,2	0,1	1	1,3
#2	0	0,4	0,5	0,1	2	1,7
#3	0,2	0,7	0,1	0	1	0,9
Promedio	0,1	0,57	0,27	0,07	1	1,3
Mediana	0,1	0,6	0,2	0,1	1	1,3
Probabilístico	-	-	-	-	-	1 (67%)
Fuzzy	0	0,55	0,22	0	1	0,98

Las tres primeras filas suponen valores que podrían obtenerse como salidas de la red neuronal (o del ensamble, como se hizo). La columna "CLASE" para estas 3 filas asigna una clase al *frame*, según la máxima probabilidad. La columna "SCORE propuesto" muestra el cálculo del score para cada *frame* según la ecuación dada anteriormente.

La fila "Promedio" muestra los promedios de las probabilidades de todos los *frames* para las cuatro clases, la clase según la probabilidad promedio máxima y el *score* calculado con los promedios de probabilidades.

La fila "Mediana" muestra las medianas de las probabilidades de todos los *frames* para las cuatro clases, la clase según la probabilidad máxima obtenida con las medianas y el *score* calculado con las medianas (en este ejemplo particular, coinciden ambos valores, promedio y mediana).

La fila "Probabilístico" muestra la clase mayoritaria, considerando las clases asignadas a cada *frame* por probabilidad máxima, y, entre paréntesis, el porcentaje de *frames* del video en que esta clase apareció.

La fila "Fuzzy" muestra la pertenencia (el valor de verdad) de todos los *frames* para las cuatro clases, la clase asignada al video según pertenencia máxima y el *score* calculado con los valores de verdad.

Estos métodos tienen la limitación de que pesan las cuatro clases por igual. En la asignación por observación, los especialistas ponderan con más fuerza a los *frames* que tienen los peores estados de aireación, por lo cual hay que seguir trabajando con estas fórmulas para reflejar esta consideración. Esto queda asignado al trabajo futuro de esta investigación.

Aún no estamos en condiciones de decir cuál es el mejor enfoque, pues esto está en proceso de discusión con los especialistas. Por el momento hemos detectado que los valores calculados se ajustan muy bien a los valores determinados por observación en los casos extremos y en los casos en que no hay errores de clasificación en casi ningún *frame*, de parte del sistema desarrollado.

Interfaz de usuario

Durante la investigación se encontraron diferentes desafíos. Por un lado, los videos recibidos para el análisis debían ser recortados para extraer la zona de interés, como se muestra en la Figura 23.



Fig. 23: Videos sin editar con la zona de interés demarcada.

Esto implicaba extraer los *frames*, recortarlos y agruparlos secuencialmente para su análisis. Dado que los videos provienen de distintos equipos a menudo la zona de recorte difería de un video a otro lo que implicaba realizar manualmente la tarea de reconocimiento de los límites. Por otro lado, el formato de video no es único lo que hacía necesario una frecuente actualización del código de Python que realizaba la extracción de *frames*. Además, luego del análisis el análisis y generación de gráficas para visualizar los resultados se realizaba en forma separada lo cual consume un tiempo considerable.

Teniendo en cuenta todas las problemáticas antes expuestas se decide crear una interfaz gráfica de usuario (que se denominó *Lung US Analyzer*) que agilice la tarea, integrando muchas de las características descriptas, y sin requerir ningún conocimiento de programación.

Lung US Analyzer

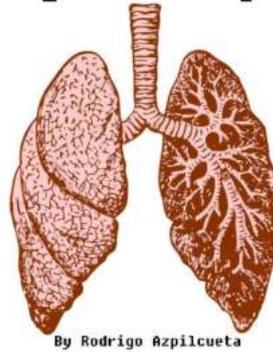


Fig. 24: Presentación de la interfaz.

