

CORPORACIÓN UNIVERSITARIA UNITEC

Facultad de Ingeniería

Ingeniería de Telecomunicaciones

Este trabajo presenta una aproximación a la integración entre las telecomunicaciones y la medicina como **telemedicina** y **telecirugía**. En telemedicina se muestra una nueva herramienta de análisis en terapia y rehabilitación de miembro superior, y una nueva tecnología de sensores inalámbricos para rehabilitación en pacientes que hayan sufrido accidentes cerebrovasculares, el diseño se basó en Unidades de Medición Inerciales (IMU *Inertial Measurement Unit*) comunicadas en por medio de una red ZigBee, la validación del sistema se realizó mediante el registro simultáneo de la cinemática por medio de los IMU inalámbricas, con el fin de reconstruir la posición tridimensional de los segmentos del miembro superior durante el gesto de alcanzar y agarrar. En la sección de telecirugía se realizó un modelo de clasificador múltiple totalmente automático de tejidos cerebrales en imágenes de Resonancia Magnética Multiespectral en etapa de simulación, con el fin de aportar en la optimización de la cuantificación de patologías en tejidos cerebrales y planificación de neurocirugías, evaluando y validando los métodos multiclase de Máquinas de soporte Vectorial (SVM *Support Vector Machine*) "uno contra uno" y "uno contra todos" el desempeño mostrado fue del orden del 99.01% en diferentes cortes.

MODELO DE INTEGRACIÓN DE LAS TELECOMUNICACIONES EN LA MEDICINA: TELEMEDICINA Y TELECIURUGÍA

Preparado por

M.Sc. Ing. Carlos A. Cifuentes G.

Bogotá, Colombia

2012

RESUMEN

INTRODUCCIÓN

Este trabajo presenta una aproximación a la integración entre las telecomunicaciones y la medicina como área de aplicación, para lo cual se profundiza en dos áreas específicas: la telemedicina y la telecirugía. En telemedicina se muestra una nueva herramienta de análisis en terapia y rehabilitación de miembro superior, y una nueva tecnología de sensores inalámbricos para mejorar la robótica de rehabilitación en pacientes que hayan sufrido accidentes cerebrovasculares, el diseño se basó en Unidades de Medición Inerciales (IMU *Inertial Measurement Unit*) comunicadas en por medio de una red ZigBee, la validación del sistema se realizó mediante el registro simultáneo de la cinemática por videografía tridimensional y las IMU inalámbricas, con el fin de reconstruir la posición tridimensional de los segmentos del miembro superior durante el gesto de alcanzar y agarrar. En la sección de telecirugía se realizó un modelo de clasificador múltiple totalmente automático de tejidos cerebrales en Imágenes de Resonancia Magnética Multiespectral en etapa de simulación, con el fin de aportar en la optimización de la cuantificación de patologías en tejidos cerebrales y planificación de neurocirugías, evaluando y validando los métodos multiclase de Máquinas de soporte Vectorial (SVM *Support Vector Machine*) “uno contra uno” y “uno contra todos” el desempeño mostrado fue del orden del 99.01% en diferentes cortes.

Adicionalmente el registro electromiográfico sEMG que representa el estado de activación muscular, ha sido ampliamente usado para analizar el progreso en el proceso de rehabilitación y la interacción humano y robot. El progreso de la recuperación motora puede monitorearse durante el entrenamiento asistido por robot por sEMG mediante análisis cuantitativo de los parámetros de la electromiografía (Hu, y otros, 2003). El seguimiento adicional de la intención de control a través del registro de actividad cerebral podría proveer mayor interacción durante el movimiento completo, lo cual sería beneficioso para promover la restitución de la función motora de los pacientes luego del episodio cerebrovascular (Song, Tong, Hu, & Li, 2008). Este

En esta aplicación existe la necesidad de obtener variables tales como las aceleraciones y velocidades angulares de la articulación para cerrar bucles de control en la búsqueda de cumplir objetivos específicos. Para ello los sensores deben contar con determinadas características tales como escaso tamaño, larga vida útil de la batería, capacidad de extraer un amplio rango de parámetros del movimiento humano, alta estabilidad a órtesis aplicación ortésica, y adecuado ancho de banda entre otros requisitos preferibles. Estas especificaciones hacen atractivos a los sensores inerciales basados en Sistemas Micro Electro Mecánicos (MEMS de sus siglas en inglés) para el campo de la rehabilitación robótica (Rocan, y otros, 2007). Estos sensores tales como acelerómetros, giroscopios y magnetómetros pueden combinar sus mediciones a través de buses para obtener registro de datos cinemáticos, típicamente aceleración, velocidad, posición y orientación.

INTRODUCCIÓN

Dentro del desarrollo de las Tecnologías de la Información y la Comunicación una de las aplicaciones que ha despertado interés en la última década es la prestación de servicios de salud a través de la red, ofreciendo la posibilidad de acceder a dichos servicios a la población en lugares remotos (Universidad Nacional de Colombia, 2011); otra forma de integración es el uso del recurso de la cirugías asistidas por robots donde la manipulación del instrumental quirúrgico (robot) se realiza en forma remota a través de las redes de telecomunicación (W.S. Melvin, 2002); la integración de las telecomunicaciones en la medicina a su vez permite el cuidado y monitoreo domiciliario de pacientes crónicos o en proceso de rehabilitación (Heras, 2003).

El uso de rehabilitación robótica para proveer terapia motriz tiene un gran potencial. Algunos de sus beneficios abarcan: mayor posibilidad de realizar ejercicios terapéuticos precisos y repetibles, reducción del esfuerzo de los terapeutas involucrados, incorporación de sistemas interactivos de realidad virtual y además, la recolección de datos cuantitativos que pueden ser utilizados para optimizar las sesiones de terapia y analizar el desempeño del paciente (Schabowsky, Godfrey, R.J.Holley, & Lum, 2010). En esta aplicación existe la necesidad de obtener variables tales como las aceleraciones y velocidades angulares de la articulación para cerrar bucles de control en la búsqueda de cumplir objetivos específicos. Para ello los sensores deben contar con determinadas características tales como escaso tamaño, larga vida útil de la batería, capacidad de extraer un amplio rango de parámetros del movimiento humano, fácil adaptabilidad a órtesis aplicación ortésica, y adecuado ancho de banda entre otros aspectos preferibles. Estas especificaciones hacen atractivos a los sensores inerciales basados en Sistemas Micro Electro Mecánicos (MEMs de sus siglas en inglés) para el campo de la rehabilitación robótica (Rocon, y otros, 2007). Estos sensores tales como acelerómetros, giróscopios y magnetómetros pueden combinar sus mediciones a través de IMUs para obtener registro de datos cinemáticos, típicamente aceleración, velocidad, posición y orientación.

Adicionalmente el registro electromiográfico sEMG que representa el estado de activación muscular, ha sido ampliamente usado para analizar el progreso en el proceso de rehabilitación y la interacción humano y robot. El progreso de la recuperación motora puede monitorearse durante el entrenamiento asistido por robot post-ACV mediante análisis cuantitativo de los parámetros de la electromiografía (Hu, y otros, 2009). El seguimiento adicional de la intención de control a través del registro mioeléctrico continuo podría proveer mayor interacción durante el movimiento completo, lo cual sería beneficioso para promover la restitución de la función motora de los pacientes luego del episodio cerebrovascular (Song, Tong, Hu, & Li, 2008). Este

aspecto está contemplado en el presente diseño para futuras aplicaciones en el avance de esta línea de investigación.

Por otro lado los procesos quirúrgicos tradicionales presentan alto riesgo en infección, posibles daños en los tejidos adyacentes a la intervención, tiempo de intervención elevado y mayor dolor post-operatorio. Este tipo de situaciones pueden ser superadas con la cirugía mínimamente invasiva en donde se realiza una cirugía cerrada y local con el fin de evitar grandes heridas para acceder a la zona que necesita intervención, evitando así la lesión de otros órganos (Byron Alfonso, 2008). Sin embargo ambos procesos requieren de la presencia física del cirujano, esto imposibilita el acceso para los pacientes en lugares distantes que requieren de una intervención pronta debido a la patología presentada o el avance de ésta.

