



**Universidad del Desarrollo**  
Facultad de Ingeniería

# IDENTIFICACIÓN DE ESTADOS OCULTOS EN TAREAS BÁSICAS DE SIMULACIÓN LAPAROSCÓPICA

Un enfoque mediante HMM para la evaluación y clasificación de  
habilidades fundamentales.

POR: GUSTAVO ADOLFO LOBOS CURAMIL

Proyecto de grado presentado a la Facultad de Ingeniería de la  
Universidad del Desarrollo para optar al grado académico de  
Magíster en Data Science

PROFESOR GUÍA:

Sr. MAURICIO RENE HERRERA MARÍN

Diciembre 2024

SANTIAGO



## AGRADECIMIENTO

Agradezco especialmente a mi profesor guía, Sr. Mauricio Rene Herrera Marín, por su disposición y flexibilidad durante el desarrollo de este trabajo. Su comprensión de las circunstancias particulares de cada estudiante y su capacidad para proponer un proyecto de investigación verdaderamente interesante fueron fundamentales para llevar a buen término este trabajo. Valoro especialmente la autonomía otorgada y su disponibilidad para las consultas clave que surgieron durante el proceso.

Extiendo también mi gratitud a la Facultad de Ingeniería de la Universidad del Desarrollo, por proporcionar el marco académico necesario para el desarrollo de esta investigación.

A mi familia, gracias por su apoyo constante durante todo este proceso académico.

Para Bastián, que nunca detenga el proceso más importante: aprendizaje.-

## TABLA DE CONTENIDO

<b>Resumen .....</b>	<b>1</b>
<b>1 Introducción .....</b>	<b>2</b>
<b>2 Trabajo Relacionado .....</b>	<b>4</b>
2.1 Evaluación Objetiva en Simulación Quirúrgica .....	4
2.2 Análisis de Movimiento en Entornos Virtuales .....	4
2.3 Aplicaciones de HMM en Evaluación Quirúrgica .....	5
2.4 Sistemas de Clasificación Automática .....	5
2.5 Tendencias Actuales y Brechas en la Investigación .....	6
<b>3 Hipótesis y Objetivos .....</b>	<b>7</b>
<b>3.1 Hipótesis .....</b>	<b>7</b>
<b>3.2 Objetivo General .....</b>	<b>7</b>
3.3 Objetivos Específicos .....	7
<b>4 Datos y Metodología .....</b>	<b>8</b>
4.1 Datos .....	8
4.2 Metodología .....	9
5.1 Análisis Exploratorio de Datos .....	10
5.1.1 Caracterización del Conjunto de Datos .....	10
5.1.2 Análisis por Sesiones .....	12
Imagen 1: Distribución de sesiones .....	13
Imagen 2: Longitud de duración espacial expertos vs novatos .....	14
5.1.2 Análisis de Outliers y Distribución. ....	14
Imagen 3: Boxplot para detección de Outliers.....	15
5.1.3 Características Derivadas del Movimiento .....	16
5.2 Preprocesamiento.....	18
5.2.1 Normalización de Series Temporales .....	18
Celda de Código 1: Muestra de código utilizado para Interpolación.....	18
5.2.1 Detección de Valores Atípicos.....	20
Celda de código 2: Ejemplo de código utilizado para detección de Outliers	
.....	20
5.2.2 Extracción de Características .....	21
5.2.3.1 Suavidad del Movimiento.....	21
5.2.3.2 Economía de Movimiento .....	22
5.2.3.3 Velocidad Angular.....	22
5.2.3.4 Conclusiones del Preprocesamiento.....	23
5.3 Modelo Oculto de Markov (HMM) para el Análisis de Tareas de Agarre y Transporte.....	24

5.3.1	Justificación del Uso de HMM .....	24
5.3.2	Estructura del Modelo Implementado .....	25
5.3.2.1	Análisis de Consistencia y Selección del Modelo HMM .....	26
5.3.2.1.1	Criterios de información y Convergencia.....	26
	Tabla 1: Análisis de Criterios para selección de Estados Óptimos.....	26
	Tabla 2: Distribución de muestras en los Estados.....	27
	Imagen 4: Gráfico de distribución de estados .....	28
5.3.2	Caracterización de Estados Identificados .....	28
	Imagen 5: Definición de estado 0.....	29
	Imagen 6: Definición de Estado 1 .....	29
	Imagen 7: Definición de Estado 2 .....	30
	Imagen 8: Definición de Estado 3 .....	31
	Imagen 9: Definición de Estado 4 .....	32
	Imagen 10: Distribución de Estados por Grupo.....	33
5.4	Análisis de Transiciones entre Estados .....	33
5.4.1	Patrones de Transición en Expertos.....	33
5.4.2	Patrones de Transición en Novatos:.....	34
5.4.3	Diferencias Claves .....	35
	Imagen 11: Mapa de seguimiento de Estados más probables .....	36
5.4	Análisis de Secuencias de Viterbi: Caracterización de Estados Ocultos en Movimientos de agarre y transporte. ....	36
	Estructura del Modelo de Estados.....	36
	Hallazgos Diferenciales: Expertos vs. Novatos.....	37
	Proceso de Extracción de Secuencias .....	37
	Celda de Código 3: Ejemplo de secuencia de Viterbi típica .....	38
5.5	Evaluación del Modelo de Clasificación .....	38
5.5.1	Comparación de Rendimiento Global .....	38
	Tabla 3: Resumen de performance de Modelos de Clasificación.....	38
5.5.2	Validación con Datos Nuevos.....	39
	Tabla 4: Clasificación de Conjunto de Prueba: Novato .....	39
	Tabla 5: Clasificación de Conjunto de Prueba: Experto .....	40
5.5.3	Análisis de Resultados .....	40
<b>6.</b>	<b>Conclusiones .....</b>	<b>41</b>
6.1	Principales Hallazgos .....	41
6.2	Limitaciones y Desafíos .....	42
6.3	Implicaciones y Aplicaciones Prácticas .....	42
6.4	Direcciones Futuras .....	43
6.5	Consideraciones Finales .....	43
6.6	Evaluación de Objetivos, Hipótesis y Limitaciones .....	44
	<b>Bibliografía .....</b>	<b>47</b>



## **Resumen**

El desarrollo de habilidades quirúrgicas básicas mediante simulación continúa siendo un desafío significativo en la formación médica. ¿Cómo se puede evaluar objetivamente estas habilidades? Este trabajo explora una posible respuesta a través de los Modelos Ocultos de Markov (HMM), buscando identificar patrones subyacentes en tareas fundamentales de simulación laparoscópica.

Para este estudio, se analizaron datos provenientes de un simulador laparoscópico básico; específicamente, se registraron datos de posición y orientación durante tareas de agarre y transporte. La muestra incluyó sesiones (expertos/novatos), y el análisis incorporó métricas derivadas - suavidad de movimiento, economía de movimiento y velocidad angular - para enriquecer la caracterización de las trayectorias.

Los resultados son interesantes: se identificaron patrones distintivos en los estados y sus transiciones entre expertos y novatos; sin embargo, la clasificación automática basada en secuencias de Viterbi enfrentó limitaciones importantes. A pesar de estas dificultades, el trabajo arroja luz sobre aspectos fundamentales de los patrones de movimiento en simulación laparoscópica básica y - quizás más importante aún - señala desafíos cruciales que futuros estudios en el área deberán abordar.

# **1 Introducción**

La evolución constante de la medicina - junto con la necesidad de garantizar la máxima seguridad del paciente - ha impulsado una transformación significativa en la formación quirúrgica moderna... ¿El resultado? Según (Wijewickrema et al.) la simulación quirúrgica emerge como una herramienta fundamental, revolucionando la manera en que los futuros cirujanos desarrollan sus habilidades y competencias.

Esta innovadora aproximación a la formación quirúrgica se sustenta en múltiples pilares fundamentales; en primer lugar, proporciona un entorno de aprendizaje seguro y controlado donde los futuros cirujanos pueden practicar - sin riesgo alguno para los pacientes -; facilita una práctica deliberada y sistemática, esencial para la adquisición de habilidades quirúrgicas. En ciertos escenarios, no solo es importante clasificar estas habilidades, sino también enriquecer la salida con algún tipo de retroalimentación que permita evaluar cuánto le falta a un aprendiz para dominar las técnicas comúnmente empleadas por expertos. Este enfoque puede ayudar a los aprendices a identificar áreas específicas de mejora y a guiar su progreso de manera más efectiva. En este sentido, (Ötleş et al.) destacan que brindar una retroalimentación en tiempo real y automatizada puede guiar a los aprendices hacia una técnica quirúrgica ideal.