La pantalla principal (figura 25) cuenta con 4 pestañas. Una principal (*Lung Us Analyzer*) donde se gestionan todas las funcionalidades del programa y las pestañas *Graph 1*, *Graph 2*, *Graph 3* donde se exhiben los gráficos generados a partir del análisis del video cargado. Para cargar un video a analizar se debe hacer clic en el botón "open file".

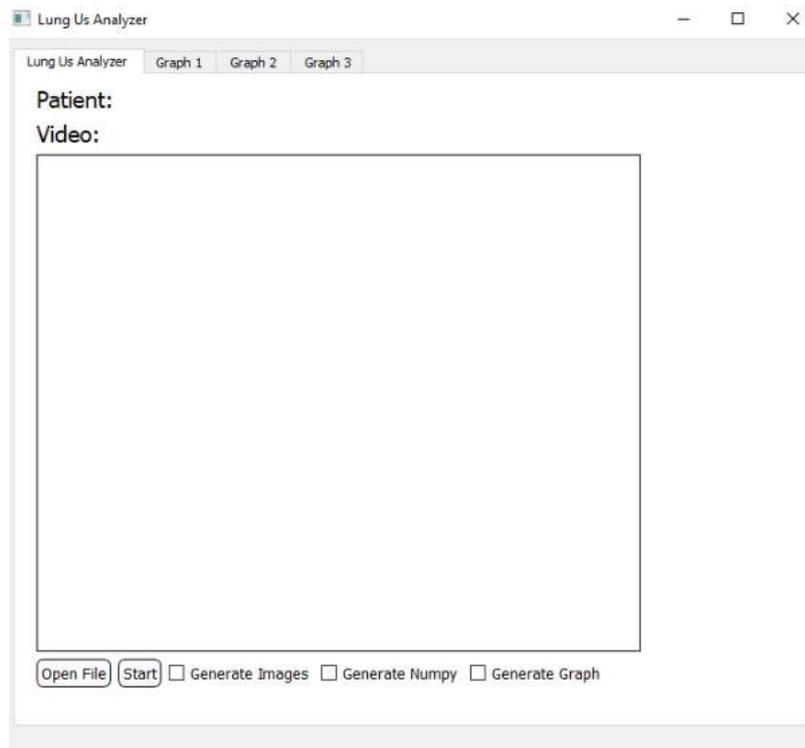


Fig. 25: Pantalla principal de la interfaz

Esto abre una ventana de dialogo (figura 26) que permite al usuario navegar en los archivos disponibles en la PC reconociendo diferentes formatos de videos.