El uso de las redes inalámbricas para la manipulación remota de instrumental quirúrgico, ofrece la posibilidad de tener estaciones de teleoperación en lugares de difícil acceso y adicionalmente usar la misma estación para diferentes especialidades. No obstante la telecirugía al igual que los procesos tradicionales requiere de planeación quirúrgica (Chan & Frank, 2009) (Chauhan, 2010), la cual se basa en imágenes diagnósticas que detallan la anatomía, fisiología y las patologías del sujeto, para esto es preciso contar con un modelo virtual que satisfaga las condiciones anteriormente expuestas. Estos modelos virtuales pueden integrarse a la navegación dentro de la cirugía en tiempo real, por lo que este es el objetivo principal de este proyecto.

Estos modelos virtuales se crean a partir de imágenes diagnósticas, e incluyen segmentación de los tejidos y planificación automática de los tejidos para la cirugía diagnóstica, brindando resultados para la determinación de procedimientos (Helpert, 2006); en la planeación de telecirugías, además de proporcionar información (Lee SL, 2010).

El presente trabajo apunta al desarrollo de un sistema de rehabilitación robótica mediante protocolo ZigBee. Este nodo de sensores es implementado en un sistema de terapia de movimiento continuo (llamada en inglés) a ser usada en aplicaciones de

1. TELEMEDICINA

1.1. Antecedentes de la Telemedicina

Actualmente, existe una variedad de sensores IMU listos para la transmisión de datos en forma inalámbrica (van Acht, Bongers, Lambert, & Verberne, 2007) (El-Gohary, y otros, 2011), y varios de los métodos de sensado han sido hallados con el objeto de reducir las imprecisiones inherentes a las mediciones de los sensores micro electro mecánicos (El-Gohary, y otros, 2011) (Edwan, Zhang, Zhou, & Loffeld, 2011), por otro lado hay sensores eletromiográficos implementados sobre diversos protocolos inalámbricos (Youn & Kim, 2009). Nuestro trabajo se concentra en el desarrollo de un sensor IMU que sea lo suficientemente pequeño como para ser integrado con fácil adaptabilidad tanto a la ropa como a la órtesis de un usuario. Esto puede ser usado para cerrar los lazos de control en búsqueda de propósitos específicos a través de los sistemas de rehabilitación robótica. Al mismo tiempo estos sensores pueden utilizarse para monitoreo simultaneo de la evolución de la terapia ya sea para el grupo médico como para el paciente como herramienta de retroalimentación.

La tecnología ZigBee define las redes, seguridad y la estructura de la aplicación para un sistema basado en IEEE 802.15.4. Estas capacidades permiten a la red, tener miles de dispositivos sobre una única red inalámbrica de trabajo. La llamada ZigBee Alliance focalizada en el espacio del cuidado de la salud ha resultado en el desarrollo de un perfil de aplicación pública denominado ZigBee Health Care (ZHC). El diseño de este sistema surgió para usarse en dispositivos de asistencia operando en el cuidado no invasivo de la salud y proporciona un estándar de amplia aplicación industrial para el intercambio de datos entre una variedad de dispositivos médicos y no médicos. La principal aplicación de dominio y uso se aplican a casos tales como: Manejo de la Enfermedad, Monitoreo de la Actividad Física Personal, y Monitoreo del Bienestar Personal (Cifuentes, Gentiletti, Suarez, & Rodríguez, 2010). Este trabajo apunta al desarrollo de una arquitectura de monitoreo para terapia de rehabilitación robótica basada en redes de sensores IMU portables comunicados mediante protocolo ZigBee para el cuidado de la salud ZHC, este sensor propuesto es implementado en un novedoso y único microcontrolador ARM Cortex M4 Kinetis. Este nodo de sensores permitirá el registro de la cinemática del paciente en terapia de movimiento continuo sobre todos los segmentos del cuerpo como una Red Corporal de Sensores (llamada BSN: Body Sensor Network por sus siglas en inglés) a ser usada en aplicaciones de rehabilitación robótica.

En este trabajo exponemos los detalles del diseño y la implementación de los sistemas de sensores portables ZigBee. En principio, mostramos las características del sensor y las fórmulas matemáticas para su modelización, en segundo lugar presentamos la implementación y la evaluación de desempeño para rehabilitación de miembro superior en la terapia de alcanzar y agarrar objetos. Se validó el sistema con un sistema de rastreo óptico de movimiento. Las cámaras y los sensores IMU registraban la posición en el mismo instante de tiempo durante el gesto de alcanzar y agarrar un objeto con la extremidad superior.

1.2. Diseño

El sistema de sensores portable desarrollado consiste en una red ZigBee llamada ZIMUED compuesta de un coordinador y varios sensores denominados dispositivos finales, los cuales están compuestos de una IMU y un dispositivo final. El diagrama simplificado de un dispositivo ZIMUED se muestra en la Fig. 1.

La IMU se diseñó empleando un microcontrolador ARM Cortex M4 Kinetis K53. Este es un moderno microprocesador ARM integrado especialmente desarrollado para el mercado de señales digitales. La familia de microcontroladores K50 posee un sistema de mediciones analógicas implementadas con operacionales y amplificadores de transimpedancia que en conjunto con conversores analógico digitales y digitales analógicos de alta resolución, proveen al diseñador un potente motor para la adquisición de datos (Semiconductor, K53 Sub-Family Data Sheet, 2011). La red se basó en el MC13224 el cual incorpora un transmisor de 2.4 GHz de bajo consumo, microcontrolador basado en el núcleo ARM7 de 32-bit, y aceleración por hardware tanto para la capa IEEE 802.15.4 MAC (Media Access Control) como para la seguridad AES (Advanced Encryption Standard) (Semiconductor, MC1322X Technical Data, 2010).

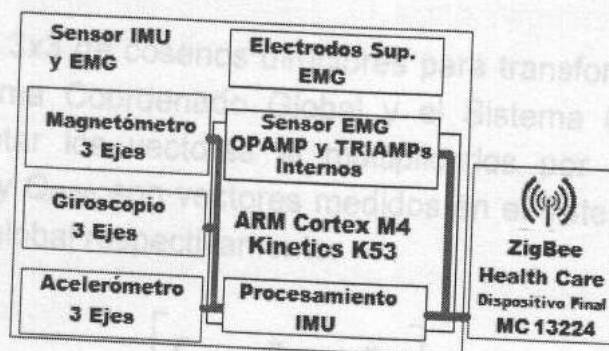


Fig. 1. Diseño esquemático de la ZIMUED.

1.3. Sensor IMU

La IMU se basó en la implementación de una matriz de cosenos directores, previamente desarrollada para el vuelo de aviones y helicópteros a escala (Mahony, Hamel, & Pflimlin, 2008)(Euston, Coote, Mahony, Kim, & Hamel, 2008)(Baldwin, Mahony, Trunpf, & Hamel, 2007)(Mahony, Sung-Han, & Hamel, 2006).




Fig. 2. (a) Sistema de ejes coordenados del segmento. (b) Sistema Coordinado Local (LSC) and Sistema Coordinado Global (GSC)

La orientación puede ser descripta utilizando tres ángulos denominados ángulos de Euler: 1) *yaw* ψ , para la rotación del segmento alrededor del eje z, 2) *pitch* θ para la rotación del segmento alrededor del eje y y 3) *roll* ϕ para la rotación alrededor del eje x (Fig 2a). Para describir el movimiento de los segmentos del cuerpo humano hacen falta definir dos sistemas coordenados, El Sistema Coordinado Global del laboratorio (GSC) y el Sistema Coordinado Local del segmento (LSC) (Fig. 2b). Ambos sistemas son ortogonales y regidos por la regla de la mano derecha.