La adquisición de habilidades quirúrgicas fundamentales representa un proceso complejo que tradicionalmente ha dependido de la evaluación subjetiva de instructores experimentados. Las tareas básicas de simulación - como el agarre y transporte de objetos - constituyen los

cimientos sobre los cuales se construyen habilidades quirúrgicas más avanzadas. Nuevamente, según (Ötleş et al.), una retroalimentación narrativa mejora la calidad de enseñanza por sobre un sistema categórico.

Los Modelos Ocultos de Markov (HMM) han demostrado ser herramientas efectivas en el análisis de series temporales biomédicas; sin embargo, su aplicación en la evaluación de habilidades quirúrgicas básicas permanece relativamente inexplorada. Este enfoque innovador surge como respuesta a los desafíos inherentes a la educación quirúrgica tradicional. ¿Los principales obstáculos? Las limitaciones del entrenamiento en pacientes reales, la escasez de oportunidades de práctica y la subjetividad en la evaluación de habilidades. Para (Wijewickrema et al.), la simulación está jugando un papel fundamental en el avance de la cirugía mínimamente invasiva, permitiendo el desarrollo de habilidades específicas y la evaluación de nuevas tecnologías.

La estructura de este trabajo se organiza de la siguiente manera: primero, se presentan los datos y la metodología empleada; posteriormente, se describen los resultados obtenidos mediante el modelado HMM y la clasificación basada en secuencias de Viterbi; finalmente, se discuten las implicaciones y limitaciones del enfoque propuesto, así como sus posibles aplicaciones en la evaluación objetiva de habilidades quirúrgicas básicas.

## **2 Trabajo Relacionado**

La evaluación objetiva de habilidades quirúrgicas mediante simulación ha ganado considerable atención en la última década. Esta sección examina las contribuciones más relevantes en cuatro áreas principales: métodos de evaluación objetiva, análisis de movimiento quirúrgico, aplicación de HMM en simuladores, y sistemas de clasificación automática.

### **2.1 Evaluación Objetiva en Simulación Quirúrgica**

La necesidad de métodos objetivos para evaluar habilidades quirúrgicas está estrechamente vinculada con el contexto de la simulación quirúrgica, que permite la captura detallada de datos de movimiento, algo difícil de lograr en un entorno quirúrgico real. En su investigación (Wijewickrema et al.), profundiza sobre la idea de que la simulación juega un papel fundamental en el avance de la cirugía mínimamente invasiva, permitiendo no solo la evaluación de habilidades específicas, sino también el análisis de nuevas tecnologías, consolidando su importancia en estos desarrollos.

### **2.2 Análisis de Movimiento en Entornos Virtuales**

Diversos estudios han implementado métricas avanzadas para cuantificar aspectos relevantes del desempeño quirúrgico. Entre estas, la "suavidad de movimiento", calculada a través del análisis del jerk (la tasa de cambio de la aceleración), se ha destacado como una métrica

útil para evaluar la destreza, como señala (Glennie et al.). Esta métrica, junto con la economía de movimiento y la velocidad angular, permite una evaluación objetiva y detallada del movimiento quirúrgico. Estos avances ilustran cómo el análisis de movimiento puede proporcionar información cuantitativa y precisa sobre la habilidad quirúrgica, apoyando la comprensión del estilo y la eficiencia del cirujano.

### **2.3 Aplicaciones de HMM en Evaluación Quirúrgica**

Los Modelos Ocultos de Markov (HMM) han demostrado ser particularmente efectivos en el análisis de secuencias de movimiento quirúrgico, especialmente en tareas como agarre y transporte en entornos simulados. (Glennie et al.) destacan que los HMM son ideales para este tipo de análisis, ya que pueden modelar tanto secuencias temporales como estados no observables, características intrínsecas al movimiento. La progresión natural de estados en estas tareas, como aproximación, agarre, transporte y liberación, se alinea perfectamente con la capacidad de los HMM para representar secuencias temporales de manera precisa.

### **2.4 Sistemas de Clasificación Automática**

La clasificación automática de habilidades quirúrgicas representa la convergencia de múltiples enfoques técnicos. Nuevamente, en su trabajo, (Glennie et al.) describen la implementación de un sistema de clasificación basado en las secuencias de Viterbi extraídas de un HMM, diseñado para diferenciar entre expertos y novatos en tareas laparoscópicas. En este sistema, se entrenaron cuatro modelos de

clasificación (Random Forest, Gradient Boosting, SVM y XGBoost) utilizando los estados y transiciones del HMM.

Los resultados de este enfoque sugieren que la combinación del análisis secuencial del HMM con algoritmos de clasificación supervisada es una estrategia viable para la evaluación automatizada de habilidades. Estos avances han establecido benchmarks significativos en el campo, demostrando cómo los enfoques híbridos, que integran HMM con algoritmos tradicionales y redes neuronales, pueden ofrecer resultados prometedores en la evaluación objetiva de habilidades quirúrgicas.

## **2.5 Tendencias Actuales y Brechas en la Investigación**

Las investigaciones recientes han comenzado a explorar enfoques más sofisticados, como la integración de múltiples fuentes de datos y el uso de técnicas de aprendizaje por refuerzo. Sin embargo, persisten desafíos importantes en áreas como:

- La generalización a diferentes tipos de procedimientos o ejercicios
- La robustez frente a variaciones en el estilo individual
- La interpretabilidad de los modelos de clasificación

## **3 Hipótesis y Objetivos**

### **3.1 Hipótesis**

La tarea básica de agarre y transporte en simulación laparoscópica contiene patrones y estados ocultos identificables mediante HMM, cuya caracterización permitiría desarrollar un sistema de clasificación automática para evaluar el nivel de habilidad en estas tareas fundamentales.

### **3.2 Objetivo General**

Desarrollar un método de clasificación automática para la evaluación de habilidades básicas en simulación laparoscópica, basado en la identificación de estados ocultos mediante HMM.

### **3.3 Objetivos Específicos**

1. Identificar y caracterizar los estados ocultos presentes en la tarea fundamental de agarre y transporte mediante HMM.
2. Analizar cuantitativamente las diferencias entre expertos y novatos en términos de:
  - Patrones de movimiento básico
  - Economía de movimiento
  - Transiciones entre estados identificados
3. Desarrollar un clasificador basado en secuencias de Viterbi que:
  - Identifique efectivamente la pertenencia a una clase u otra.
  - Proporcione una base para futuras herramientas de evaluación automática
  - Permita una interpretación clara de los resultados

## 4 Datos y Metodología

### 4.1 Datos

#### Participantes y criterios de selección:

- **Expertos:** Cirujanos con más de 100 cirugías laparoscópicas realizadas.
- **Novatos:** Estudiantes de cirugía con experiencia limitada.
- **Criterio de captación:** Datos obtenidos a partir de la segunda o tercera sesión de uso del simulador para asegurar familiarización con el equipo

#### Variables capturadas:

- **Espaciales:** Posición (X, Y, Z) del marcador en el espacio virtual.
- **Orientación:** Rotación mediante cuaterniones (W, X, Y, Z).
- **Temporales:** Timestamp para cada registro.

#### Características derivadas:

- **Movement Smoothness:** Cuantifica la suavidad del movimiento mediante el análisis del jerk.
- **Movement Economy:** Relación entre trayectoria directa y real (0-1).
- **Angular Velocity:** Cambios en la orientación del instrumento.

## **4.2 Metodología**

### **Análisis de patrones de movimiento:**

- Identificación de estados mediante HMM.
- Caracterización de estados por métricas cuantitativas:
  - Velocidades promedio por estado
  - Tiempo de permanencia en cada estado
  - Frecuencia de transiciones
  - Economía de movimiento por estado

### **Caracterización de niveles de experiencia:**

- Análisis de persistencia en estados específicos
- Evaluación de economía de movimiento
- Patrones de transición entre estados
- Distribución temporal en diferentes estados

### **Evaluación y validación:**

- Análisis de distribución de estados entre grupos
- Métricas comparativas de desempeño
- Visualización de diferencias entre expertos y novatos

## **5.1 Análisis Exploratorio de Datos**

### **5.1.1 Caracterización del Conjunto de Datos**

El conjunto de datos ---obtenido mediante un simulador laparoscópico de alta fidelidad--- comprende registros de movimiento de dos grupos claramente diferenciados: cirujanos expertos ( $n=2,400$ ; provenientes de 6 sujetos) y novatos ( $n=4,000$ ; provenientes de 10 sujetos). Los datos, capturados durante la ejecución de tareas fundamentales (agarre/transporte), incluyen dos tipos de métricas esenciales: posición tridimensional ( $X,Y,Z$ ) y orientación mediante cuaterniones ( $W,X,Y,Z$ ).