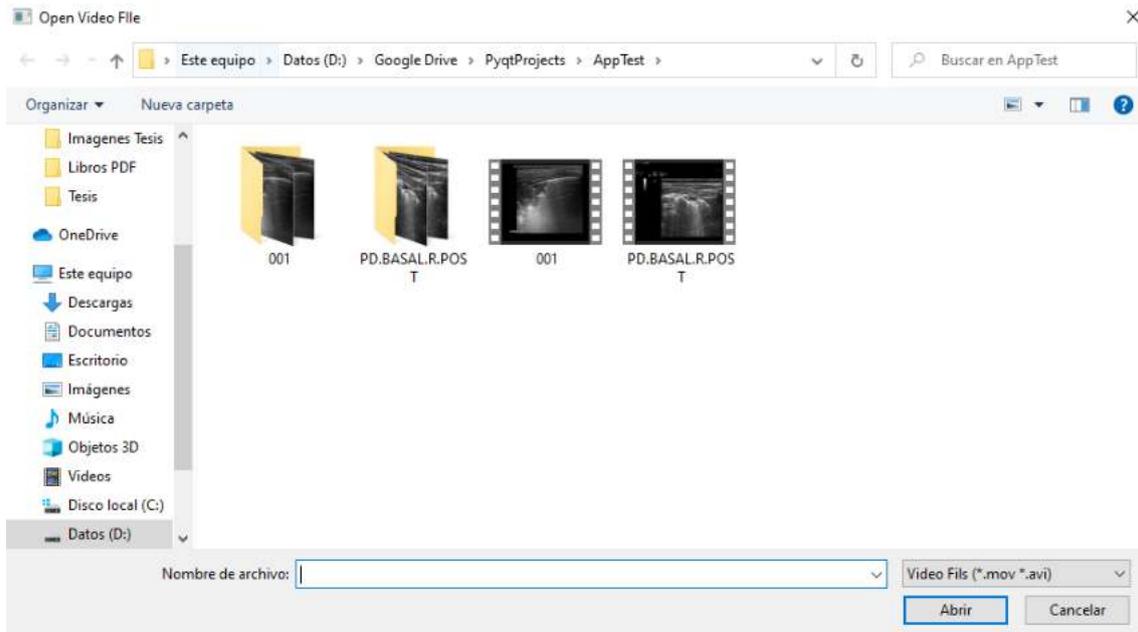


Fig. 26: Selección de videos.

Una vez seleccionado el video a analizar, se carga el primer *frame* del mismo en la pantalla principal como se muestra en la figura 27.



Fig. 27: Video cargado en la interfaz.

Manteniendo el clic izquierdo y arrastrando el mouse, el usuario puede seleccionar la región a analizar, la cual queda demarcada por un rectángulo rojo como el de la Figura 28.

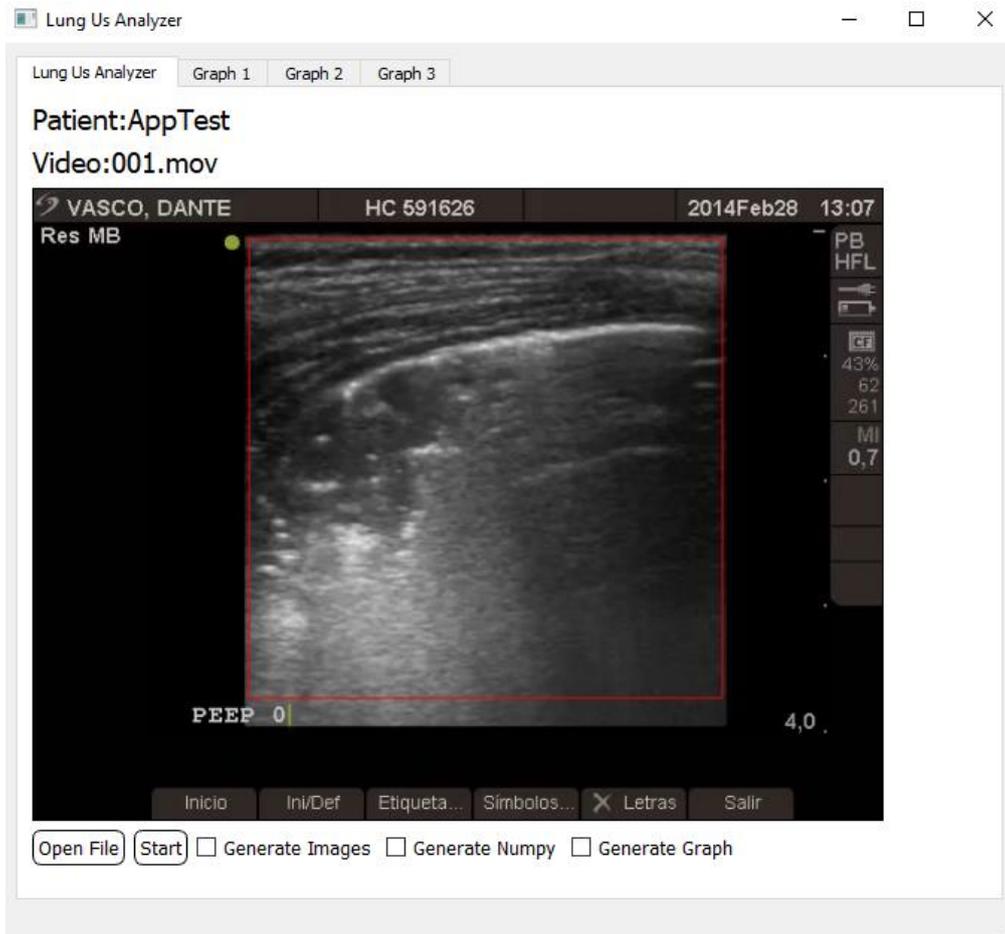


Fig. 28: Selección de la región de interés.

