

La investigación reportada en esta tesis es parte de los programas de investigación del CICESE (Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California).

La investigación fue financiada por el SECIHTI (Secretaría de Ciencia, Humanidades, Tecnología e Innovación).

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México). El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo o titular de los Derechos de Autor.

**Centro de Investigación Científica y de Educación  
Superior de Ensenada, Baja California**



---

**Maestría en Ciencias  
en Tecnologías Avanzadas e Integradas**

---

**Impacto de la frecuencia en la detección de conducción  
agresiva versus no agresiva con IMUs utilizando bases de  
datos autoevaluadas**

Tesis  
para cubrir parcialmente los requisitos necesarios para obtener el grado de  
Maestro en Ciencias

Presenta:

Alan Alejandro Galán García

Monterrey, Nuevo León, México  
2025

Tesis defendida por  
**Alan Alejandro Galán García**

y aprobada por el siguiente Comité

**Dr. Gabriel Alejandro Galaviz Mosqueda**  
Codirectores de tesis

**Dr. Salvador Villarreal Reyes**  
Codirectores de tesis

**Dr. Benjamín Raziel Jaramillo Ávila**

**M.C. Enrique Guerrero Arbona**

**Dr. Mario Aguilera Ruiz**

**Dra. Cecilia Soldatini**



**Dr. Benjamín Raziel Jaramillo Ávila**  
Coordinador del Posgrado en Tecnologías Avanzadas e  
Integradas

**Dra. Ana Denise Re Araujo**  
Directora de Estudios de Posgrado

Resumen de la tesis que presenta **Alan Alejandro Galán García** como requisito parcial para la obtención del grado de Maestro en Ciencias en Tecnologías Avanzadas e Integradas

**Impacto de la frecuencia en la detección de conducción agresiva versus no agresiva con IMUs  
utilizando bases de datos autoevaluadas**

Resumen aprobado por:

**Dr. Gabriel Alejandro Galaviz Mosqueda**  
Codirector de tesis

**Dr. Salvador Villarreal Reyes**  
Codirector de tesis

La seguridad vial impulsa el uso de Unidades de Medición Inercial (IMUs) para monitorear el estilo de manejo. Si bien las IMUs de alta precisión son costosas, existen sensores de bajo costo (como los utilizados en smartphones o dispositivos dedicados) que resultan más accesibles. Sin embargo, estos presentan limitaciones en cuanto a estandarización y documentación técnica. Este estudio evalúa el impacto de la frecuencia de muestreo de IMUs de bajo costo en la precisión de la clasificación de manejo (agresivo vs. no agresivo). Se utilizó un dispositivo de captura diseñado a medida para recolectar datos en un circuito cerrado, con conductores que adoptaron estilos agresivos y no agresivos autorreportados. Esta clasificación fue validada objetivamente mediante el análisis de métricas de riesgo físico (aceleración lateral normalizada en curvas). Se aplicaron técnicas de procesamiento de señales (suavizado, diezmado) y aprendizaje automático (KNN, Random Forest, SFFS, PCA) a características extraídas de los datos inerciales, analizando el rendimiento a través de un espectro de frecuencias de muestreo simuladas. Los resultados confirman la viabilidad de IMUs de bajo costo (rango  $\pm 2g$ ), logrando una clasificación de alta precisión (Test AUC > 0.9) siempre que se opere dentro de un rango de frecuencias adecuado. La frecuencia de muestreo es crítica: existe un umbral de viabilidad ( $\sim 1.0$  Hz) por debajo del cual el rendimiento decae drásticamente. En el rango de 5-10 Hz se observa un excelente equilibrio entre precisión y eficiencia, mientras que frecuencias más altas ofrecen ganancias marginales. Características clave incluyeron descriptores espectrales de baja frecuencia y de la forma de la distribución de la señal. La expansión del conjunto de características no mejoró sustancialmente el rendimiento. Random Forest y KNN fueron competitivos, y ambos sensores (LSM6DS y LSM9DS1) resultaron igualmente competentes. El etiquetado autoevaluado se validó eficazmente. El trabajo proporciona una base empírica y recomendaciones para sistemas de monitoreo accesibles.