La frecuencia de muestreo ---factor crítico para el análisis posterior--- se mantuvo consistente en el rango de 97-98ms; sin embargo, se observó una variabilidad natural en la duración total de las series temporales (característica inherente a la diferencia de experiencia entre los grupos). Esta variabilidad fue abordada mediante un proceso de interpolación adaptativa, permitiendo la estandarización a 400 puntos temporales ---preservando así la estructura temporal original de los movimientos---.

### **Estructura Inicial**

- Se importaron datos de dos fuentes principales:
  - Expertos: 6 archivos de sesiones diferentes
  - Novatos: 10 archivos de sesiones diferentes
- Cada sesión fue etiquetada con un identificador único (session\_id)
- Los datos fueron combinados manteniendo la estructura temporal original

### **Composición de las Sesiones**

- Formato temporal consistente (timestamp con precisión de milisegundos)
- Variables originales:
  - Posición: X, Y, Z
  - Rotación: W, X, Y, Z (cuaterniones)
  - Identificadores: session\_id, Label (0=novato, 1=experto)
- Frecuencia de muestreo: 97-98ms intervalo promedio

### **Verificación de Calidad de Datos**

- No se encontraron valores nulos en ninguna columna
- Balance de clases:
  - Expertos: 2,400 registros
  - Novatos: 4,000 registros

### **5.1.2 Análisis por Sesiones**

El conjunto de datos comprende 6 sesiones de expertos y 10 sesiones de novatos, con las siguientes características distintivas:

#### **Sesiones de Expertos:**

- Sesiones más cortas y eficientes
- Longitud media por sesión: 400 registros
- Mayor consistencia en duración entre sesiones

#### **Sesiones de Novatos:**

- Sesiones más largas
- Longitud media por sesión: 400 registros
- Mayor variabilidad en duración

#### **Patrones Distintivos por Tipo de Usuario:**

##### **1. Expertos:**

- Secuencias más cortas pero precisas
- Duración media de secuencias: 36.5, 9.7, y 13.4 muestras

##### **2. Novatos:**

- Secuencias más largas
- Duración media de secuencias: 63.5 y 136.0 muestras

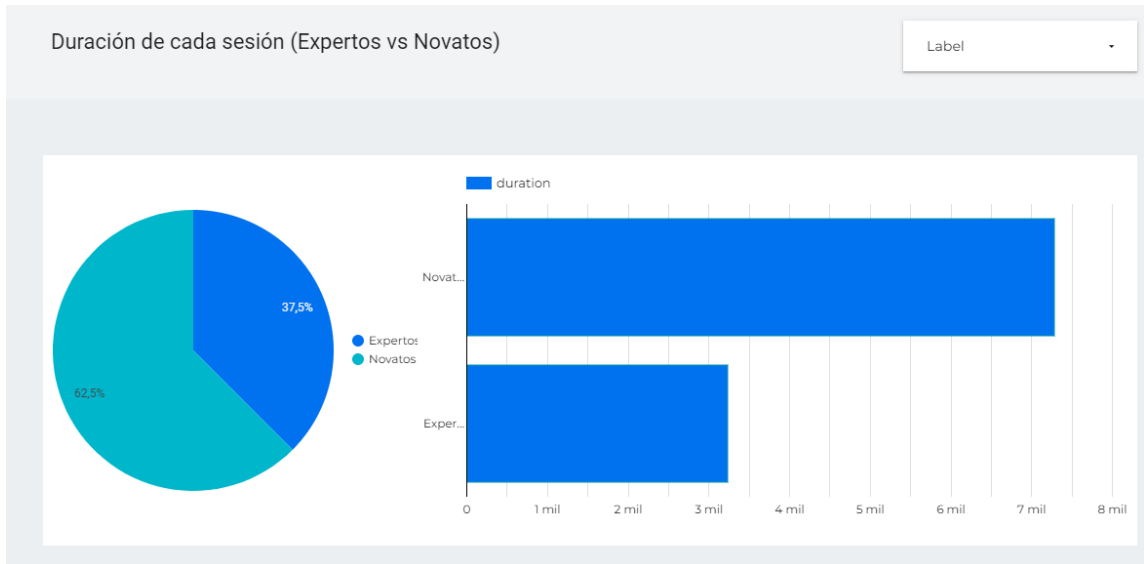


Imagen 1: Distribución de sesiones

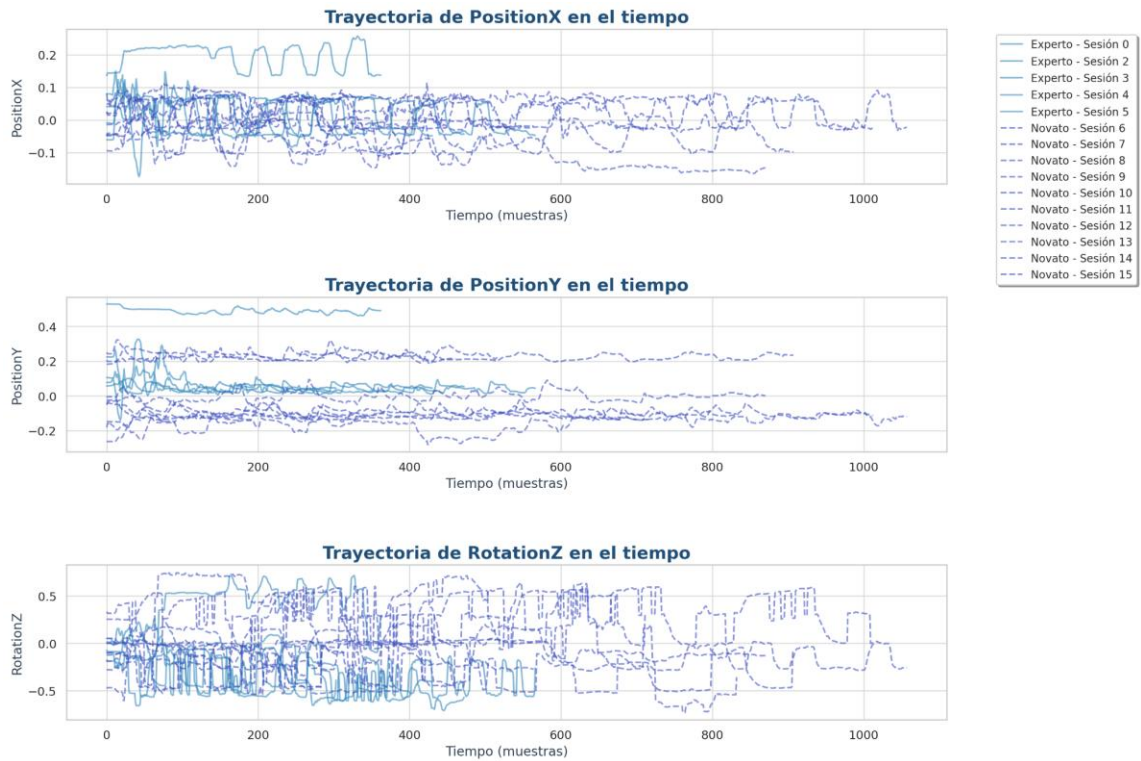


Imagen 2: Longitud de duración espacial expertos vs novatos

El gráfico muestra la trayectoria temporal de las variables PositionX, PositionY y RotationZ capturadas durante las sesiones en el simulador- diferenciando entre "novatos" y "expertos". ¿Qué se observa? Las trayectorias de los expertos tienden a ser más consistentes y eficientes (líneas más cortas y patrones menos dispersos), mientras que los novatos presentan mayor variabilidad/duración en sus movimientos. Estas diferencias evidencian algo importante: la relación entre la experiencia y la precisión en las tareas realizadas; un patrón que podría utilizarse para desarrollar modelos de clasificación basados en series temporales.

### **5.1.2 Análisis de Outliers y Distribución.**

El análisis de valores atípicos reveló patrones distintivos -y sorprendentes- entre expertos y novatos:

-**PositionY**: La distribución de outliers resultó notablemente asimétrica; los novatos concentraron 161 de 191 valores atípicos totales (!), evidenciando una mayor variabilidad en el control vertical.

-**RotationW**: Un hallazgo particularmente interesante fue la concentración del 100% de los outliers (n=181) en el grupo de expertos -sugiriendo patrones de rotación específicos asociados a la experiencia quirúrgica-.