Se utiliza una matriz 3x3 de cosenos directores para transformar entre los sistemas de referencia, el Sistema Coordinado Global y el Sistema Coordinado Local (1). Además es posible rotar los vectores al multiplicarlos por la matriz de cosenos directores, donde Q_{LSC} y Q_{GSC} son vectores medidos en el sistema coordenado local y el sistema coordenado global respectivamente.

$$R = \begin{bmatrix} r_{xx} & r_{xy} & r_{xz} \\ r_{yx} & r_{yy} & r_{yz} \\ r_{zx} & r_{zy} & r_{zz} \end{bmatrix} \quad (1)$$

$$Q_{GSC} = RQ_{LSC} \quad (2)$$

En la matriz de cosenos directores (3) las funciones trigonométricas de los ángulos de Euler $c\theta$ y $s\theta$ son abreviaturas para $\cos\theta$ y $\sin\theta$ respectivamente.

$$R = \begin{bmatrix} c\theta c\psi & s\phi s\theta c\psi - c\phi s\psi & c\phi s\theta s\psi + s\phi s\psi \\ c\theta s\psi & s\phi s\theta s\psi + c\phi c\psi & c\phi s\theta c\psi - s\phi c\psi \\ -s\theta & s\phi c\theta & c\phi c\theta \end{bmatrix} \quad (3)$$

R permite rotar el vector de medido en el SCL hacia el Sistema Coordinado Global, además cumple con la condición de ortogonalidad. La tasa de cambio del vector rotante producido por el movimiento se encuentra puede evaluar (4), donde $\omega(t)$ es la velocidad angular obtenida de los giróscopos en el sistema coordinado local y $r(t)$ el vector en el sistema global.

$$\frac{dr(t)}{dt} = \omega(t) \times r(t) \quad (4)$$

El desplazamiento angular se calcula con (5).

$$d\theta(t) = \omega(t) dt \quad (5)$$

En (6) se muestra el cálculo de la posición angular por integración aproximada. Desde el sistema coordinado local, el sistema coordinado global se encuentra rotando igual y opuesto a la rotación del Sistema Coordinado Local. De esta manera los ejes del sistema global pueden verse en el sistema coordinado local simplemente como un cambio de signo de la señal del giróscopo. El signo negativo es combinado con el producto vectorial, cambiando el orden de los operandos.

$$r(t) = r(0) + \int_0^t d\theta(t) \times r(t) \quad (6)$$

La expresión (7) permite actualizar la matriz de cosenos directores desde las señales provenientes de los giróscopos.

$$r_{GSC}(t + dt) = r_{GSC}(t) + r_{GSC}(t) \times d\theta(t) \quad (7)$$

Adicionalmente este algoritmo realiza una normalización de la matriz, con el fin de eliminar el ruido numérico que podría acumularse durante la integración y que con el tiempo podría afectar la precisión de los cálculos. Los elementos unidad en la matriz en la diagonal (8), representan el primer término de la ecuación (7). Los elementos fuera de la diagonal representan el segundo término de esta ecuación.

Ésta matriz R se actualiza con rotaciones cada vez más grandes cada vez que se produce el muestreo, por consiguiente es posible obtener los ángulos de Euler, es decir la orientación del segmento desde el ultimo renglón y la primer columna de la matriz (3).

$$R(t + dt) = R(t) \begin{bmatrix} 1 & -d\theta_z & d\theta_y \\ d\theta_z & 1 & d\theta_x \\ -d\theta_y & d\theta_x & 1 \end{bmatrix} \quad (8)$$

$$d\theta_x = \omega_x dt$$

$$d\theta_y = \omega_y dt$$

$$d\theta_z = \omega_z dt$$

$$\theta = -\sin^{-1}(r_{zx})$$

$$\phi = \tan^{-1}(r_{zy}, r_{zz}) \quad (9)$$

$$\psi = \tan^{-1}(r_{yx}, r_{xx})$$

1.4. Red ZIMUED

El diseño final de la IMU sobre el microcontrolador K53N512 se muestra en la Fig. 3. El giróscopo triaxial es la fuente principal de información, esta variación angular es integrada en cada eje para así obtener constantemente la posición angular en tiempo real mediante la rutina que utiliza de la matriz de cosenos directores.

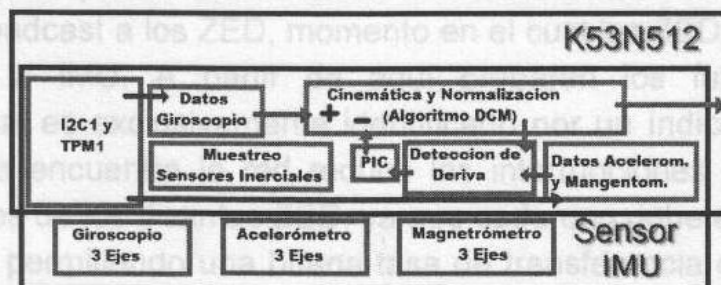


Fig. 3. Diagrama en Bloque del sensor de la IMU.

El sistema portable implementado consiste básicamente en dos pequeñas tarjetas de circuitos impresos: el circuito de sensores y el circuito ZigBee. Estas versiones han sido

Adicionalmente este algoritmo realiza una normalización de la matriz, con el fin de eliminar el ruido numérico que podría acumularse durante la integración y que con el paso de las muestras violaría el requerimiento de ortogonalidad que deben satisfacerse en la matriz de cosenos directores. Por ello es necesario realizar pequeños ajustes en los elementos de la matriz para satisfacer esta condición.

De la misma manera es necesario realizar la detección de la desviación del giroscopio, ya que el offset de este acumula gradualmente errores en los elementos de la nombrada matriz. Este procedimiento se realiza en tres etapas: 1) utilizando vectores referencia de orientación para poder cuantificar la desviación. Estos vectores se obtienen a partir de un magnetómetro el cual detecta la desviación del *yaw*, y un acelerómetro que detecta la desviación del *pitch* y el *roll*. 2) Realimentando el vector error mediante un controlador proporcional-integral, reajustando los giróscopios. 3) Restando el error de rotación a la señal registrada de los giróscopos. El muestreo de los sensores es realizado a 60Hz para ser compatible con la tasa de muestreo del sistema de video utilizado para la validación experimental.

1.4. Red ZIMUED

La red ZigBee tiene tres tipos de dispositivos: dispositivos finales (ZED, ZigBee End Device), routers (ZR, ZigBee Routers) y sólo un coordinador (ZC, ZigBee Coordinator). La red ZIMUED propuesta en este trabajo se implementó sobre el perfil de aplicación ZHC y la pila ZigBee de Freescale para el chip MC13224. Esta red es una configuración estrella donde el ZC recibe la información del paciente de los ZED. El protocolo de la red usa multiplexación de tiempo donde se define un tiempo de transmisión para que cada ZED envíe al ZC. El período de comunicación comienza en el momento que el ZC envía un paquete broadcast a los ZED, momento en el cual los ZED comienzan a tomar las mediciones de la IMU. A partir de aquí preparan los futuros paquetes de transmisión, cada cual es exclusivamente identificado por un índice. La topología tipo estrella en la que se encuentra la red reduce las interrupciones en la recepción de paquetes provenientes de los distintos ZED, ya que cada uno debe enviar el paquete en un tiempo particular, permitiendo una buena tasa de transferencia con baja pérdida de datos (Rodríguez, 2011).

Implementación del Sistema

El sistema portable implementado consiste básicamente en dos pequeñas tarjetas de circuitos impresos: el circuito de sensores y el circuito ZigBee. Estas versiones han sido

desarrolladas como un prototipo, en versiones posteriores se planea reducir el tamaño integrando ambos bloques en una sola tarjeta.

La tarjeta de sensores se muestra en la Fig. 4. Tiene un microcontrolador KN53N512 conectado por buses I2C a ambos sensores inerciales para el procesamiento de las señales. Posee además conexión USB para reprogramación y depuración en tiempo real, también capacidad para tarjeta microSD en caso de requerirse almacenamiento masivo. En su parte superior posee dos conectores con los que se la comunica a la tarjeta que posee el modulo ZigBee. Adicionalmente posee un pack de baterías ya que debe ser un dispositivo portable




Fig. 4. Tarjeta del sensor de la IMU.