**Palabras clave:** IMU, estilo de manejo, conducción agresiva, frecuencia de muestreo, aprendizaje automático

Abstract of the thesis presented **by Alan Alejandro Galan Garcia** as a partial requirement to obtain the Master of Science degree in Advanced and Integrated Technologies

### **Impact of Frequency on the Detection of Aggressive versus Non-Aggressive Driving Using IMUs and Self-Reported Datasets**

Abstract approved by:

**Dr. Gabriel Alejandro Galaviz Mosqueda**  
Thesis Codirectors

**Dr. Salvador Villarreal Reyes**  
Thesis Codirectors

Road safety concerns have increased the use of Inertial Measurement Units (IMUs) to monitor driving style. While high-precision IMUs are expensive, low-cost sensors (e.g., in smartphones, dedicated devices) are more accessible, although their standardization and technical documentation are limited. This study evaluates the impact of the sampling frequency of low-cost IMUs on the accuracy of driving style classification (aggressive vs. non-aggressive). A custom-built data acquisition device was used to collect data on a closed-circuit track, with drivers adopting self-reported aggressive and non-aggressive styles. This classification was objectively validated by analyzing physical risk metrics (normalized lateral acceleration in curves). Signal processing (smoothing, decimation) and machine learning (KNN, Random Forest, SFFS, PCA) techniques were applied to features extracted from the inertial data, analyzing performance across a spectrum of simulated sampling frequencies. The results confirm the viability of low-cost IMUs ( $\pm 2g$  range) for achieving high-accuracy classification (Test AUC > 0.9), provided they operate within an appropriate frequency range. Sampling frequency is critical: a viability threshold exists ( $\sim 1.0$  Hz) below which performance drops drastically. An excellent trade-off between accuracy and efficiency is observed in the 5-10 Hz range, while higher frequencies offer only marginal gains. Key features included low-frequency spectral descriptors and metrics related to the signal's distribution shape. Expanding the feature set did not substantially improve performance. Random Forest and KNN were competitive, and both sensors (LSM6DS and LSM9DS1) proved to be equally competent. The self-reported labeling was effectively validated. This work provides an empirical foundation and recommendations for designing accessible monitoring systems.

**Keywords: IMU, driving style, aggressive driving, sampling frequency, machine learning**

## **Dedicatoria**

Este logro es el resultado del apoyo incondicional de las personas más importantes en mi vida. A mi familia, mi pilar fundamental, y de manera muy especial a mi madre, Marianella García, por su amor y por enseñarme a nunca rendirme. Sobre todo, dedico cada página a mi increíble esposa, Ana. Gracias por tu paciencia infinita, por las noches en vela y por creer en mí sin titubear. Tu confianza fue mi brújula y este triunfo es tan tuyo como mío, porque sin ti, nada de esto tendría sentido.

Mi más profundo agradecimiento también al ámbito académico. A mis profesores, por ser guías que retaron mi intelecto y compartieron su conocimiento con generosidad, inspirándome a explorar más allá de lo evidente. Este trabajo es, además, un homenaje a la fortuna de nacer en este tiempo; una era que nos ofrece un universo de información y herramientas capaces de potenciar nuestra curiosidad y permitirnos construir sobre el saber de una forma que antes solo podíamos soñar. Confío en que este sea solo el primer paso de una trayectoria con propósito, con la esperanza de contribuir al desarrollo y abrir caminos para las generaciones.

## Agradecimientos

Quiero agradecer el apoyo institucional y financiero del Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California (CICESE) y de la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI), por el apoyo institucional y financiero brindado. Gracias por ofrecerme los recursos, el entorno académico y la oportunidad para desarrollar esta tesis.

Mi más sincero reconocimiento a los miembros de mi comité de tesis. En especial, agradezco a mis codirectores, el Dr. Gabriel Alejandro Galaviz Mosqueda y el Dr. Salvador Villarreal Reyes. Su guía fue mucho más que una orientación académica; fomentaron un ambiente de trabajo estimulante y riguroso que fue clave para el desarrollo de esta investigación. Valoro enormemente su paciencia, su constante disposición para discutir ideas y su agudeza para corregir errores y proponer mejoras. Gracias por su confianza, su exigencia y por su acompañamiento constante en cada etapa de este camino.

Extiendo un agradecimiento muy especial al Dr. Benjamín Raziel Jaramillo Ávila. Su apoyo en los análisis fue fundamental para afinar los enfoques y dar solidez a los resultados. Su claridad conceptual y su orientación práctica resultaron cruciales en los momentos más desafiantes de este proyecto.

De igual forma, agradezco profundamente al M.C. Enrique Guerrero Arbona. Su detallada retroalimentación y sus valiosas sugerencias enriquecieron significativamente la redacción, la estructura y el enfoque metodológico de este trabajo. Su visión crítica y su exigencia académica dejaron una huella imborrable en la versión final de esta tesis.