Se cuenta con tres *check buttons* que habilitan distintas opciones (algunas para usuarios más avanzados, precisamente usuarios de Python).

Marcando "Generate Images" crea en el directorio del video una carpeta en la cual deposita los *frames* recortados en formato de imagen (jpg). Esto no es necesario para el análisis del video, pero es frecuente requerir las imágenes por separado

De manera similar "Generate Numpy" genera un archivo con datos de Python (extensión npy) con los resultados de las predicciones para cada *frame*.

"Generate Graph" crea archivos gráficos (formato jpg) con los gráficos que se exhiben luego del análisis.

En las figuras 29, 30 y 30 se muestran los gráficos generados en las distintas pestañas, en la versión actual de la interfaz. Corresponde al gráfico temporal con

frames de ejemplo, a los *violín-plots* para observar las frecuencias de las diferentes probabilidades a lo largo de los *frames* y los scores calculados para cada *frame* a lo largo del video.

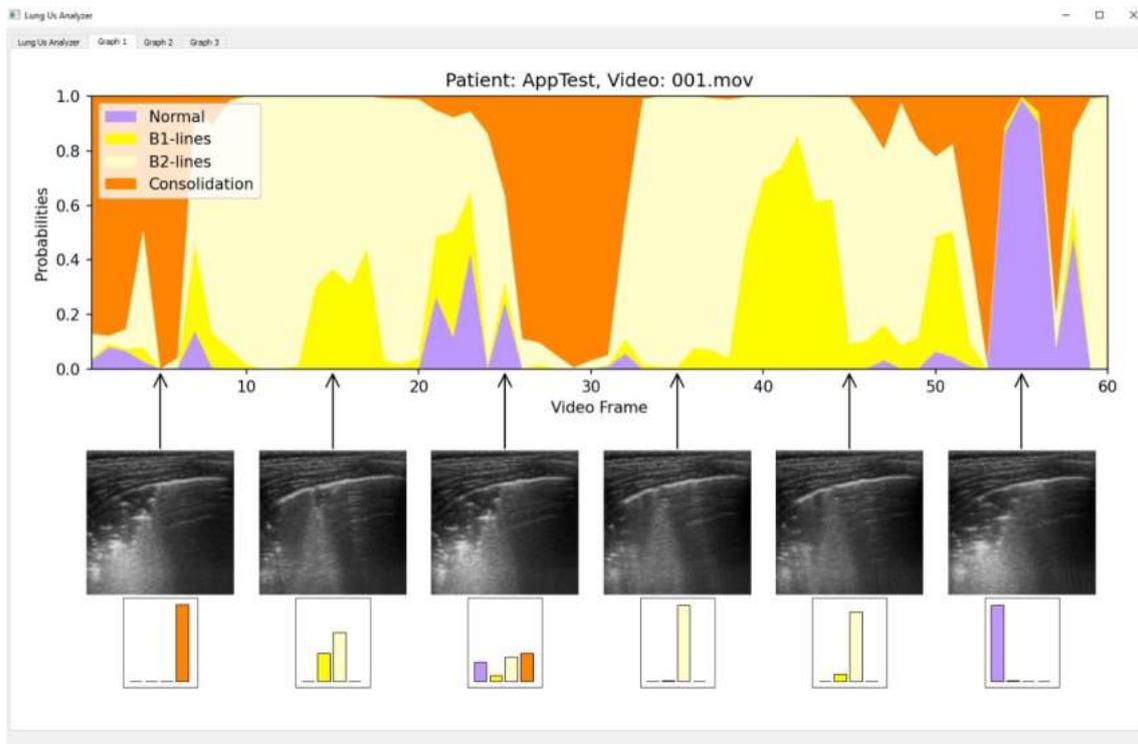


Fig. 29: Pestaña 1: análisis *frame a frame*.