La tarjeta ZigBee montada sobre la tarjeta de sensores se muestra en la Fig. 5. Posee el microcontrolador MC13224 y con el fin de permitir diferentes aplicaciones se la ha diseñado con tres posibles antenas: SMA para grandes distancias, tipo chip para disminuir el tamaño y tipo F para reducir la cantidad de componentes. Además esta tarjeta posee pulsadores y LEDs para realizar la configuración y la inicialización de los respectivos módulos.




Fig. 6. Configuración de la RED ZIMUED.




Fig. 5. Tarjeta ZigBee Health Care Board sobre la IMU.

Finalmente, en la Fig. 6, se muestra la red ZIMUED aplicada. En cada dispositivo terminal ZIMUED la tarjeta de sensores manda a una tasa determinada los datos procesados al módulo ZigBee en la tarjeta superior, el cual envía los datos al coordinador en una red tipo estrella, este recibe los paquetes provenientes de los distintos dispositivos terminales y envía la información a PC vía USB para post-procesamiento y visualización. Resumiendo el proceso de adquisición de datos el IMU envía de datos vía el bus I2C hacia el microcontrolador K53N512 a una tasa de 60Hz. Luego se envía esta información, nuevamente hacia la tarjeta superior que posee el módulo Zigbee embebido en el microcontrolador MC13224, mientras que la información cinemática se envía en cuanto se adquiere. Luego se produce la transmisión inalámbrica a través de la red ZIMUED en el tiempo particular asignado por el coordinador.




Fig. 6. Configuración de la RED ZIMUED.

1.5. Evaluación

La validación del método se realizó adquiriendo simultáneamente datos a través del sistema inalámbrico desarrollado y del sistema de video 3D convencional ampliamente utilizado para análisis biomecánicos. Se eligió el gesto de alcanzar y agarrar debido a la importancia de este movimiento en la independencia y calidad de vida de los pacientes con secuelas de accidentes cerebrovasculares, el cual es mencionado en la introducción. Detalles de la cinemática del tronco y el miembro inferior pueden ser encontrados en trabajos existentes (Braidot, Canalis, Dieser, Gomez, & Crespo, 2011). En el desarrollo del presente trabajo se han empleado 10 marcadores reflectivos localizados en los siguientes posiciones anatómicas: séptima cervical, acromion izquierdo, acromion derecho, esternón, olecranon, estiloides radial, estiloides ulnar, tercer metacarpiano, marcador radial del brazo y trapecio (Fig. 7).




Fig. 7. Localización de los marcadores y la IMU para el registro simultáneo.

Con los datos registrados por el sistema de videografía se puede calcular la posición de los segmentos a partir de la realización de un modelo antropométrico con el fin de poder estimar los centros articulares del hombro, codo y muñeca (Rab, Petuskey, & Bagley, 2001). Además de encontrar estos centros articulares, se deben poder conocer la orientación espacial de los diferentes segmentos brazo y antebrazo, para ello se debe generar primero un sistema coordenado local ubicado en el centro de gravedad del segmento (Braidot, Canalis, Dieser, Gomez, & Crespo, 2011).

El protocolo de validación del nuevo método de adquisición se efectuó mediante los registros simultáneos de videografía tridimensional y los sensores IMU. El gesto de alcanzar y agarrar se realiza con el sujeto sentado frente a una mesa colocada en altura coincidente a las cámaras de video. El brazo derecho del sujeto en reposo, con el codo y el antebrazo ubicados sobre la mesa formando un ángulo de flexión de

aproximadamente 90° respecto al brazo. Un ciclo del gesto completo representa la extensión del miembro superior hasta agarrar el objeto ubicado en la mesa a una distancia del alcance de la mano y regresar hasta colocar la extremidad en la posición donde se inicio del gesto.

Para validar el sistema diseñado de registro de la IMU se comparan los resultados de los datos obtenidos en simultáneo con ambas técnicas de registro. Con los datos de ambos sistemas de registro se calcula en forma vectorial el ángulo de flexión-extensión del codo. En la Fig. 8 se muestran los valores correspondientes al ángulo de flexión-extensión del codo para 3 gestos del movimiento de alcanzar y agarrar para un mismo sujeto con diferentes colores, en función del porcentaje del ciclo. Las dos graficas de un mismo color corresponden el mismo gesto registrado. En trazo continuo los datos calculados con el sistema de video y con trazo cortado los datos calculados con el correspondiente a la IMU.

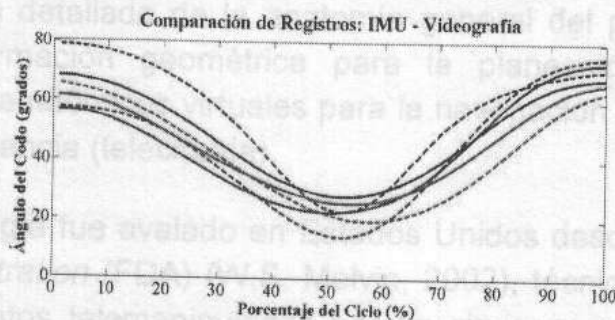


Fig. 8. Comparación de Registros Videográficos y de IMUs para 3 Gestos.

En la Fig. 9 se puede observar el alto grado de repetibilidad que presentan las señales adquiridas por las IMUs para 14 gestos de un mismo individuo efectuadas en diferentes días, donde se verifica la similitud morfológica y los datos de ángulos de flexión-extensión del codo en función del porcentaje del ciclo. Se puede apreciar que los datos están libres de ruido y artefactos.




Fig. 9. Curvas del Ángulo del Codo proveniente de 14 Gestos de un sujeto en distintos días de registro.

2. TELE CIRUGÍA

2.1. Antecedentes

La clasificación de tejidos cerebrales es usada en investigaciones y estudios clínicos en el área de neurología para el seguimiento y cuantificación de patologías como: accidentes cerebrovasculares, edema cerebral, tumores, enfermedades degenerativas como Parkinson o Alzheimer (Ramani, Jensen, & Joseph A. Helpert, 2006); otra aplicación tiene lugar en el campo de la neurocirugía ya sea convencional o teleasistida por robots como: NeruoArm que es compatible con Imágenes de Resonancia Magnética (IRM) (New Scientist Tech and Reuters, 2007), o Hexapod (DPA, 2003), que necesitan contar con la estructura detallada de la anatomía general del paciente, indicación de patologías claras, información geométrica para la planeación preoperatoria y la generación de modelos anatómicos virtuales para la navegación en sistemas de cirugía asistida por robots a distancia (telecirugía).

El sistema de telecirugía fue avalado en Estados Unidos desde julio del 2000 por la *Food and Drug Administration* (FDA) (W.S. Melvin, 2002), técnicamente no son robots cirujanos sino instrumentos telemanipulados por un cirujano; compuestos por brazos articulados controlados desde una consola que dispone de una cámara de alta definición en imágenes tridimensionales (S.L Lee, 2010). El hospital universitario de Johns Hopkins, en Baltimore, ha desarrollado un sistema integrado para la planificación, navegación y asistencia de robots en cirugías de base del cráneo; en la planificación la zona de perforación se define mediante una tomografía preoperatoria, este procedimiento presenta una desviación en el corte planificado de 0.6 mm que es clínicamente inaceptable, por lo cual se requiere mayor precisión en el análisis digital de imágenes pre operatorias (Tian Xia, 2009). En Southwestern Medical Center de la Universidad de Texas, la radiación quirúrgica de tumores cerebrales asistida por robots demanda de precisión geométrica en la planeación, para minimizar el riesgo de toxicidad en tejidos sanos, esto puede lograrse a partir de la clasificación automática de tejidos cerebrales con altas tasas de acierto (C.A. Giller, 2004), El Instituto Nacional de Neurociencias de Singapur plantea en la fase de planeación, el uso del procesamiento digital de imágenes para establecer la precisión en el posicionamiento y la trayectoria de la intervención teleasistida (Chan, y otros, 2009) (Chauhan, Tan, Seet, & Ng, 2010). Actualmente las pruebas de estos sistemas se han realizando con cadáveres o con perros buscando exactitud en la planificación quirúrgica (Tian Xia, 2009) (Chan, y otros, 2009) (Chauhan, Tan, Seet, & Ng, 2010); y es precisamente donde la clasificación automática de tejidos cerebrales puede brindar herramientas para obtener precisión en

el corte, proteger y prevenir el daño del sistema neurovascular, y mejorar todos aquellos aspectos que permitan el avance científico de las intervenciones quirúrgicas en mención.