Quiero también manifestar mi gratitud al Dr. Mario Aguilera Ruiz y a la Dra. Cecilia Soldatini por el tiempo, la orientación y el compromiso que dedicaron a la evaluación y seguimiento de esta investigación. Reconozco y agradezco sus invaluable aportaciones y su vasta experiencia.

Finalmente, agradezco a todo el personal académico, técnico y administrativo del CICESE, así como a los profesores que me acompañaron durante mis estudios de maestría. Cada clase, cada consejo, cada experiencia en el laboratorio y cada conversación informal contribuyeron de manera significativa a mi crecimiento profesional y personal. Gracias por formar parte de este proceso y por compartir generosamente su conocimiento y su tiempo.

## Tabla de contenido

|   | Página   |
|---|----------|
| Resumen en español.....   | ii       |
| Resumen en inglés.....  | iii      |
| Dedicatoria .....   | iv       |
| Agradecimientos .....   | v        |
| Lista de figuras .....  | x        |
| Lista de tablas.....  | xii      |
| <b>Capítulo 1. Introducción .....</b>                                   | <b>1</b> |
| 1.1 Antecedentes.....   | 2        |
| 1.2 Justificación.....  | 5        |
| 1.3 Planteamiento del problema .....                                    | 6        |
| 1.4 Hipótesis .....   | 6        |
| 1.5 Objetivos .....   | 6        |
| 1.5.1 Objetivo general.....   | 6        |
| 1.5.2 Objetivos específicos.....  | 7        |
| <b>Capítulo 2. Metodología.....</b>                                     | <b>8</b> |
| 2.1 El problema de la clasificación.....                                | 9        |
| 2.1.1 Etiquetado del estilo de manejo .....                             | 10       |
| 2.1.2 Limitaciones de la estrategia de etiquetado.....                  | 11       |
| 2.2 Diseño experimental y adquisición de datos.....                     | 13       |
| 2.3 Etiquetado de estilos de manejo y validación .....                  | 17       |
| 2.4 Preprocesamiento y ampliación de la base de datos .....             | 22       |
| 2.4.1 Justificación del método de submuestreo por diezmado simple ..... | 24       |
| 2.5 Extracción y selección de características.....                      | 27       |
| 2.6 Modelos de clasificación y evaluación.....                          | 29       |

|   |           |
|---|-----------|
| <b>Capítulo 3. Resultados.....</b>  | <b>32</b> |
| 3.1 Validación del etiquetado de estilos de manejo y análisis preliminar de datos ..... | 33        |
| 3.1.1 Análisis estadístico de aceleraciones .....                                       | 33        |
| 3.1.2 Validación del etiquetado mediante métrica de riesgo en curvas (IAL y KDE) .....  | 35        |
| 3.1.2.1 Impacto del estilo de manejo en el IAL.....                                     | 36        |
| 3.1.2.2 Impacto del estilo de manejo en la distribución de los datos .....              | 41        |
| 3.2 Validación de la clasificación basada en autoevaluación .....                       | 46        |
| 3.3 Análisis exploratorio de la dimensionalidad y separabilidad de clases.....          | 46        |
| 3.3.1 Metodología del PCA exploratorio.....   | 47        |
| 3.3.2 Resultados visuales y cuantitativos del PCA .....                                 | 48        |
| 3.3.3 Implicaciones del PCA exploratorio .....  | 51        |
| 3.4 Evaluación del impacto de la frecuencia de muestreo.....                            | 52        |
| 3.4.1 Metodología del análisis PCA multifrecuencia.....                                 | 52        |
| 3.4.2 Resultados visuales y cuantitativos del análisis multifrecuencia.....             | 53        |
| 3.4.3 Implicaciones del PCA multifrecuencia .....                                       | 55        |
| 3.4.4 Resumen y validación metodológica integral .....                                  | 55        |
| 3.5 Resultados de los análisis computacionales de clasificación .....                   | 56        |
| 3.5.1 Análisis #1: evaluación con características "Vaitkus-Inspired" .....              | 57        |
| 3.5.1.1 Metodología específica del análisis #1 .....                                    | 57        |
| 3.5.1.2 Resultados detallados del análisis #1 .....                                     | 60        |
| 3.5.1.3 Discusión del análisis #1 .....   | 62        |
| 3.5.2 Análisis #2: evaluación con características "Zylius-OPTIM" .....                  | 64        |
| 3.5.2.1 Metodología específica del análisis #2 .....                                    | 64        |
| 3.5.2.2 Resultados detallados del análisis #2 .....                                     | 66        |
| 3.5.2.3 Discusión y Conclusiones del Análisis #2 .....                                  | 70        |