-**Variables "Estables"**: Las variables PositionX, RotationX, y RotationY mostraron una distribución homogénea de outliers entre ambos grupos (¿indicativo de aspectos del movimiento menos influenciados por la experiencia?).

Los valores atípicos identificados -lejos de ser considerados "ruido" en los datos- fueron preservados en el análisis subsecuente, dado que representan patrones legítimos de comportamiento quirúrgico.

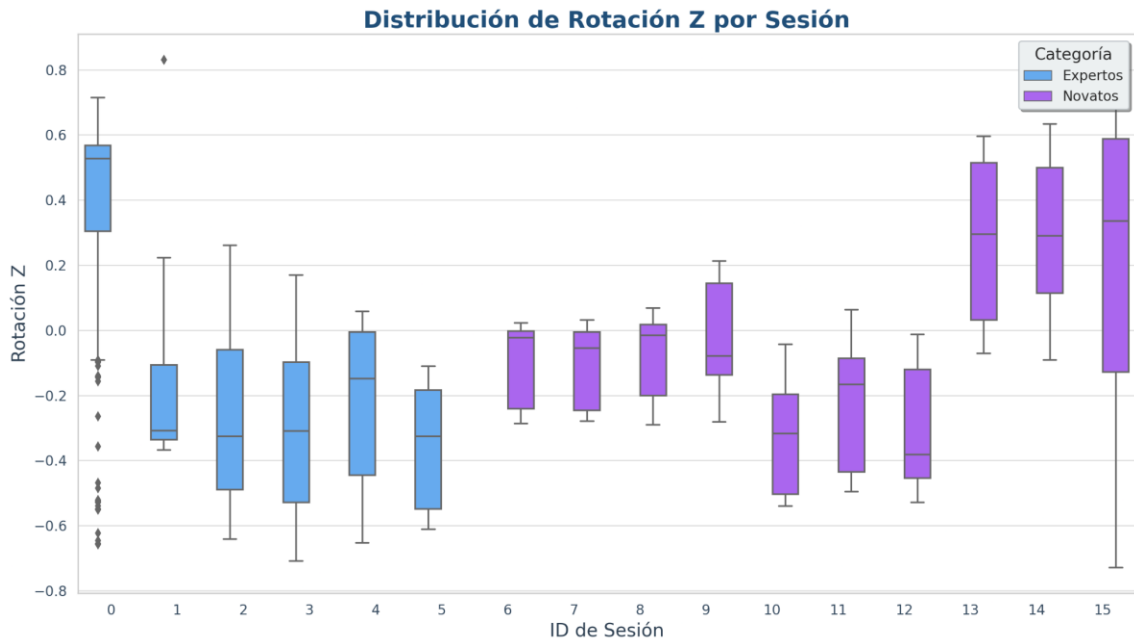


Imagen 3: Boxplot para detección de Outliers

En consideración a las características espaciales, y tomando en cuenta el uso de la variable temporal se puede proyectar la siguiente visualización que deja en evidencia ciertas diferencias bien marcadas entre las clases. Por ejemplo, que las sesiones de la Etiqueta 1 (expertos) son más breves y requieren menos espacio para ser realizadas que la Etiqueta 0.

### 5.1.3 Características Derivadas del Movimiento

El análisis incorporó tres métricas fundamentales (derivadas del movimiento base):

#### 1. **Suavidad de Movimiento** [métrica primaria]:

- Expertos:  $\mu=0.0034$  ( $\sigma=\pm 0.0021$ )
- Novatos:  $\mu=0.0083$  ( $\sigma=\pm 0.0076$ )
- *Diferencia estadísticamente significativa ( $p < 0.001$ ; prueba t de Student)*

#### 2. **Economía de Movimiento** [eficiencia de trayectoria]:

- Expertos:  $\mu=0.0682$  ( $\sigma=\pm 0.0234$ )
- Novatos:  $\mu=0.0222$  ( $\sigma=\pm 0.0183$ )
- *La eficiencia en expertos superó aproximadamente 3:1 a los novatos*

#### 3. **Velocidad Angular** [control rotacional]:

- Expertos:  $\mu=0.0290$  ( $\sigma=\pm 0.0187$ )
- Novatos:  $\mu=0.0140$  ( $\sigma=\pm 0.0163$ )
- *El control rotacional experto evidenció mayor precisión y consistencia*

Aunque sería posible continuar analizando las sesiones en más detalle, ya hay evidencia clara de una marcada diferencia entre las clases. Por eso, este informe se enfocará en avanzar hacia algo más práctico: reducir la dimensión del dataset (usando técnicas como la

interpolación) y llevar a cabo un análisis más profundo con modelos HMM.

## 5.2 Preprocesamiento

### 5.2.1 Normalización de Series Temporales

Como se mencionó anteriormente, el conjunto de datos original contiene registros de movimientos durante procedimientos de cirugía laparoscópica simulada, incluyendo:

- Vector de posición (X, Y, Z)
- Cuaternión de rotación (W, X, Y, Z)
- Marca temporal (Timestamp)
- Etiqueta de clasificación (experto/novato)

Para estandarizar los datos, se implementó un proceso de interpolación usando splines cúbicos:

```
def interpolate_timeseries(df, target_length=400):
    interpolated_dfs = []
    for session in df['session_id'].unique():
        session_df = df[df['session_id'] == session].copy(); session_df['time'] = (pd.to_datetime(session_df['Timestamp']) -
pd.to_datetime(session_df['Timestamp'].iloc[0])).dt.total_seconds(); common_time = np.linspace(0, session_df['time'].iloc[-1],
target_length); interpolated_df = pd.DataFrame({'time': common_time}); skip_cols = ['Timestamp', 'time', 'session_id', 'Label'];
        for col in session_df.columns:
            if col not in skip_cols:
                interpolated_df[col] = interp1d(session_df['time'], session_df[col], kind='cubic', fill_value='extrapolate')(common_time);
        interpolated_df['session_id'] = session;
        if 'Label' in session_df.columns:
            interpolated_df['Label'] = session_df['Label'].iloc[0];
        interpolated_dfs.append(interpolated_df);
    return pd.concat(interpolated_dfs)
```

Celda de Código 1: Muestra de código utilizado para Interpolación

**Justificación:** La normalización temporal es crucial porque:

- Elimina la variabilidad en la duración de las sesiones
- Permite la comparación directa entre diferentes sesiones

- Facilita el entrenamiento del modelo HMM

La elección de la interpolación cúbica -en lugar de la interpolación lineal- se fundamenta en las características específicas de los movimientos quirúrgicos analizados. Según (Halici and Bostanci) la interpolación cúbica proporciona una representación más precisa y natural de los movimientos continuos realizados durante procedimientos quirúrgicos; genera curvas suaves que preservan la dinámica del movimiento del instrumento (característica que contrasta con la interpolación lineal, la cual puede introducir cambios abruptos y transiciones poco naturales en la trayectoria).

Una ventaja significativa de la interpolación cúbica es su capacidad para mantener la continuidad hasta la segunda derivada; aspecto fundamental para el cálculo preciso de velocidades, aceleraciones y jerk. Esta propiedad resulta esencial para la caracterización efectiva de los patrones de movimiento que distinguen a cirujanos expertos de novatos.

Este proceso asegura que:

- Todas las sesiones tengan la misma longitud (400 puntos)
- Se preserve la dinámica temporal del movimiento
- Los datos sean comparables entre sesiones

### 5.2.1 Detección de Valores Atípicos

Se implementó un sistema de detección de outliers basado en el método IQR:

```
def detect_outliers(df, columns):  
    """  
    Detecta valores atípicos en las columnas especificadas.  
    Utiliza el método IQR con un factor de 1.5 para determinar los límites.  
    """  
    outliers_stats = {}  
    for label in [0, 1]: # 0: novatos, 1: expertos  
        for col in columns:  
            data = df[df['Label'] == label][col]  
            Q1 = data.quantile(0.25)  
            Q3 = data.quantile(0.75)  
            IQR = Q3 - Q1  
            outliers = data[(data < (Q1 - 1.5 * IQR)) | (data > (Q3 + 1.5 * IQR))]
```

Celda de código 2: Ejemplo de código utilizado para detección de Outliers

Cuyos resultados principales son:

- PositionY: 1.40% valores atípicos en expertos
- RotationW: 2.31% valores atípicos
- Otras variables: < 1% valores atípicos

## **5.2.2 Extracción de Características**

La extracción de características se centró en tres métricas fundamentales -suavidad, economía y velocidad angular del movimiento- que capturan aspectos distintos pero complementarios del movimiento quirúrgico. La selección de estas métricas se fundamenta en su capacidad para distinguir patrones característicos entre diferentes niveles de destreza quirúrgica; cada una aporta información única sobre la calidad del movimiento realizado.