Comúnmente en el análisis y procesamiento digital de imágenes médicas se encuentran técnicas de clasificación de tejidos cerebrales como *K-means* (Yong Fan, 2007)], *Fuzzy C-means* (FCM) (Bazin & Dzung L. Pham, 2007), *K-Nearest Neighbor* (KNN) (Petronella Anbeek, Bochove, Osch, & Grond, 2005), *Markov Random Fields* (MRF), *Partial Volume Estimation* (PVE) (Jahyun J. Koo, 2007), estas son solo algunas técnicas de clasificación, el desarrollo de estos trabajos generalmente se realiza sobre una sola secuencia de IRM iniciando con la extracción de la corteza craneal para eliminar su interferencia en la clasificación (Yong Fan, 2007)(Petronella Anbeek, Bochove, Osch, & Grond, 2005), la clasificación de los tejidos cerebrales en IRM se origina a partir de: a) diferentes intensidades de la imagen, b) modelamiento espacial, y/o c) estimaciones volumétricas; estos clasificadores presentan un costoso entrenamiento y manejan múltiples mínimos locales (Alba Castro, 2009). Una de las técnicas más usadas es máquinas de soporte vectorial (SVM, por sus siglas en inglés), basada en la teoría del aprendizaje estadístico (Cortes & Vapnik, 1995)[9], en sus inicios esta técnica fue desarrollada para problemas binarios y posteriormente fue extendida a problemas multi-clase (Hsu & Lin)(Smola, 1999).

Las SVM permiten conseguir una solución óptima a un problema de clasificación con un tamaño pequeño de muestras, del cual se obtendrá una solución global no sólo para superar el problema de múltiples mínimos locales, sino también por transformar el problema a un espacio de características de alta dimensión y hacer una discriminación no lineal en el espacio original. Este método de clasificación ha presentado un mejor desempeño comparado con otros métodos clásicos del mismo orden (Guo, Liu, Wu, Yan, & Shen, 2007).

En la clasificación con SVM se asume un conjunto de etiquetas de entrenamiento (x_i, y_i) , $i = 1, \dots, l$ donde $x_i \in \mathbb{R}^N$ y $y_i \in \{-1, 1\}$, que puede ser separado por un hiperplano $h(x) = (w \cdot x) + b = 0$. Para el caso lineal, se construye un hiperplano que separe las dos clases, de tal forma que el margen (γ) será la máxima distancia entre el hiperplano óptimo y el patrón de entrenamiento más cercano (vectores de soporte), este problema puede ser descrito como (Eq. 10):

$$\begin{cases} \min \frac{1}{2} \|w\|^2 \\ \text{s. a. } \cdot y_i ((w \cdot x_i) + b) \geq 1 \end{cases} \quad (10)$$

2.2. Materiales y métodos

En el caso no lineal se introduce el espacio de entrada en otro de mayor dimensión, a fin de obtener un nuevo mapeo de los datos y poder usar un clasificador lineal. En términos matemáticos se introducen en la ecuación 1 variables *non-negative* $\xi_i \geq 0 \forall_i$ y un parámetro Costo (C), esto se expresa como (Eq.11):

$$\begin{cases} \min \frac{1}{2} \|w\|^2 + C \sum_i \xi_i^k \\ \text{s. a. } \therefore y_i(w \cdot x_i + b) \geq 1 - \xi_i \\ \xi_i > 0 \forall_i \end{cases} \quad (11)$$

Los clasificadores SVM multi-clase son la combinación de varios clasificadores binarios, aunque existen muchas formas de combinar estos clasificadores, en este trabajo sólo se utiliza los métodos 1-v-1 y 1-v-r, en el primer método se construyen $(k \cdot (k-1)/2)$ clasificadores binarios donde k es el número de clases, luego se usa una estrategia de votación para cada clasificador binario, y se toma la clase con mayor número de votos (Hsu & Lin)(Smola, 1999). Para el método 1-v-r se construyen k modelos binarios, asignando etiquetas positivas a las muestras de la clase i-ésima y etiquetas negativas a las clases restantes, donde cada función clasificadora parcial f_i enfrenta los vectores de la clase θ_i contra el resto de clases $(k-1)$.

El método desarrollado se fundamenta en las SVM y utiliza las técnicas multiclase 1-v-1 y 1-v-r, se presenta un modelo para la clasificación de cuatro clases de tejidos cerebrales a partir de las diferentes intensidades de las IRM: materia gris (MG), materia blanca (MB), líquido cefalorraquídeo (LCR) y un conjunto denominado "resto" conformado por: fondo de la imagen, musculo, piel, grasa, conectivo y hueso. La clasificación de tejidos cerebrales de IRM se realiza en las tres secuencias: T1 (tiempo de relajación longitudinal), T2 (tiempo de relajación transversal), DP (densidad protónica), y no se realiza la extracción de la corteza craneal sobre estas imágenes.

Esta publicación presenta un estudio de imágenes de Resonancia Magnética, basado en el clasificador SVM; la primera explica el clasificador, el método a utilizar, en esta sección también introducimos características de las imágenes y la base de datos para evaluar el clasificador escogido y diseñado. En la segunda sección se presentan los resultados de los métodos 1-v-1 y 1v-r. En la siguiente sección se analizan y discuten los resultados obtenidos, donde se establecen las contribuciones, limitaciones, y por último los lineamientos futuros de esta investigación

2.2. Materiales y métodos

Para este proyecto todos los algoritmos se programaron en *Matlab*®, que se complementaron con la librería *LIBSVM* para las SVM (Chih-Jen, Chih-Chung, & Lin, 2009); la base de datos de IRM se tomó del simulador *BRAINWEB* del laboratorio BIC (Brain Imagin Center- Monterreal Neurology Institute-McGill , 2006). En esta base de datos del cerebro se pueden fijar tres secuencias distintas (T1, T2, DP), 5 espesores de corte, 6 niveles de ruido y 3 niveles de falta de homogeneidad, también se pueden solicitar simulaciones personalizadas con parámetros distintos y descargar los datos del modelo anatómico cerebral. En el sitio *BRAINWEB* se pueden visualizar en escala de grises o *hot metal* los diferentes cortes de las imágenes de RM o descargarlas en el formato MINC (.mnc), el cual es un formato volumétrico, dispuesto de la siguiente manera 181, 217, 181, en los planos X, Y, Z, (axial, coronal, sagital). El presente trabajo se desarrollo en tres etapas así: Selección de datos de entrenamiento, Diseño del clasificador y Evaluación.

2.2.1. Selección de datos de entrenamiento

Para los datos de entrenamiento de las SVMs se tomó el modelo anatómico de *BRAINWEB*, el cual es un modelo difuso basado en Fuzzy C-Means con correcciones manuales realizadas por expertos y está representado por datos volumétricos que definen la distribución espacial de los diferentes tejidos como: MG, MB, LCR, grasa, músculo, piel, hueso, vasos sanguíneos, tejido conectivo, dura madre, médula ósea y fondo de la imagen, donde la intensidad del voxel es proporcional a la fracción de tejido dentro del voxel. La imagen base de este modelo es T1 con TE/TR/FA = 18mS/10mS/30deg y resolución espacial = 1mm, en condiciones ideales (0% ruido y =% falta de homogeneidad). Para tener datos de T2 y DP se solicitaron simulaciones personalizadas con estas mismas especificaciones.

Tomando las imágenes de referencia (T1, T2 y DP) y sus respectivos tejidos del modelo anatómico, a partir de esto, se compara pixel a pixel, los tejidos con las imágenes de referencia, a fin de determinar las intensidades de cada tejido en las diferentes secuencias. Finalmente se obtienen intensidades para los cortes 40, 90,120, con el fin de tener un número de muestras pequeño reduciendo el costo computacional.