|                    |  |            |
|--------------------|--|------------|
| 3.5.3              | Análisis #3: evaluación con características "Zylius-Inspired" completas.....             | 71         |
| 3.5.3.1            | Resultados detallados del análisis #3 .....  | 74         |
| 3.5.3.2            | Metodología específica del análisis #4 .....   | 82         |
| 3.5.3.3            | Resultados detallados del análisis #4 .....  | 84         |
| 3.5.3.4            | Discusión parcial del análisis #4 y comparación con análisis anteriores.....             | 92         |
| 3.6                | Similitud de rendimiento entre sensores (Accel1 vs. Accel2) .....                        | 95         |
| <b>Capítulo 4.</b> | <b>Discusión.....</b>  | <b>97</b>  |
| 4.1                | Validación de la estrategia de etiquetado y relevancia para la clasificación .....       | 97         |
| 4.2                | Impacto de la frecuencia de muestreo en la precisión de la clasificación .....           | 97         |
| 4.2.1              | Baja tasa de muestreo (Frecuencias por debajo de 0.5 Hz).....                            | 98         |
| 4.2.2              | El Umbral de viabilidad (0.5 Hz - 1.0 Hz) .....  | 98         |
| 4.2.3              | La Meseta de rendimiento recomendado (1.0 Hz - 25.0 Hz) .....                            | 98         |
| 4.2.4              | La Zona de mejores en rendimientos marginales y redundancia (25.0 Hz - 50.0 Hz)<br>..... | 99         |
| 4.3                | Eficacia de los conjuntos de características y estrategias de selección .....            | 100        |
| 4.4                | Implicaciones prácticas y alineación con objetivos .....                                 | 101        |
| 4.5                | Conclusión general en respuesta a la hipótesis.....                                      | 102        |
| <b>Capítulo 5.</b> | <b>Conclusiones .....</b>  | <b>104</b> |
| 5.1                | Resumen general del estudio .....  | 104        |
| 5.2                | Conclusiones respecto a los objetivos del estudio .....                                  | 104        |
| 5.3                | Conclusión respecto a la hipótesis del estudio.....                                      | 106        |
| 5.4                | Implicaciones generales y contribuciones del estudio .....                               | 107        |
| 5.4.1              | Contribuciones prácticas: optimización de recursos y viabilidad comercial .....          | 107        |
| 5.4.2              | Contribuciones metodológicas.....  | 108        |
| 5.4.3              | Contribuciones científicas .....   | 108        |

|     |  |            |
|-----|--|------------|
| 5.5 | Reflexión final: la importancia de la capa física en la era del aprendizaje automático ..... | 109        |
| 5.6 | Limitaciones del estudio .....   | 110        |
| 5.7 | Recomendaciones para trabajos futuros.....   | 110        |
|     | <b>Literatura citada.....</b>  | <b>112</b> |
|     | <b>Anexos .....</b>  | <b>115</b> |

## Lista de figuras

| Figura   | Página |
|--|--------|
| Figura 1. Diagrama de la metodología empleada en este trabajo de tesis.....  | 8      |
| Figura 2. Diagrama de la generación de la base de datos.....   | 12     |
| Figura 3. Diagrama descriptivo de proceso de análisis de datos ante determinada frecuencia.<br>.....   | 12     |
| Figura 4. Circuito recorrido para el análisis de conducción dentro del Parque de Investigación e Innovación Tecnológica (PIIT); la flecha amarilla marca el inicio del recorrido. .... | 15     |
| Figura 5. Coordenadas UTM con las curvas identificadas del recorrido utilizado en las pruebas de estilo de conducción.....   | 15     |
| Figura 6. Dispositivo de captura de datos inerciales utilizados en las pruebas de estudio. ....  | 16     |
| Figura 7. Orientación de los ejes de los sensores inerciales utilizados, dentro del vehículo de prueba.....  | 17     |
| Figura 8. Gráfico de $ accX $ estimado GPS (verde) vs. IMU filtrada con Savitzky-Golay (magenta).....  | 21     |
| Figura 9. Aproximación de radio curva a partir de coordenadas UTM .....  | 22     |
| Figura 10. Comparación de señales de aceleración lateral capturadas y diezmadadas versus filtradas.....  | 27     |
| Figura 11. Distribución del valor de aceleración lateral Accel_1_X entre los grupos de estilos de manejo definidos (Agresivo, Cauteloso, Normal, Reconocimiento). ....                 | 34     |
| Figura 12. IAL promedio por estilo de manejo. ....   | 37     |
| Figura 13. IAL Promedio por Curva para Diferentes Estilos de manejo .....  | 39     |
| Figura 14. IAL promedio por piloto y estilo de manejo. ....  | 41     |
| Figura 15. Comparación de las gráficas de densidad de kernel del índice de aceleración Lateral máxima por estilo de manejo. ....   | 42     |
| Figura 16. Densidad de kernel del índice de aceleración Lateral máxima por estilo de manejo, Valor esperado (EV) y umbral de violacion (EV + STDev). ....                              | 43     |