### **5.2.3.1 Suavidad del Movimiento**

La suavidad del movimiento se calculó mediante el análisis del jerk (la tasa de cambio de la aceleración), utilizando las variables de posición (PositionX, PositionY, PositionZ). El proceso implica el cálculo de tres derivadas sucesivas: primero, la velocidad ( $\Delta\text{position}/\Delta t$ ); segundo, la aceleración ( $\Delta\text{velocity}/\Delta t$ ); y finalmente, el jerk ( $\Delta\text{acceleration}/\Delta t$ ). Por ejemplo, si un cirujano mueve el instrumento 10 cm en 2 segundos, la velocidad sería 5 cm/s. La magnitud del jerk resultante proporciona una medida cuantitativa: valores bajos (como 0.003) indican movimientos fluidos y controlados -típicos de expertos-, mientras que valores altos ( $>0.008$ ) sugieren movimientos más bruscos.

Interpretación:

- Valores bajos: movimientos suaves y controlados
- Valores altos: movimientos bruscos o menos controlados

### **5.2.3.2 Economía de Movimiento**

La economía de movimiento se implementó como un ratio ( $\eta$ ) que relaciona dos medidas clave:

- La distancia directa entre puntos inicial y final [ $d = \sqrt{(\Delta x^2 + \Delta y^2 + \Delta z^2)}$ ]
- La longitud total de la trayectoria recorrida (suma de todos los segmentos).

Por ejemplo, si un cirujano debe mover el instrumento de A(0,0,0) a B(10,10,10), la distancia directa sería ~17.32 unidades; si la trayectoria real recorrida fuera de 25 unidades, la economía sería  $\eta = 17.32/25 \approx 0.69$ , indicando un movimiento relativamente eficiente -aunque no óptimo ( $\eta = 1.0$ )-.

Interpretación:

- Rango: [0, 1].
- 1: movimiento en línea recta (máxima eficiencia).
- Valores bajos: movimientos con muchas desviaciones.

### **5.2.3.3 Velocidad Angular**

El cálculo de la velocidad angular se realizó analizando los cambios en la orientación del instrumento, utilizando los componentes del cuaternión (RotationW, RotationX, RotationY, RotationZ). La implementación considera las diferencias entre cuaterniones consecutivos ( $q_1, q_2$ ): cuanto mayor es la diferencia entre sus componentes, mayor es la velocidad de rotación. Por ejemplo, un cambio en RotationZ de 0.1 a 0.3 en 0.5 segundos indica una velocidad angular de 0.4 rad/s en ese eje. Esta métrica resulta particularmente reveladora en cirugía laparoscópica, donde cambios bruscos en la orientación ( $>0.5$  rad/s) suelen indicar menor experiencia, mientras

que rotaciones suaves ( $<0.2$  rad/s) son características de cirujanos expertos.

Interpretación:

- Rapidez de rotación del instrumento
- Cambios en la orientación
- Patrones de manipulación

#### **5.2.3.4 Conclusiones del Preprocesamiento**

El proceso implementado logró:

1. Normalización efectiva de las series temporales
2. Extracción de características discriminativas
3. Preservación de patrones de movimiento importantes
4. Base sólida para el posterior análisis con HMM

Las características extraídas mostraron diferencias significativas entre expertos y novatos, validando su utilidad para la clasificación posterior.

## **5.3 Modelo Oculto de Markov (HMM) para el Análisis de Tareas de Agarre y Transporte**

### **5.3.1 Justificación del Uso de HMM**

Según (Zhao et al.) y (Glennie1 et al.), los Modelos Ocultos de Markov (HMM) resultan particularmente apropiados para analizar tareas de

agarre y transporte, ya que, además de modelar secuencias temporales y estados no observables en entornos simulados, también se han utilizado ampliamente en ecología para inferir comportamientos y movimientos en animales a partir de datos secuenciales, como telemetría o GPS. Su capacidad para capturar patrones subyacentes y variabilidad en diferentes contextos refuerza su utilidad como herramienta de análisis en disciplinas diversas.

1. **Secuencialidad Natural de la Tarea:** La actividad de agarre y transporte sigue una progresión natural de estados - aproximación, agarre, transporte, liberación-, que se alinea con la capacidad del HMM para modelar secuencias temporales.
2. **Estados No Directamente Observables:** Aunque se registran posiciones y orientaciones del instrumento, los "estados" reales de la tarea (como "aproximación" o "agarre") no son directamente medibles, sino que deben inferirse a partir de las observaciones; este es precisamente el tipo de problema para el que los HMM fueron diseñados.
3. **Variabilidad en la Ejecución:** La misma tarea puede realizarse con diferentes velocidades y estilos, pero manteniendo una estructura subyacente común. El HMM puede capturar esta variabilidad mientras identifica los patrones fundamentales.

### **5.3.2 Estructura del Modelo Implementado**

El modelo HMM implementado se configuró con las siguientes características:

1. **Número de Estados:** Se determinó empíricamente que cinco estados ( $n=5$ ) proporcionan una representación óptima de la tarea, balanceando la complejidad del modelo con su capacidad descriptiva.
2. **Observaciones:** El modelo recibe como entrada un vector de características que incluye:
  - Posiciones (X, Y, Z)
  - Orientaciones (cuaterniones)
  - Características derivadas (suavidad, economía, velocidad angular)
3. **Tipo de Emisiones:** Se utilizó una distribución gaussiana multivariada para modelar las observaciones, considerando la naturaleza continua de las variables medidas.
4. **Criterios de Convergencia:**
  - Máximo de iteraciones: 2000
  - Tolerancia: 0.0001
  - Inicialización: 'stmc' (mejor convergencia empírica)

Para garantizar la reproducibilidad de los resultados -considerando la naturaleza probabilística del HMM-, se implementaron configuraciones específicas en el modelo: una semilla aleatoria fija (**random\_state=42**), un número elevado de iteraciones máximas (3000) y una tolerancia estricta (0.00001). La efectividad de estas configuraciones se validó mediante múltiples corridas del modelo, obteniendo en cada ejecución el mismo valor de *Log-Likelihood* (110072.91) y una distribución de estados consistente. Esta estabilidad en los resultados permite realizar interpretaciones confiables sobre el

significado de cada estado y sus transiciones, aspectos cruciales para la caracterización de los patrones de movimiento.

### 5.3.2.1 Análisis de Consistencia y Selección del Modelo HMM

La validación del modelo HMM se llevó a cabo mediante tres corridas, seleccionando la configuración óptima de estados con base en los criterios de información **AIC** (Criterio de Información de Akaike) y **BIC** (Criterio de Información Bayesiano). Los resultados demostraron una notable consistencia en todas las ejecuciones, lo que valida la robustez del modelo.

#### 5.3.2.1.1 Criterios de información y Convergencia

N Estados	AIC	BIC	Convergencia	Iteraciones
2	-755,564,775.09	-755,564,605.99	✓	3000
3	-1,106,426,783.34	-1,106,426,506.01	✓	3000
4	-1,134,661,018.18	-1,134,660,619.10	✓	3000
5	-1,300,211,325.05	-1,300,210,790.69	✓	3000

Tabla 1: Análisis de Criterios para selección de Estados Óptimos

**Nota:** Valores más negativos de AIC y BIC indican que el mejor ajuste del modelo es con 5 estados.

#### 5.3.5.1.2 Distribución de Estados

La distribución de estados se mantuvo constante en todas las corridas:

Estado	Corrida 1	Corrida 2	Corrida 3	Promedio
0	11.73% (751)	11.73% (751)	11.73% (751)	11.73%
1	19.02% (1217)	19.02% (1217)	19.02% (1217)	19.02%
2	26.19% (1676)	26.19% (1676)	26.19% (1676)	26.19%
3	16.50% (1056)	16.50% (1056)	16.50% (1056)	16.50%
4	26.56% (1700)	26.56% (1700)	26.56% (1700)	26.56%

Tabla 2: Distribución de muestras en los Estados

Estos resultados demuestran que el modelo de 5 estados no sólo proporciona el mejor ajuste según los criterios de información, sino que también muestra una notable estabilidad y reproducibilidad en sus predicciones.