Para el entrenamiento del clasificador se tomaron 4500 muestras aleatorias de los tejidos previamente adquiridos MG, MB, LCR, y 900 muestras aleatorias de cada tejido para conformar la clase Resto (hueso, piel y músculo, fondo de la imagen, conectivo y grasa). De esta manera se reduce el tiempo y el costo computacional al momento de

utilizar el clasificador. La figura 10 es la representación en el espacio de los datos de entrenamiento.




Fig. 10. Muestras de los datos de entrenamiento.

2.2.2. Diseño del clasificador

En esta propuesta para la clasificación de los tejidos cerebrales se utilizan los métodos de clasificación SVM multi-clase 1-v-1 y 1-v-r, en el desarrollo se asignan etiquetas a las muestras de los datos previamente adquiridas para el entrenamiento de las SVM como se muestra en la tabla 1.

Tabla 1. Etiquetas de los datos de entrenamiento

Tejido	Clase	Etiqueta
MB	MB	1
MG	MG	2
LCR	LCR	3
Hueso	Resto	4
Piel y Músculo	Resto	4
Fondo de la imagen	Resto	4
Conectivo	Resto	4
Grasa	Resto	4

Los parámetros de C y γ se diseñan mediante una validación cruzada (VC) con el método de grilla de búsqueda (grid search), que crea una "red" de todas las posibles ubicaciones de los puntos de intersección de configuración, para encontrar los mejores parámetros, se tomaron los valores de $C = 2^{-5}, 2^{-3}, \dots, 2^{15}$ y $\gamma = 2^{-15}, 2^{-13}, \dots, 2^3$, evaluando distintas funciones kernel: lineal, polinomial, Función Base Radial (RFB, por sus siglas en inglés) y sigmoidea, encontrando mejor desempeño con RFB. El método 1-v-1 se entrenó con los mejores resultados encontrados de la VC: $C = 32768$, $\gamma = 8$, con un porcentaje de precisión en la clasificación de 98.8222%. En el método de clasificación 1-v-r se establecieron cuatro clasificadores binarios comparando un tejido con los otros restantes, la disposición de los 4 clasificadores se muestra en la tabla 2. A cada uno de estos clasificadores se le aplicó la "grilla de búsqueda" de forma independiente, para hallar los parámetros óptimos de desempeño, los valores con mejor acierto de clasificación se presentan en la tabla 3. Finalmente se realizan las predicciones sobre las imágenes de prueba en ambos métodos.

Tabla 2. Clasificadores binarios de 1-v-r

Modelo	Clase 1	Clase 2
1	MG	MB, LCR y Resto
2	MB	MG, LCR y Resto
3	LCR	MG, MB y Resto
4	Resto	MG, M. Blanca y LCR

Tabla 3. VC clasificadores binarios

Modelo	Γ	C	% Clasificación
1	8	0.03125	99.5882
2	8	32	98.8111
3	8	0.0125	100
4	8	32768	98.3111

2.2.3. Evaluación de los clasificadores

Para la evaluación de los métodos de clasificación multi-clase se introdujeron las IRM en las secuencias T1, T2 y DP. La prueba inicial se hizo con el corte axial 90, corte medio del entrenamiento, en el cual hay mayor presencia de MG y MB, para establecer su comportamiento en condiciones ideales. Posteriormente se realizaron pruebas en cortes axiales diferentes a los del entrenamiento, así: por contar con mayor presencia de hueso, músculo y piel se eligió el corte 30; debajo del corte 75 empieza el cerebelo, y en los cortes superiores se encuentra mayor presencia de LCR, en este caso se eligió el corte 105. Se evalúa la clasificación en los cortes anteriormente mencionados por medio de una Matriz de Confusión (MC), que establece los falsos positivos y los falsos negativos de una clasificación. En este análisis se evalúan las etiquetas de los datos de entrenamiento y las etiquetas de los datos predichos, los datos se representan en matrices de NxN correspondientes a las clases de la clasificación estableciendo la tasa de acierto para cada tejido.

2.3. RESULTADOS

Teniendo en cuenta que el clasificador ha sido entrenado con condiciones ideales, se realizan pruebas con bajos niveles de ruido y de falta de homogeneidad, que serían el equivalente a las mejores condiciones encontradas en la toma de imágenes reales. Las imágenes de prueba tienen los siguientes parámetros: espesor = 1mm, 1% de ruido y 20% de falta de homogeneidad. Se presenta la respuesta de los clasificadores en imágenes binarias y la evaluación cuantitativa mediante la MC. En la figura 11 se indican las IRM en diferentes secuencias que se ingresaron en el clasificador.

Las imágenes de la figura 12 corresponden a la respuesta del método 1-v-1, en la figura 13 se muestra el resultado de la clasificación realizada con el método 1-v-r. En estas imágenes binarias se muestra cada clase de tejido de manera independiente en los diferentes cortes de prueba.

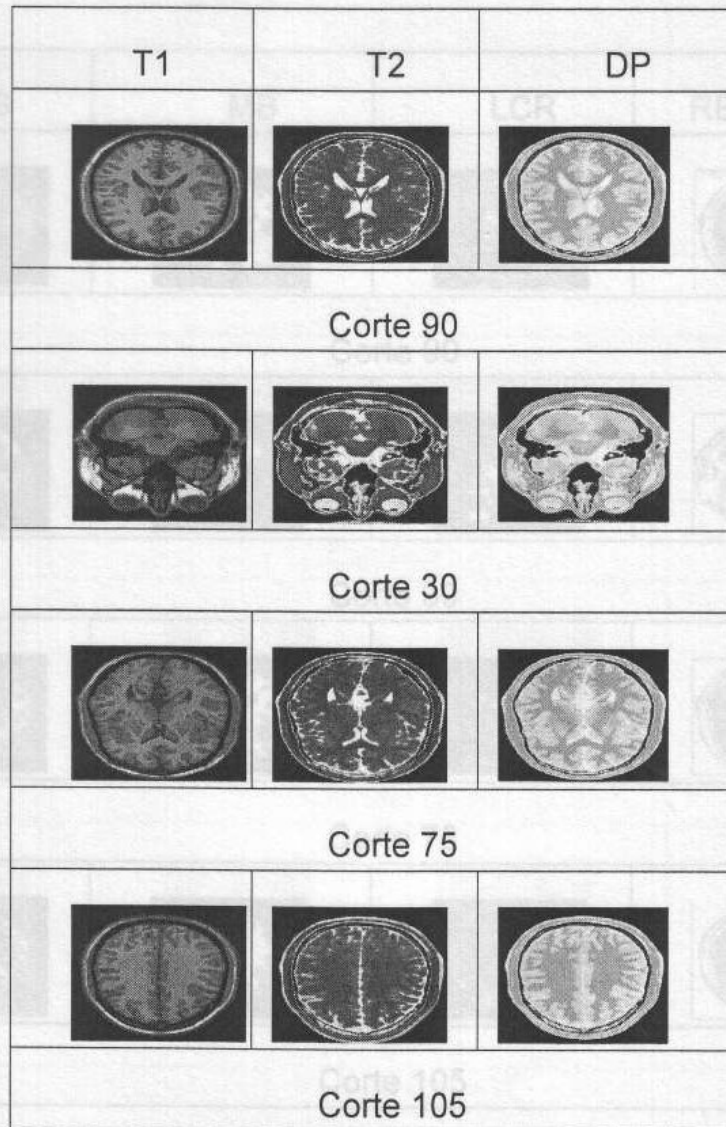


Fig. 11. Imágenes de entrada en secuencias T1, T2 y DP, en los cortes axiales 90, 30, 75 y 105

Las imágenes de la figura 12 corresponden a la respuesta del método 1-v-1, en la figura 13 se muestra el resultado de la clasificación realizada con el método 1-v-r. En estas imágenes binarias se muestra cada clase de tejido de manera independiente en los diferentes cortes de prueba.