|   |     |
|---|-----|
| Figura 17. Matriz de violaciones de umbral de riesgo por curva individual. El color rojo corresponde a un valor superior al umbral de riesgo, teniendo así, una violación. ....   | 45  |
| Figura 18. Visualización de Clases de Recorrido en Espacio PCA (3D) .....   | 48  |
| Figura 19. Mapa de calor de las cargas del Análisis de Componentes Principales para datos a 50 Hz. ....   | 50  |
| Figura 20. Análisis Comparativo por frecuencia de muestreo de la Visualización de Clases de Recorrido en Espacio PCA (3D). ....   | 53  |
| Figura 21. F1-Scores por modelo de clasificación para datos con características "Vaitkus-Inspired". ....  | 61  |
| Figura 22. F1-Scores por modelo de clasificación para datos con características "Zylius-OPTIM". ....  | 68  |
| Figura 23. Métricas de rendimiento (a) Accuracy CV, b) F1-Weighted CV, c) Test AUC para KNN y RF) y d) número de componentes PCA (95% varianza) en función de la frecuencia de muestreo para el Análisis #3.....  | 76  |
| Figura 24. Importancia de características (RF Gini) y curva ROC (Test Set) para el clasificador Random Forest a 10 Hz. ....   | 79  |
| Figura 25. Métricas de rendimiento (a) Accuracy CV, b) F1-Weighted CV, c) Test AUC para KNN y RF) y d) número de componentes PCA (95% varianza) en función de la frecuencia de muestreo para el Análisis #4.....  | 86  |
| Figura 26. Paisaje de Relevancia de Categorías de Características. Los valores representan la proporción de la importancia de Gini total que aporta cada categoría de características, normalizada por frecuencia. Este análisis se basa en los resultados del clasificador Random Forest sobre el "Conjunto Extendido". .... | 87  |
| Figura 27. Ejemplo de Curva ROC para RF usando datos muestreados a 10 Hz. El AUC de 0.972 indica un alto poder discriminatorio. ....  | 91  |
| Figura 28. Tabla de estudios completa .....   | 115 |

## Lista de tablas

| Tabla   | Página |
|---|--------|
| Tabla 1. Resumen de estudios previos. ....  | 3      |
| Tabla 2. Tabla de estadísticas por recorrido para la componente de aceleración lateral (Accel_1_X).....   | 35     |
| Tabla 3. Tabla de estadísticas por piloto. Valores estadísticos por piloto de base de datos original.....   | 35     |
| Tabla 4. IAL Promedio y Desviación Estándar por estilo de manejo en recorridos completos. ....  | 37     |
| Tabla 5. IAL promedio por curva y estilo de manejo seleccionado, con radio promedio de Curva. ....  | 38     |
| Tabla 6. IAL Promedio por Piloto (Codificado Numéricamente) y estilo de manejo. ....  | 40     |
| Tabla 7. Resumen de Estadísticas KDE y Violaciones por estilo de manejo.....  | 44     |
| Tabla 8. Varianza Explicada por PCA y ARI. ....   | 49     |
| Tabla 9. Rendimiento promedio de clasificación (KNN y RF) con características "Vaitkus-Inspired" en diversas particiones de datos (métricas promedio de validación cruzada de 5 pliegues). ....                   | 60     |
| Tabla 10. Rendimiento promedio de clasificación (KNN y RF) con características "Zylius-Inspired" (6 características) en diversas particiones de datos balanceadas (métricas promedio de validación cruzada). .... | 67     |
| Tabla 11. Resultados Comparativos por Frecuencia para Análisis #3 (Segmentos, 78 características Zylius-Inspired con SFFS).....   | 75     |
| Tabla 12. Resultados Comparativos por Frecuencia de Muestreo para el Análisis #4 .....  | 85     |
| Tabla 13. Resultados Comparativos por Frecuencia (características Extendidas) .....   | 89     |

## Capítulo 1. Introducción

---

La seguridad vial y la conducción eficiente son temas cruciales para la industria automotriz y las autoridades de tránsito. Su impacto en la salud pública y la economía es innegable: los accidentes viales no solo causan pérdidas humanas, sino que también generan costos económicos sustanciales (OMS, 2023). De hecho, el Banco Mundial estima que reducir a la mitad las fatalidades viales podría aumentar el PIB per cápita entre un 7% y un 22% en cinco años para algunos países (Banco Mundial, 2018). La urgencia de esta mejora se intensifica con el aumento de vehículos en circulación, impulsado por una industria logística global que se proyecta alcanzará los 14 billones de dólares para 2028 (Fernández, 2024), complejizando aún más la movilidad.