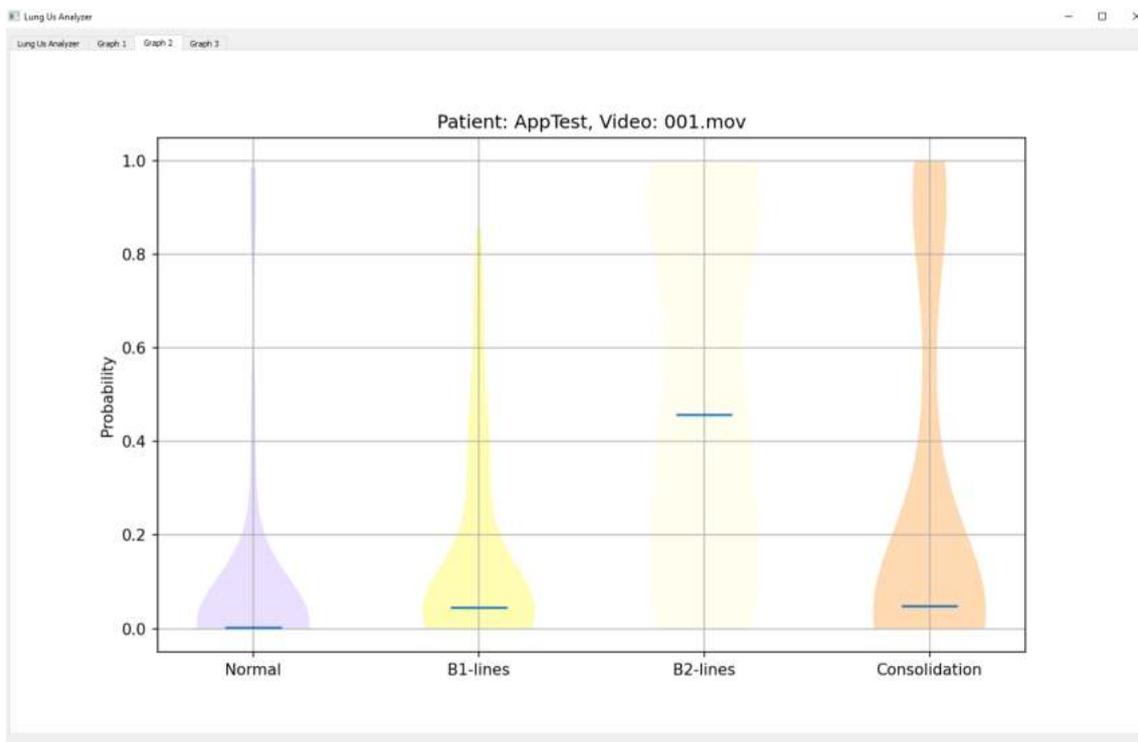


Fig. 30: Pestaña 2: Violín-plots.