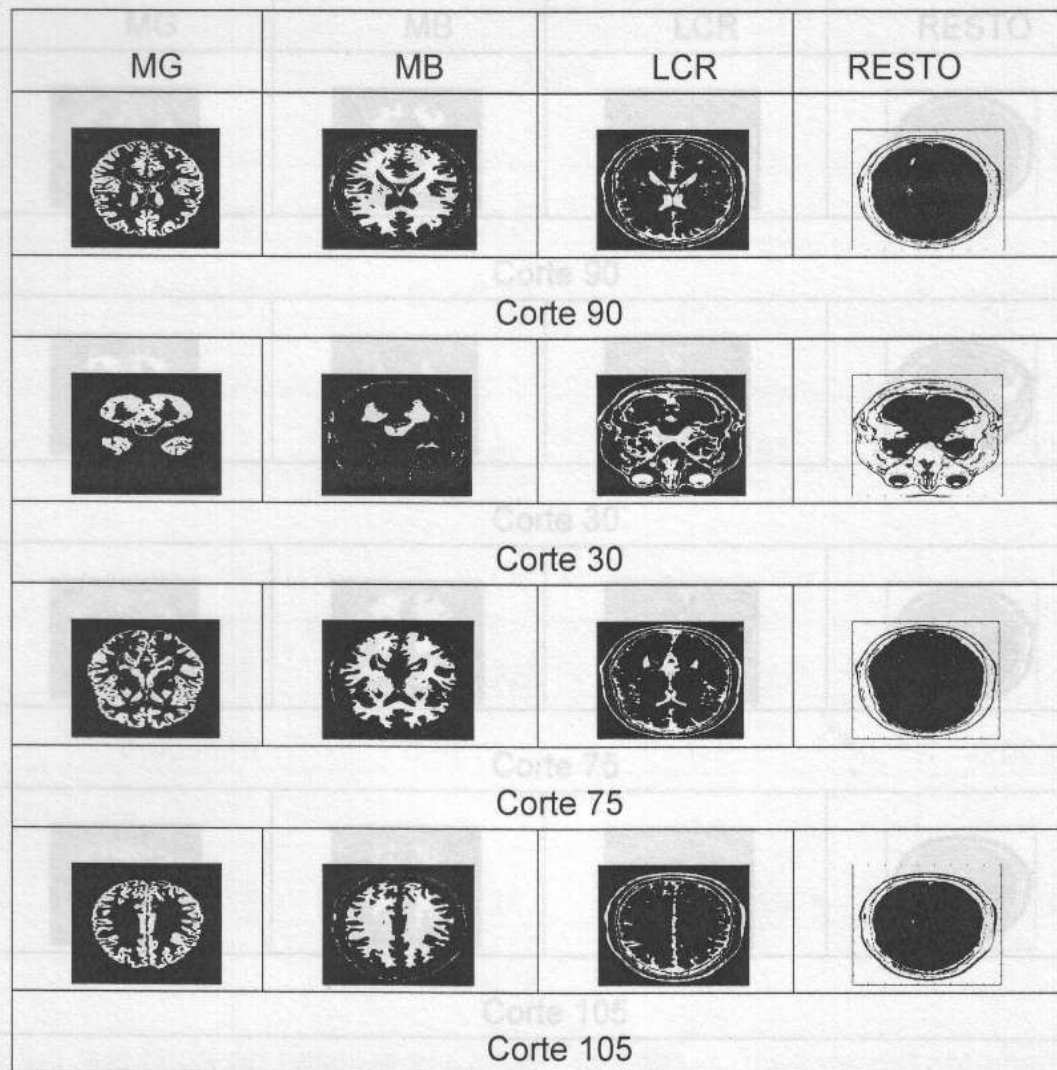


Fig. 12. Resultados de SVM multiclase 1-v-1 en los cortes 90, 30, 75 y 105

Fig. 13. Resultados de SVM multiclase 1-v-1 en los cortes 90, 30, 75 y 105

La evaluación se realiza mediante MC en cada corte de prueba, los datos se representan en matrices de 4x4 correspondientes a las clases de la clasificación estableciendo la tasa de acierto para cada tejido, el promedio de las MC de los cortes de prueba se muestra en la tabla 4 para ambos clasificadores.

















MG	MB	LCR	RESTO
			
Corte 90			
			
Corte 30			
			
Corte 75			
			
Corte 105			

Fig. 13. Resultados de SVM multiclase 1-v-r en los cortes 90, 30, 75 y 105

La evaluación se realiza mediante MC en cada corte de prueba, los datos se representan en matrices de 4x4 correspondientes a las clases de la clasificación estableciendo la tasa de acierto para cada tejido, el promedio de las MC de los cortes de prueba se muestra en la tabla 4 para ambos clasificadores.

El tiempo que tarda en hacer la predicción se calcula después del entrenamiento de cada modelo, el algoritmo se ejecuta en un procesador DualCore de 2.20 GHz, en el modelo 1-v-1 es de 0.0039 y en el clasificador 1-v-r son 27.7383 segundos.

La transmisión ZigBee desarrollados para uso portable en rehabilitación es una fuente confiable de adquisición de datos cinemáticos, lo que sumado a las ventajas ya descritas del sistema promueve un importante avance en rehabilitación robótica con biofeedback. La continuación de esta investigación a través de mayor registro de datos entre diversos pacientes y con un cálculo más avanzado de los datos cinemáticos y el agregado del registro electromiográfico, permitirán ponderar mejores perspectivas del aporte real de esta innovación en el campo de la rehabilitación de miembro superior.

Tabla 4. MC de los clasificadores

1-v-1				
	MG	MB	LCR	Resto
MG	0,999775	0,000225	0	0
MB	0,000075	0,996775	0	0,00315
LCR	0	0	1	0
Resto	0,0499	0,0388	0,1485	0,7628
1-v-r				
	MG	MB	LCR	Resto
MG	0,999025	0,000925	0,00005	0
MB	0,000075	0,9979	0	0,002025
LCR	0	0	1	0
Resto	0,077825	0,04225	0,146575	0,73335

El tiempo que tarda en hacer la predicción se calcula después del entrenamiento de cada modelo, el algoritmo se ejecuta en un procesador DualCore de 2.20 GHz, memoria RAM de 2 GB; el tiempo promedio para los cortes de prueba en segundos en el método 1-v-1 es de 6.9359, y en el clasificador 1-v-r son 27.1383 segundos.

3. DISCUSIONES Y CONCLUSIONES

El novedoso sistema inalámbrico presentado en este trabajo bajo protocolos de transmisión ZigBee desarrollados para uso portable en rehabilitación es una fuente confiable de adquisición de datos cinemáticos, lo que sumado a las ventajas ya descritas del sistema promete constituir un importante avance en rehabilitación robótica con biofeedback. La continuación de esta investigación a través de mayor registro de datos entre diversos pacientes y con un cálculo más avanzado de los datos cinemáticos y el agregado del registro electromiográfico, permitirán ponderar mejores perspectivas del aporte real de esta innovación en el campo de la rehabilitación de miembro superior.

Asimismo este sistema diseñado permite estudiar otro tipo de movimientos cuya rehabilitación funcional sea de importancia en los pacientes otras con secuelas debido a accidentes cerebrovasculares o a otro tipo de enfermedades.

La clasificación realizada de los tejidos cerebrales presenta altas tasas de acierto y tiempos de ejecución reducidos. Se resalta el resultado obtenido en la clase MG en todos los cortes con el método 1-v-1 el cual aparece totalmente independiente de los tejidos extra craneales, mientras que en el método 1-v-r este tejido presenta adiciones de tejidos extra craneales. En la clasificación de los tejidos MB y LCR en ambos clasificadores se observa un comportamiento parecido, sin embargo es clara la adición de los tejidos extra craneales debido a que las intensidades de estos son muy similares. El grupo de trabajo plantea la utilización de los resultados obtenidos de las imágenes clasificadas en un estudio sobre imágenes reales, que luego será aplicado en la cuantificación de patologías, planeación de neurocirugías, además de ser un apoyo en la investigación sobre la precisión en el posicionamiento y la trayectoria de la intervención de telecirugías a través de la generación de modelos 3D de estructuras anatómicas para la navegación virtual.