En este escenario, las Unidades de Medición Inercial (IMU) emergen como herramientas clave para monitorear el estilo de conducción. Estos dispositivos, que integran acelerómetros, giroscopios y a veces magnetómetros, capturan en tiempo real la aceleración, velocidad angular y orientación del vehículo (Ahmad et al., 2013). Su capacidad para generar datos en vivo permite detectar eventos críticos como frenazos bruscos, aceleraciones repentinas o patrones de manejo asociados a la fatiga y la distracción.

La Industria 4.0, con el Internet de las Cosas (IoT) y la Inteligencia Artificial (IA), ha potenciado el uso de las IMU para mejorar la seguridad y eficiencia vial (Siddiqui et al., 2024), lo que permite el desarrollo de sistemas de movilidad más inteligentes y seguros (Tewolde, 2012). Sin embargo, la adopción masiva de esta tecnología se enfrenta a una barrera económica: el alto costo de las IMU de alta precisión. Mientras que los sensores de bajo costo (presentes en la electrónica de consumo) valen apenas unos dólares, las unidades de grado táctico o de navegación pueden costar desde cientos hasta decenas de miles de dólares, dependiendo de su estabilidad y precisión. Esta brecha de precios limita las IMU de alta gama a aplicaciones críticas como la aeroespacial o la robótica avanzada.

Recientemente ha habido un creciente interés en el uso de IMUs de bajo costo para aplicaciones en la industria automotriz. Investigaciones recientes han demostrado que estos sensores, como los que se encuentran en smartphones y tabletas, pueden utilizarse para monitorear el comportamiento del conductor y detectar eventos de manejo (de Oliveira et al., 2022; Dong & Li, 2021). Estos estudios sugieren que, con el procesamiento adecuado de los datos y la aplicación de técnicas avanzadas de análisis, es posible obtener información valiosa sobre las condiciones de manejo y el comportamiento del conductor utilizando dispositivos de bajo costo ampliamente disponibles. Esta utilidad amplía significativamente las

oportunidades, abriendo la puerta a tecnologías avanzadas de seguridad vial y monitoreo de conductores, haciéndolas accesibles para una gama mucho más amplia de aplicaciones y usuarios. En este contexto, optimizar la recolección de datos y su preprocesamiento se convierte en un área de investigación abierta y de gran interés.

La implementación de sistemas de monitoreo basados en IMUs para determinar estilos de manejo no solo puede ayudar a mejorar la seguridad vial, sino que también contribuye significativamente a la sostenibilidad y eficiencia en el sector del transporte y movilidad. Al proporcionar datos precisos sobre el comportamiento del conductor, los sistemas de monitoreo avanzados permiten optimizar el consumo de combustible y reducir las emisiones de gases de efecto invernadero. Según la Agencia Internacional de Energía (IEA, 2021), las mejoras en la eficiencia de los vehículos y la adopción de prácticas de conducción eficiente son fundamentales para reducir las emisiones en el sector del transporte.

Esto se traduce en una disminución sustancial de la huella de carbono del sector transporte, que actualmente representa aproximadamente el 24% de las emisiones globales de CO<sub>2</sub> relacionadas con la energía (IEA, 2023). Además, al mejorar la eficiencia operativa y reducir el desgaste de los vehículos, estos sistemas contribuyen a la sostenibilidad económica de las empresas de transporte, movilidad y logística, así como a conductores privados.

## **1.1 Antecedentes**

El uso de IMUs para capturar información detallada sobre los movimientos del vehículo y el estilo de manejo ha sido explorado en diversos estudios. Investigaciones previas facilitan la identificación de patrones de comportamiento y la detección de eventos anómalos en tiempo real (Andria et al., 2016; Ferreira et al., 2017). Las funciones específicas de cada componente son descritas por (Woodman, 2007): Los acelerómetros miden la aceleración propia, que incluye tanto la aceleración debida al movimiento del vehículo como la componente de la aceleración gravitacional, los giroscopios miden velocidad angular y orientación, y los magnetómetros determinan la orientación absoluta respecto al campo magnético terrestre. Esta información es fundamental para inferir cambios en la velocidad y la orientación del vehículo.