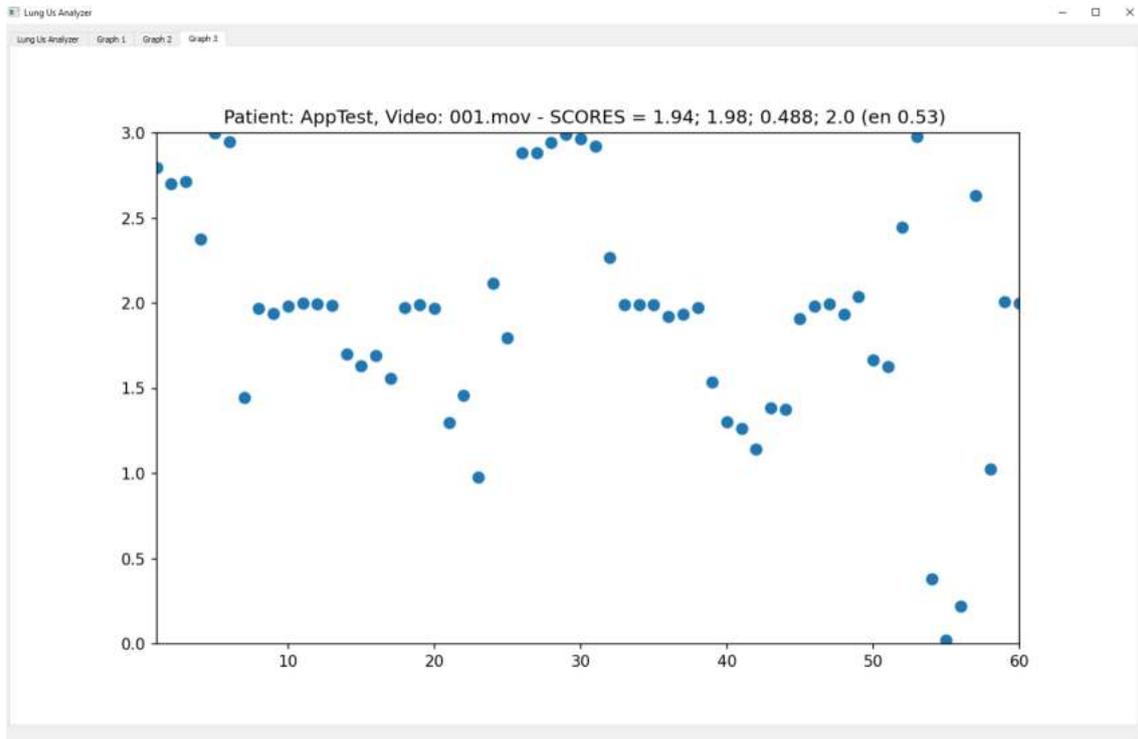


Fig. 31: Pestaña 3: Scores calculados por *frame*.

El objetivo del desarrollo de la interfaz es crear una herramienta que sea intuitiva, fácil de usar, y que agilice el análisis de los videos ecográficos. Además, tiene que ser adecuada a la terminología de los especialistas, de modo que ellos puedan operar y sentirse familiarizados con el lenguaje utilizado.

Como se planea en el futuro compartir esta interfaz con investigadores de otros países, se decidió la implementación directamente en inglés.

Conclusión

La presente investigación constituye una contribución al monitoreo de pacientes en anestesia o con respiración mecánica, con el desafío de constituir una herramienta de soporte de decisión que le ofrezca al personal médico la posibilidad de obtener información en tiempo real de la condición actual del paciente con un método no invasivo que le permita actuar de forma rápida y eficaz.

Si se cuenta con estudios adquiridos en iguales condiciones, esto es, que la región de interés no varía a lo largo de los estudios (esencialmente, que hayan sido capturados de la misma manera y con el mismo equipo), el método propuesto puede ser utilizado también para estudios de bases de datos de videos con fines de soporte para medicina basada en la evidencia. Los resultados pueden ser utilizados para estimar scores de aireación en forma automática, proceso que actualmente se realiza en forma visual y operador-dependiente.