BIBLIOGRAFÍA

- Alba Castro, J. L. (2009). Decisión, estimación y clasificación SVM. Oro Verde.
- Baldwin, G., Mahony, R., Trumpf, J., & Hamel, T. (2007). *Complementary filter design on the Special Euclidean group SE(3)*.
- Bazin, P.-L., & Dzung L. Pham. (2007). *Topology-Preserving Tissue Classification of*. 26(4).
- Braidot, A., Canalis, G., Dieser, P., Gomez, S., & Crespo, M. (2011). *Análisis del Gesto de Alcanzar y Agarrar un Objeto en Pacientes con ACV*.
- Brain Imagin Center- Monterreal Neurology Institute-McGill . (2006, Junio 12). *BrainWeb: Simulated Brain Database*. Retrieved 2010, from <http://mouldy.bic.mni.mcgill.ca/brainweb/>
- C.A. Giller, B. B. (2004). *Feasibility of radiosurgery for malignant brain tumors using robotic radiosurgery*.
- Chan, F., Kassim, I., Lo, C., Ho, C. L., Low, D., Ang, B. T., & Ng, I. (2009). *Image-guided robotic neurosurgery—an in vitro and in vivo point accuracy evaluation experimental study*. 71.

- Chauhan, S., Tan, M. T., Seet, G., & Ng, I. (2010). *Minimally invasive robotic HIFU neurosurgical applications*. *Reconfigurable Computer*, 7.
- Chih-Jen, Chih-Chung, C., & Lin. (2009, Enero 5). *LIBSVM*. Retrieved from Chih-Jen, Chang Chih-chung and Lin. LIBSVM -- A Library <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>
- Cifuentes, C., Gentiletti, G., Suarez, M., & Rodríguez, L. (2010). *Development of a Zigbee platform for bioinstrumentation*.
- Cortes, C., & Vapnik, V. (1995). *SUPPORT-VECTOR NETWORKS*. USA: AT&T Bell Labs.
- DPA. (2003, Enero 16). *World's first robot brain surgeon developed*. Retrieved from smh: <http://www.smh.com.au/articles/2003/01/15/1042520673704.html>
- Edwan, E., Zhang, J., Zhou, J., & Loffeld, O. (2011). *Reduced DCM based attitude estimation using low-cost IMU and magnetometer triad*.
- El-Gohary, M., Holmstrom, L., Huisinga, J., King, E., McNames, J., & Horak, F. (2011). *Upper limb joint angle tracking with inertial sensors*.
- Euston, M., Coote, P., Mahony, R., Kim, J., & Hamel, T. (2008). *A complementary filter for attitude estimation of a fixed-wing UAV*.
- Guo, L., Liu, X., Wu, Y., Yan, W., & Shen, X. (2007). *Research on the Segmentation of MRI Image Based on Multi-Classification Support Vector Machine*. Lyon, France: IEEE.
- Harwin, W., Patton, J., & Edgerton, V. (2006). *Challenges and Opportunities for Robot-Mediated Neurorehabilitation*. 94.
- Heras, P. d. (2003). *Propuesta de un modelo de sistema de telemedicina para la atención sanitaria domiciliaria*, Tesis doctoral. Madrid: Universidad Politécnica de Madrid.
- Hsu, W., & Lin, J. (n.d.). *A Comparison of methods for multi-class Support Vector Machines*. Taiwan: Tapei.
- Hu, X., Tong, K., Song, R., Zheng, X., Lui, K., & Leung, W. (2009). *Quantitative evaluation of motor functional recovery process in chronic stroke patients during robotassisted wrist training*. 19.
- Schabowsky, C., Godfrey, S., R.J.Holley, & Lum, P. (2010, Julio). *Development and pilot testing of HEXORR: Hand EXOskeleton Rehabilitation Robot*. Retrieved from

- Jahyun J. Koo, A. C. (2007). *Accelerating A Medical 3d Brain Mri Analysis Algorithm Using A High-Performance Reconfigurable Computer*. 7.
- Mackay, & Mensah, G. (2004). *Atlas of heart disease and stroke*. Retrieved from
- Mackey, A. H. (2005). *Reliability of upper and lower limb three-dimensional kinematics in children with hemiplegia*. Retrieved from
- Mahony, R., Hamel, T., & Pflimlin, J.-M. (2008). *Nonlinear Complementary Filters on the Special Orthogonal Group*. 53.
- Mahony, R., Sung-Han, C., & Hamel, T. (2006, Noviembre). *A coupled estimation and control analysis for attitude stabilisation of mini aerial vehicles*. Retrieved from ARRA: http://www.araa.asn.au/acra/acra2006/papers/paper_5_40.pdf
- New Scientist Tech and Reuters. (2007, Abril 18). *NewScientist*. Retrieved from MRI-enabled brain surgery robot revealed: <http://www.newscientist.com/article/dn11631-mrienabled-brain-surgery-robot-revealed.html>
- Petronella Anbeek, K. L., Bochove, G. S., Osch, M. J., & Grond, J. v. (2005). *Probabilistic segmentation of brain tissue in MR imaging*. 10.
- Rab, G., Petuskey, K., & Bagley, A. (2001). *A method for determination of upper extremity kinematics*. 15.
- Ramani, A., Jensen, J. H., & Joseph A. Helpern. (2006). *Quantitative MR Imaging in Alzheimer Disease*. 241.
- Rathore, S. S., Hinn, A. R., Cooper, L. S., Tyroler, H. A., & Rosamond, W. D. (2002). *Characterization of Incident Stroke Signs and Symptoms*. Retrieved from Stroke: <http://stroke.ahajournals.org/content/33/11/2718>.
- Rocon, E., Moreno, J., Ruiz, A., Brunetti, F., Miranda, J., & Pons, J. (2007). *Application of inertial sensors in rehabilitation robotics*.
- Rodríguez, C. C. (2011). *Análisis Biomecánico de la Marcha basado en Acelerómetros sobre una Red ZigBee*.
- S.L Lee, M. L. (2010). *From medical images to minimally invasive intervention computer assistance for robotic surgery*. 34.
- Schabowsky, C., Godfrey, S., R.J.Holley, & Lum, P. (2010, Julio). *Development and pilot testing of HEXORR: Hand EXOskeleton Rehabilitation Robot*. Retrieved from

Journal of NeuroEngineering and Rehabilitation:
<http://www.jneuroengrehab.com/content/7/1/36>.

- Semiconductor, F. (2010, Octubre). *MC1322X Technical Data*. Retrieved from <http://www.freescale.com/>
- Semiconductor, F. (2011, Septiembre). *K53 Sub-Family Data Sheet* . Retrieved from <http://www.freescale.com/>
- Smola, S. C. (1999). T. Joachims, *Making large-Scale SVM Learning Practical. Advances in Kernel Methods - Support Vector Learning*.
- Song, R., Tong, K.-y., Hu, X., & Li, L. (2008). *Assistive Control System Using Continuous Myoelectric Signal in Robot-Aided Arm Training for Patients After Stroke*. 16.
- Tian Xia, C. B. (2009). *An integrated system for planning, navigation and robotic assistance for skull base surgery*. (4).
- Universidad Nacional de Colombia. (2011). *Centro de Telemedicina*. Retrieved from <http://www.telemedicina.unal.edu.co/historia.php>
- van Acht, V., Bongers, E., Lambert, N., & Verberne, R. (2007). *Miniature Wireless Inertial Sensor for Measuring Human Motions*.
- W.S. Melvin, B. N. (2002). *Computer enhanced robotic telesurgery*. 16.
- Wenzelburger, R., Kopper, F., Frenzel, A., Stolze, H., Klebe, S., Brossmann, A., . . . Deuschl, G. (2004). *Brain*. Retrieved from <http://brain.oxfordjournals.org/content/128/1/64>.
- Yong Fan, D. S. (2007). *COMPARE: Classification of Morphological Patterns Using Adaptive Regional Elements*. 26(1).
- Youn, W., & Kim, J. (2009). *Development of a compact-size and wireless surface EMG measurement system*.