La literatura ha demostrado que el uso de IMUs, en la detección de eventos y estilos de manejo, es una herramienta eficaz para mejorar la seguridad y eficiencia del transporte y movilidad. Estudios como el de

(Ferreira et al., 2017) investigaron el perfilado del comportamiento del conductor utilizando sensores de teléfonos inteligentes y técnicas de aprendizaje automático, demostrando la eficacia de estos sensores en la detección de eventos de manejo.

A menudo se combinan los sensores inerciales (IMU) con sistemas de posicionamiento (GPS) para el análisis del comportamiento de conducción. (Andria et al., 2016) desarrollaron una plataforma de adquisición de datos automotriz para el análisis del comportamiento de conducción, subrayando la importancia de los datos precisos. (Dettù et al., 2022) diseñaron y validaron un sistema de evaluación del estilo de manejo para tractores agrícolas, destacando la relevancia de las IMUs en aplicaciones diversas. (Chen et al., 2023) exploraron la selección de características para el agrupamiento de estilos de conducción utilizando datos naturalistas y cuestionarios.

**Tabla 1.** Resumen de estudios previos.

| Estudio           | Tipo de sensor  | Modelo Sensor | Rango Sensor | FREQ. Muestreo (Hz) |
|-------------------|-----------------|---------------|--------------|---------------------|
| Vaitkus (2014)    | Acc. 3 ejes     | No reportado  | No reportado | No reportado        |
| Zylius (2017)     | Acc. 3 ejes     | No reportado  | No reportado | 17 Hz               |
| Ferreira (2017)   | Android Cel IMU | No reportado  | No reportado | 50~100Hz            |
| Van Ly (2013)     | IMU CAN         | No reportado  | No reportado | No reportado        |
| Jachimczyk (2018) | Acc/GPS/OBD-II  | ADXL345       | ±4g          | 12.5Hz              |
| Chen (2023)       | IMU/GPS/CAM     | No reportado  | No reportado | 10 Hz               |

La revisión de la literatura (Bouhsissin et al., 2023) indica que los sensores inerciales y en particular los acelerómetros, constituyen una de las fuentes de datos más utilizadas para la clasificación del comportamiento del conductor. Las métricas frecuentemente empleadas para este fin incluyen la velocidad, la aceleración/desaceleración, los ángulos relativos o absolutos del vehículo y la tasa de rotación. En cuanto a las metodologías, técnicas de Machine Learning como K-means y redes neuronales son populares para identificar perfiles de conducción, mientras que Dynamic Time Warping (DTW) se utiliza a menudo para detectar patrones específicos de manejo (Bouhsissin et al., 2023; Tselentis & Papadimitriou, 2023).

Al examinar estudios previos, como los de (Chen et al., 2023), (Ferreira et al., 2017) y otros, se observa una variabilidad considerable en las frecuencias de captura empleadas. La Tabla 1, resume las características de una selección de estos trabajos. Se observa una variabilidad considerable en las frecuencias de captura empleadas, que típicamente oscilan entre 10 Hz y 100 Hz. Esta amplia dispersión en las frecuencias de muestreo es un factor crítico que merece mayor atención. La falta de estandarización es tan pronunciada que algunos estudios relevantes omiten reportar la frecuencia de muestreo utilizada, lo que dificulta severamente la reproducibilidad y la comparación de resultados.

Esta notable falta de estandarización en la frecuencia de adquisición sugiere una ausencia de consenso sobre la resolución temporal óptima o mínima requerida para capturar fielmente la dinámica relevante de los diferentes estilos de conducción. Una frecuencia demasiado baja podría omitir eventos transitorios cruciales (frenazos, giros bruscos), mientras que una frecuencia excesivamente alta podría preservar con mayor detalle componentes de ruido de alta frecuencia (ya sean inherentes al sensor, al entorno del vehículo o a vibraciones) que no son necesariamente relevantes para la caracterización del estilo de manejo. Esto, además de introducir redundancia computacional y aumentar innecesariamente los requisitos de almacenamiento y energía, podría no traducirse en una mejora proporcional en la precisión de la clasificación.

La elección de la frecuencia impacta directamente la naturaleza de la señal original sin procesar y en consecuencia, podría afectar la efectividad de las características extraídas y el rendimiento de los modelos de aprendizaje automático posteriores. Esta variabilidad, junto a la falta de estudios comparativos sistemáticos, crea una necesidad imperante de investigar el impacto específico de la frecuencia de muestreo. Por tanto, es fundamental determinar dos aspectos clave: el umbral de frecuencia mínimo por debajo del cual la clasificación se degrada significativamente, y el rango óptimo que equilibre la precisión con la eficiencia de los recursos.