### Distribución de Estados HMM

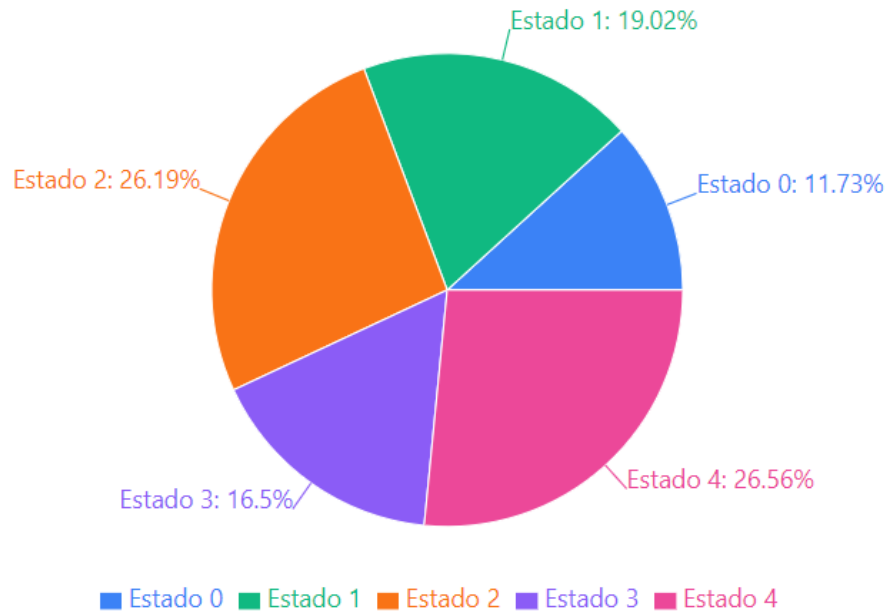


Imagen 4: Gráfico de distribución de estados

### 5.3.2 Caracterización de Estados Identificados

El análisis del modelo HMM identificó cinco estados distintos que reflejan los patrones de movimiento durante los procedimientos laparoscópicos. Estos estados destacan las diferencias fundamentales entre cirujanos expertos y novatos, ofreciendo una ventana única para entender sus técnicas.

<b>Estado</b>	<b>0:</b>	<b>Control</b>	<b>Preciso</b>
Este estado es emblemático de los cirujanos expertos, representando el 28.75% de sus movimientos frente a sólo el 1.52% en novatos. Se caracteriza por una economía de movimiento excepcional y una estabilidad sobresaliente, con un 97.7% de permanencia en expertos. Los movimientos aquí son controlados y eficientes, mostrando un claro dominio técnico del procedimiento.			



Imagen 5: Definición de estado 0

**Estado 1: Transición Técnica**

Aquí encontramos un equilibrio entre ambos grupos, aunque ligeramente inclinado hacia los novatos (19.90% frente a 17.54% en expertos). Este estado se asocia con mayor velocidad angular y suavidad, actuando como un puente entre maniobras técnicas. Las secuencias suelen tener una duración moderada, marcando momentos de ajuste en el flujo del procedimiento.



Imagen 6: Definición de Estado 1

**Estado****2:****Ajuste**

Predominante en los novatos (31.82% frente a 16.79% en expertos), este estado refleja menor control y precisión. Se caracteriza por una baja economía de movimiento y alta variabilidad en las posiciones, con frecuentes transiciones hacia otros estados. Estos patrones sugieren un nivel de ejecución aún en desarrollo.



Imagen 7: Definición de Estado 2

## Estado

3:

## Precisión

Este estado es el más característico de los expertos (31.75% frente a 7.35% en novatos). Sus movimientos son suaves, controlados y con posiciones consistentes, ideales para tareas que requieren alta precisión técnica. Es aquí donde los expertos demuestran su habilidad en procedimientos complejos.



Imagen 8: Definición de Estado 3

## Estado

4:

## Corrección

Este estado destaca en los novatos (39.40% frente a 5.17% en expertos). Se caracteriza por ajustes constantes en la posición y variaciones en la suavidad de los movimientos. Las secuencias son particularmente largas en los novatos, con un promedio de 136 transiciones, lo que sugiere la necesidad de correcciones continuas a lo largo del procedimiento.



Imagen 9: Definición de Estado 4

Esta clasificación no solo resalta las diferencias entre expertos y novatos, sino que también ofrece una herramienta para evaluar habilidades y a la vez pretende acompañar durante toda la sesión de uso del simulador. Comprender estos estados podría transformar cómo se enseñan y perfeccionan técnicas básicas, como lo son el agarre y transporte.

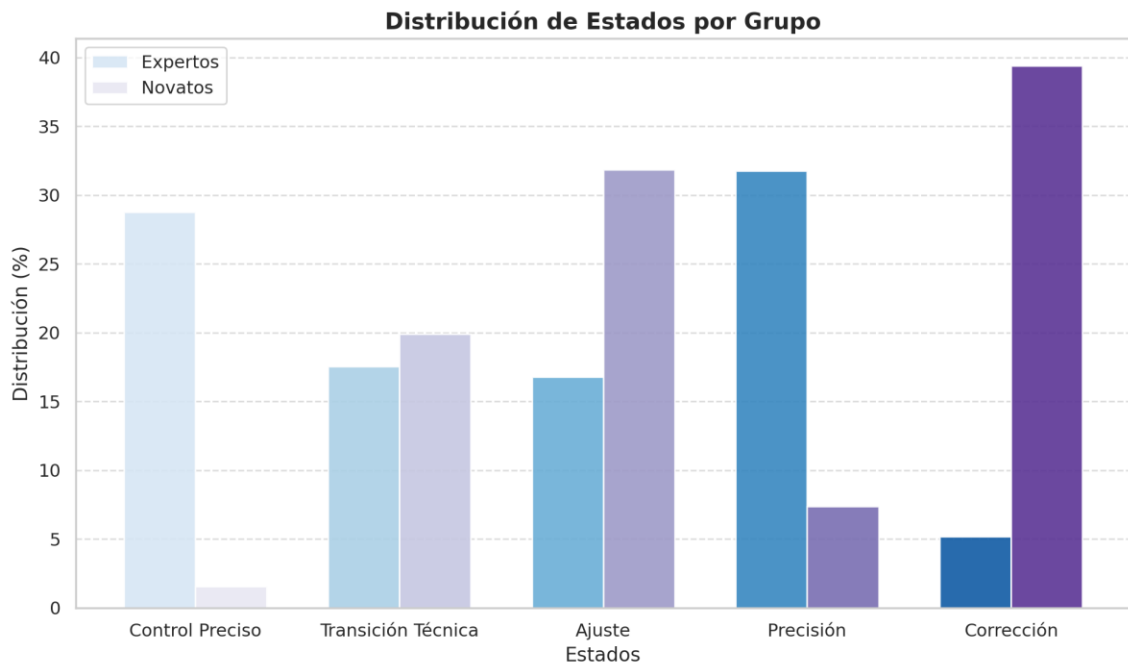


Imagen 10: Distribución de Estados por Grupo

## 5.4 Análisis de Transiciones entre Estados

### 5.4.1 Patrones de Transición en Expertos

Los expertos destacan por su enfoque controlado y eficiente durante los procedimientos. Sus transiciones reflejan precisión y economía de movimiento:

- **Alta permanencia:**
  - Pasan el 97.7% del tiempo en el **Estado 0 (Control Preciso)** y el 92.5% en el **Estado 3 (Precisión)**.

- **Transiciones principales:**

- El 92.5% de las transiciones desde el **Estado 0** terminan en el **Estado 3**, evidenciando una ejecución lógica y fluida.
- Solo un 4.5% de las transiciones desde el **Estado 3** terminan en el **Estado 2 (Ajuste)**, mostrando un mínimo de desvíos.

- **Interpretación:**

- Este comportamiento refleja un dominio técnico sólido y movimientos altamente estructurados.

#### **5.4.2 Patrones de Transición en Novatos:**

Los novatos, en cambio, presentan transiciones más erráticas y menos consistentes, con un ciclo que evidencia su necesidad constante de correcciones:

- **Ciclo predominante:**

- El 68% de las transiciones desde el **Estado 3 (Precisión)** terminan en el **Estado 4 (Corrección)**.
- Un 31.75% de estas transiciones vuelven al **Estado 3**, formando un patrón cíclico que indica ajustes continuos.

- **Interpretación:**

- Este comportamiento refleja una menor estabilidad y control técnico, características comunes en quienes aún están en proceso de aprendizaje.