Referencias

- [1] D. A. Lichtenstein y M. G. A, «Relevance of lung ultrasound in the diagnosis of acute respiratory failure: the BLUE protocol,» *Chest*, vol. 134, pp. 117-25, 2008.
- [2] D. A. Lichtenstein, «Ultrasound examination of the lungs in the intensive care unit,» *Pediatr.Crit. Care Med*, vol. 10, pp. 693-698, 2009.
- [3] G. Volpicelli, «International evidence-based recommendation for point-of-care lung ultrasound,» *Intensive Care Med*, vol. 38, pp. 577-591, 2012.
- [4] L. Gunnarson, L. Tokics, H. Gustavsson y G. Hedenstiern, «Influence of age on atelectasis formation and gas exchange impairment during general anaesthesia,» *Br. J. Anaesth*, vol. 66, pp. 423-432, 1991.
- [5] G. Tusman, S. H. Böhm, D. O. Warner y J. Sprung, «Atelectasis and perioperative pulmonary complications in high-risk patients,» *Curr. Opin. Anaesthesiol*, vol. 25, pp. 1-10, 2012.
- [6] G. Hendenstierna, «Effects of anaesthesia on ventilation/perfusion matching,» *Eur. J. Anaesthesiol*, vol. 31, pp. 447-449, 2014.
- [7] A. Eichenberger, «Morbid Obesity and Postoperative Pulmonary Atelectasis: An Underestimated Problem,» *Anesth Analg*, vol. 95, pp. 1788-1798, 2002.
- [8] F. S. Xue, «The influence of Surgical Sites on Early Postoperative Hypoxemia in Adults Undergoing Elective Surgery,» *Anesth. Analg*, vol. 88, pp. 213-219, 1999.
- [9] A. Strandberg, L. Tokics, B. Brismar, H. Lundquist y G. Hendenstierna, «Atelectasis during anaesthesia and in the postoperative period,» *Acta Anaesthesiol. Scand*, vol. 30, pp. 154-158, 1986.
- [10] G. Tusman, C. M. Acosta, M. Nicola, M. Esperatti, S. H. Bohm y F. Suarez-Sipmann, «Real-time images of tidal recruitment using lung ultrasound,» *Crit. Ultrasound J.*, vol. 7, p. 19, 2015.

- [11] B. Bouhemad, H. Brisson, M. Le-Guen, C. Arbelot, L. Q y J. Rouby, «Bedside Ultrasound Assessment of Positive End-Expiratory Pressure-induced Lung Recruitment,» *Am. J. Respir. Crit. Care Med.*, vol. 183, pp. 341-347, 2011.
- [12] G. Volpicelli, «Lung Sonography,» *J. Ultrasound Med.*, vol. 32, pp. 165-171, 2013.
- [13] G. Gardelli, F. Feletti, E. Gamberini, S. Bonarelli, A. Nanni y M. Mughetti, «Using sonography to assess lung recruitment in patients with acute respiratory distress syndrome,» *Emerg. Radiol.*, vol. 16, pp. 219-221, 2009.
- [14] A. L. Dai Pra, G. J. Meschino, C. Acosta, G. Tusman, H. J. Rabal y L. I. Passoni, «Análisis dinámico de ecografías de pulmón por medio de descriptores basados en el cálculo de gránulos temporales,» de *XX Congreso Argentino de Bioingeniería*, 2015.
- [15] Y. LeCun, Y. Bengio y G. Hinton, «Deep Learning,» *Nature*, vol. 521, pp. 436-444, 2015.
- [16] A. Krizhevsky, I. Sutskever y G. E. Hinton, «ImageNet classification with deep convolutional neural networks,» *Commun. ACM*, vol. 60, pp. 84-90, 2017.
- [17] G. Wang, «A Perspective on Deep Imaging,» *IEEE Access*, vol. 4, pp. 8914-8924, 2016.
- [18] S. Liu, «Deep Learning in Medical Ultrasound Analysis: A Review,» *Engineering*, vol. 5, pp. 261-275, 2019.
- [19] S. J. Pan y Q. Yang, «A Survey on Transfer Learning,» *IEEE Trans. Knowl. Data Eng.*, vol. 22, pp. 1345-1359, 2010.
- [20] N. Tajbakhsh, «Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?,» 2017.
- [21] D. P. Kingma y J. Lei Ba, «ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION,» de *ICLR*, 2015.
- [22] G. Volpicelli, A. Lamorte y T. Villén, «What's new in lung ultrasound during the COVID-19 pandemic,» *Intensive Care Med*, vol. 46, pp. 1445-1448, 2020.