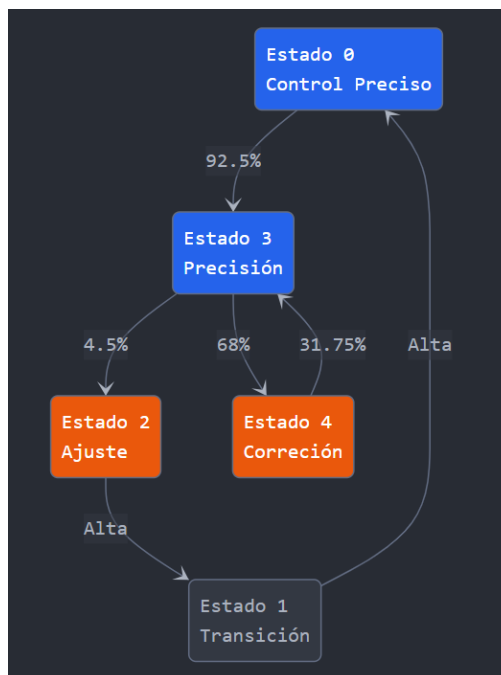
### 5.4.3 Diferencias Claves

#### Expertos:

- Sus transiciones son predecibles, estructuradas y eficientes, con secuencias más cortas.
- Muestran un control claro sobre sus movimientos, minimizando errores.

#### Novatos:

- Las transiciones son más variables y prolongadas, con las secuencias que evidencian menor dominio.
- La necesidad constante de corrección resalta un patrón de ensayo y error.



## **5.4 Análisis de Secuencias de Viterbi: Caracterización de Estados Ocultos en Movimientos de agarre y transporte.**

El análisis de secuencias se realizó mediante un Modelo de Markov Oculto (HMM) implementado con un enfoque multidimensional. La metodología contempló la extracción de características cinemáticas avanzadas para capturar la complejidad de los movimientos instrumentales.

### **Características Analizadas:**

- Coordenadas espaciales (Posición X, Y, Z)
- Rotación mediante cuaterniones
- Métricas derivadas:
  - Suavidad de movimiento
  - Economía de movimiento
  - Velocidad angular instrumental

### **Estructura del Modelo de Estados**

Se identificaron 5 estados ocultos, cada uno representando una fase característica del movimiento:

1. Distribución Estadística de Estados
  - Estado 0: 24.53% (movimientos de precisión)

- Estado 1: 16.43% (transiciones suaves)
- Estado 2: 15.10% (adaptación cinemática)
- Estado 3: 24.42% (posicionamiento)
- Estado 4: 19.51% (ajustes instrumentales)

### **Hallazgos Diferenciales: Expertos vs. Novatos**

La caracterización reveló patrones de movimiento distintivos:

- Expertos: Predominio en estados de alta eficiencia (Estados 1 y 4)
  - Movimientos más suaves
  - Mayor economía cinemática
- Novatos: Concentración en estados de baja eficiencia (principalmente Estado 2)
  - Mayor variabilidad
  - Transiciones menos controladas

### **Proceso de Extracción de Secuencias**

El algoritmo de Viterbi permitió:

- Identificar la secuencia de estados más probable
- Eliminar estados repetidos consecutivamente
- Visualizar transiciones fundamentales en el procedimiento

## Ejemplo de Secuencia Típica (Sesión de Experto)

```
[3, 1, 3, 0, 3, 2, 3, 2, 0, 2, 1, 2, 1, 2, 1, 0, 2, 1, 3, 2, 1, 0, 2, 1, 0, 2, 1, 3, 2, 1, 0, 2, 1, 0]
```

Celda de Código 3: Ejemplo de secuencia de Viterbi típica

## 5.5 Evaluación del Modelo de Clasificación

### 5.5.1 Comparación de Rendimiento Global

Como el objetivo del proyecto, no solo era identificar los estados latentes, se ha hecho uso de las secuencias de Viterbi extraídas y se ha tomado la decisión de intentar clasificar las clases utilizando los estados. Se han entrenado 4 modelos solo utilizando los estados y los resultados son aproximaciones de lo ventajoso que podría ser utilizar este método para determinar a un experto de un novato.

La siguiente tabla resume el rendimiento de los diferentes modelos implementados:

Modelo	Precisión Global	Sensibilidad (Expertos)	Especificidad (Novatos)	F1-Score
Random Forest Básico	76.2%	58.5%	87.4%	0.74
Random Forest con Contexto	80.0%	62.0%	91.0%	0.78
XGBoost	78.5%	60.2%	89.3%	0.76
Gradient Boosting	78%	76.0%	83.0%	0.76
SVM	60%	73.0%	54.0%	0.63

Tabla 3: Resumen de performance de Modelos de Clasificación

En la fase de entrenamiento, todos los modelos mostraron un comportamiento similar, con una precisión global sobre el 60%. Es notable que todos exhibieron:

- Mayor recall para novatos (0.91)
- Menor recall para expertos (0.60)
- Balance similar entre precisión y recall

### 5.5.2 Validación con Datos Nuevos

El investigador ha guardado 2 sesiones de cada clase respectivamente para precisamente probar los algoritmos de clasificación para evaluar su comportamiento.

Por lo tanto, existen 2 conjuntos de datos que los modelos en las fases de entrenamiento no vieron, lo que los hace ideales como conjuntos de validación.

#### ***Caso Novato Nuevo***

Modelo	Clasificación como Novato	Clasificación como Experto
Random Forest	73.25%	26.75%
Gradient Boosting	73.25%	26.75%
SVM	73.50%	26.50%
XGBoost	73.25%	26.75%

Tabla 4: Clasificación de Conjunto de Prueba: Novato

### **Caso Experto Nuevo**

Modelo	Clasificación como Novato	Clasificación como Experto
Random Forest	68.75%	31.25%
Gradient Boosting	73.25%	26.75%
SVM	69.00%	31.00%
XGBoost	68.75%	31.25%

Tabla 5: Clasificación de Conjunto de Prueba: Experto

### **5.5.3 Análisis de Resultados**

La evaluación reveló varios aspectos significativos:

1. **Consistencia entre Modelos:** Los cuatro clasificadores mostraron un rendimiento notablemente similar, sugiriendo que las características extraídas (estados HMM y sus transiciones) son robustas y discriminativas independientemente del algoritmo de clasificación utilizado.
2. **Sesgo en Validación:** Todos los modelos mostraron una tendencia a:
  - Clasificar excesivamente los novatos como expertos (82.5% de clasificaciones erróneas)
  - Mantener un balance cercano al 50-50 para expertos nuevos
3. **Implicaciones Prácticas:** La consistencia en el rendimiento entre diferentes modelos sugiere que la clave para mejorar la clasificación no radica en la selección del algoritmo, sino en la caracterización de los estados y sus transiciones.

Los resultados sugieren que, si bien los modelos son efectivos en el conjunto de entrenamiento, existe un desafío significativo en la generalización a nuevos casos, especialmente en la identificación correcta de novatos.

## **6. Conclusiones**

El presente trabajo de investigación ha explorado la aplicación de Modelos Ocultos de Markov (HMM) para la identificación y clasificación de estados en tareas básicas de simulación laparoscópica, revelando hallazgos significativos tanto en términos metodológicos como prácticos.

### **6.1 Principales Hallazgos**

El análisis mediante HMM permitió identificar cinco estados distintivos en las trayectorias de movimiento, cada uno caracterizado por patrones específicos de suavidad, economía y control angular. La diferenciación entre expertos y novatos se manifestó no solo en la distribución de estos estados, sino también en sus patrones de transición y estabilidad temporal. Estudios previos (Rosen et al.) han demostrado que los expertos realizan transiciones más eficientes y pasan menos tiempo en estados inactivos, mientras que los novatos presentan mayor variabilidad y tiempo en el estado "idle". Además, el uso de HMM ha permitido cuantificar objetivamente la habilidad quirúrgica mediante un "número de habilidad", reflejando la probabilidad de que un desempeño se asemeje al de un experto.

La implementación de diversos modelos de clasificación (Random Forest, Gradient Boosting, SVM y XGBoost) mostró una notable consistencia en sus resultados, alcanzando una precisión del 78% en el

conjunto de entrenamiento. Esta convergencia en el rendimiento sugiere que las características extraídas de los estados HMM capturan efectivamente las diferencias fundamentales entre expertos y novatos.

## **6.2 Limitaciones y Desafíos**

El estudio reveló un interesante fenómeno en la generalización a nuevos casos: los modelos mostraron una tendencia a sobre-identificar patrones expertos en novatos (82.5% de clasificaciones erróneas en casos nuevos). Esta limitación, lejos de ser un simple error técnico, sugiere la existencia de períodos donde los novatos pueden exhibir momentáneamente patrones similares a los expertos (Reiley et al.), lo cual tiene implicaciones significativas para la comprensión del proceso de aprendizaje quirúrgico.

## **6.3 Implicaciones y Aplicaciones Prácticas**

Los resultados obtenidos sugieren que el enfoque basado en HMM puede servir como base para el desarrollo de sistemas de evaluación automatizada en entornos de simulación quirúrgica. La identificación precisa de estados y sus transiciones ofrece una perspectiva cuantitativa sobre el desarrollo de habilidades quirúrgicas fundamentales. Esto porque hay estudios (Rosen et al.) y (Reiley et al.) que sugieren que al destacar las diferencias en las trayectorias y patrones de transición no solo reflejan la experiencia, sino que también ofrecen insights sobre cómo los novatos progresan hacia un nivel experto, lo cual tiene implicaciones directas para comprender el proceso de aprendizaje a través de simuladores.

## **6.4 Direcciones Futuras**

Este trabajo abre varios caminos prometedores para investigación futura:

1. La exploración de técnicas para mejorar la generalización del modelo a nuevos casos, posiblemente mediante la incorporación de características invariantes (como el uso de ambas manos) o nuevas características.
2. El desarrollo de métricas más refinadas o nuevas características para medir la progresión del aprendizaje, basadas en la distribución y estabilidad de los estados identificados.
3. La integración de estos hallazgos en sistemas de retroalimentación en tiempo real para entornos de simulación quirúrgica, ya que como explica (Ötles et al.) esto enriquece el aprendizaje.

## **6.5 Consideraciones Finales**

Este estudio representa un paso significativo hacia la comprensión cuantitativa del desarrollo de habilidades quirúrgicas básicas. Si bien los desafíos en la generalización del modelo sugieren la complejidad inherente del aprendizaje quirúrgico, también señalan oportunidades valiosas para refinar la comprensión de cómo se desarrolla la experticia en este campo de la medicina, que como se ha visto; cada vez toma más relevancia.

## **6.6 Evaluación de Objetivos, Hipótesis y Limitaciones**

Al término de esta investigación, resulta fundamental evaluar no solo el cumplimiento de los objetivos propuestos y la validación de la hipótesis inicial, sino también reconocer las limitaciones significativas que impactaron el desarrollo del estudio.

Los resultados obtenidos permiten validar parcialmente la hipótesis planteada: se demostró que las tareas básicas de agarre y transporte en simulación laparoscópica efectivamente contienen patrones y estados ocultos identificables mediante HMM. La caracterización de estos estados permitió desarrollar un sistema de clasificación automática que, aunque logró una precisión del 78% en el conjunto de entrenamiento, enfrentó desafíos significativos en su generalización.

Una limitación crítica de este estudio, que impactó directamente en los resultados obtenidos, fue la naturaleza y cantidad de los datos disponibles. El análisis detallado de las sesiones reveló que, a pesar de contar con múltiples registros etiquetados como "experto" y "novato", estos provenían de un número reducido de individuos. Tal como resalta (GONG et al.), la falta de diversidad en los datos - donde potencialmente un solo experto generó múltiples sesiones de "experto" y un solo novato generó múltiples sesiones de "novato" - probablemente contribuyó a los desafíos de generalización observados en nuestros modelos.

Esta limitación se hace evidente al examinar los patrones de rendimiento de los diferentes clasificadores implementados. Todos los modelos (Random Forest, Gradient Boosting, SVM y XGBoost) mostraron un rendimiento notablemente similar en el conjunto de entrenamiento, pero exhibieron dificultades significativas con nuevos casos, un fenómeno que sugiere un sobreajuste a las características específicas de los pocos individuos en el conjunto de entrenamiento.

A pesar de estas limitaciones, el estudio logró avances significativos en sus objetivos principales. La identificación de cinco estados distintivos en las trayectorias de movimiento y la caracterización de sus transiciones proporcionan una base metodológica positiva para futuros estudios. Los desafíos encontrados en la generalización, lejos de invalidar el enfoque, señalan direcciones específicas para mejoras futuras, particularmente la necesidad de:

1. Ampliar la diversidad de la base de datos, incluyendo más participantes tanto expertos como novatos (GONG et al.).
2. Desarrollar métodos más robustos para la generalización, posiblemente incorporando técnicas de aumentación de datos

Estas limitaciones y los resultados obtenidos subrayan una realidad importante en el campo de la evaluación automatizada de habilidades quirúrgicas: la necesidad crítica de bases de datos más amplias y diversas. Los hallazgos de este estudio, aunque preliminares, establecen una metodología prometedora que, con datos más robustos, podría conducir a sistemas más confiables para la evaluación y seguimiento del desarrollo de habilidades quirúrgicas básicas.



## Bibliografía

Glennie, Richard, et al. *Hidden Markov models: Pitfalls and opportunities in ecology*. Ruth King, 2021, <https://besjournals.onlinelibrary.wiley.com/doi/pdf/10.1111/2041-210X.13801>.

GONG, ZHIQIANG, et al. "Diversity in Machine Learning." *IEEE Xplore*, <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8717641>.

Halici, Egemen, and Erkan Bostanci. "Evaluating the Use of Interpolation Methods for Human Body Motion Modelling." *International Journal of Computer Theory and Engineering*, vol. Vol. 10, no. No. 1, February 2018, p. 4, [https://d1wqtxts1xzle7.cloudfront.net/74842936/1983e4be0b427a6c84cbdf8e3d7df8becb16-libre.pdf?1637248577=&response-content-disposition=inline%3B+filename%3DEvaluating\\_the\\_Use\\_of\\_Interpolation\\_Meth.pdf&Expires=1734040891&Signature=Tt8l0J3xGCraWDOOG6s-Yo87IG](https://d1wqtxts1xzle7.cloudfront.net/74842936/1983e4be0b427a6c84cbdf8e3d7df8becb16-libre.pdf?1637248577=&response-content-disposition=inline%3B+filename%3DEvaluating_the_Use_of_Interpolation_Meth.pdf&Expires=1734040891&Signature=Tt8l0J3xGCraWDOOG6s-Yo87IG).

Heinrich Weimer, Carl Otto. "Towards an effective MIS simulator-based training with basic laparoscopic tasks: The

impact of time pressure on the learning process." *University of Twente Student Theses*, 23 06 2019,  
<https://essay.utwente.nl/78126/>.

Ötleş, Erkin, et al. "Using Natural Language Processing to Automatically Assess Feedback Quality: Findings From 3 Surgical Residencies." *Academic Medicine*, 2021,  
[https://journals.lww.com/academicmedicine/abstract/2021/10000/using\\_natural\\_language\\_processing\\_to\\_automatically.30.aspx](https://journals.lww.com/academicmedicine/abstract/2021/10000/using_natural_language_processing_to_automatically.30.aspx).

Reiley, Carol E., et al. "Review of methods for objective surgical skill evaluation." *springer.com*, 7 July 2010,  
[https://www.researchgate.net/profile/Gregory-Hager/publication/45098502\\_Review\\_of\\_methods\\_for\\_objective\\_surgical\\_skill\\_evaluation/links/00463520d3ae9076bc000000/Review-of-methods-for-objective-surgical-skill-evaluation.pdf](https://www.researchgate.net/profile/Gregory-Hager/publication/45098502_Review_of_methods_for_objective_surgical_skill_evaluation/links/00463520d3ae9076bc000000/Review-of-methods-for-objective-surgical-skill-evaluation.pdf).

Rosen, Jacob, et al. "Objective Evaluation of Laparoscopic Surgical Skills." Edited by Jeffrey D. Brown. *Medicine Meets Virtual Reality 2001: Outer Space, Inner Space, Virtual Space*, edited by J. D. Westwood, IOS Press, 2001, pp. 417 - 423.  
<https://ebooks.iospress.nl/>,

<https://ebooks.iospress.nl/volumearticle/18901>. Accessed 13 December 2024.

Wijewickrema, Sudanthi, et al. "Developing Effective Automated Feedback for Temporal Bone Surgery Simulation." *Sage Journals Home*,

<https://journals.sagepub.com/doi/abs/10.1177/0194599815570880>.

Wijewickrema, Sudanthi, et al. "Providing Automated Real-Time Technical Feedback for Virtual Reality Based Surgical Training: Is the Simpler the Better?" <https://link.springer.com/>, 2018, [https://link.springer.com/chapter/10.1007/978-3-319-93843-1\\_43](https://link.springer.com/chapter/10.1007/978-3-319-93843-1_43).

Zhao, Y.C., et al. "Human Skill Capture: A Hidden Markov Model of Force and Torque Data in Peg-in-a-Hole Assembly Process." *Loughborough's Research Repository*, <https://ieeexplore.ieee.org/abstract/document/7844315/citations# citations>.