Los sensores de bajo costo, como los integrados en dispositivos móviles (de Oliveira et al., 2022; Dong & Li, 2021), si bien ofrecen una alternativa económicamente viable a las unidades de alta precisión, presentan desafíos técnicos inherentes. Estos incluyen una menor precisión, un mayor nivel de ruido y una falta de estandarización en sus especificaciones de calidad (Bouhsissin et al., 2023). En (Welch et al., 1995) destacan la importancia de aplicar algoritmos de filtrado, como el filtro de Kalman para mitigar errores en datos. Por su parte, (Ojeda & Borenstein, 2007) mostraron la viabilidad de técnicas con IMUs de bajo costo con procesamiento avanzado sin utilizar GPS.

En este contexto, surge la necesidad de determinar las características mínimas para la detección efectiva de eventos de manejo, un área que la literatura previa no ha abordado sistemáticamente en cuanto al impacto de la frecuencia de muestreo del sensor en la clasificación del comportamiento del conductor.

## **1.2 Justificación**

La adopción masiva de sistemas de monitoreo de conducción se ve frenada por dos factores clave: el alto costo de las IMUs de precisión y la falta de un consenso metodológico sobre los parámetros operativos más efectivos para las alternativas de bajo costo. Este proyecto se justifica por la necesidad crítica de cerrar esta brecha y desarrollar alternativas económicas y eficientes para la detección de eventos de manejo, mediante el uso de IMUs de bajo costo, determinando sus características mínimas y óptimas, en particular la frecuencia de muestreo. La determinación de las características mínimas para estos sensores es fundamental, ya que permitirá crear alternativas accesibles y precisas que contribuyan significativamente a la seguridad vial y la optimización de la movilidad.

Esto facilita el acceso a tecnologías avanzadas de monitoreo, la identificación de patrones de conducción riesgosos para reducir accidentes, la optimización de la eficiencia de la movilidad, y el desarrollo de sistemas de asistencia al conductor económicamente viables. Proporcionar datos de manejo puede beneficiar a compañías de seguros y contribuir al desarrollo de sistemas de movilidad inteligente. Reducir los costos operativos para empresas de movilidad mediante mantenimiento predictivo más preciso es otra ventaja. Finalmente, fomenta la investigación y desarrollo en seguridad vial y tecnología automotriz, impulsando la innovación en el sector.

Al abordar estos aspectos, la investigación beneficiará no solo a las empresas de movilidad y a la industria automotriz, sino también a la sociedad en general, contribuyendo a un entorno de movilidad más seguro, eficiente y sostenible. Además, los resultados de este estudio podrían sentar las bases para futuras investigaciones en el campo de la detección de estilos de manejo y el desarrollo de tecnologías de asistencia al conductor más avanzadas y accesibles, específicamente en el contexto del impacto de la frecuencia de muestreo.

### **1.3 Planteamiento del problema**

A pesar del creciente interés en las IMUs de bajo costo para monitorear estilos de conducción, la revisión de literatura (Sección 1.1) revela una notable variabilidad y falta de consenso respecto a un parámetro fundamental: la frecuencia de muestreo. Esta ausencia de una guía clara sobre frecuencias operativas mínimas o recomendadas tiene implicaciones directas, ya que la frecuencia de muestreo afecta el contenido de información de la señal digitalizada y, consecuentemente, los procesos de extracción de características y la precisión en la clasificación de comportamientos de manejo (agresivo vs. no agresivo). Dicha carencia limita el diseño e implementación efectivos de sistemas de monitoreo accesibles y robustos, al no poder equilibrar óptimamente la fidelidad de la señal con la eficiencia computacional y energética.

Por lo tanto, este estudio plantea la siguiente pregunta de investigación: ¿Cuál es el impacto cuantificable de la frecuencia de muestreo en la capacidad para clasificar estilos de conducción utilizando IMUs de bajo costo, (como aquellos con un rango de medición de  $\pm 2g$  comúnmente encontrados en la electrónica de consumo), y cuáles son las frecuencias operativas mínimas y adecuadas para esta tarea?

### **1.4 Hipótesis**

Las señales de aceleración registradas con IMUs de bajo costo ( $\pm 2g$ ) a diferentes frecuencias de muestreo generan características con distinto poder discriminativo para clasificar estilos de conducción (agresivo vs no agresivo). Específicamente, se espera identificar un umbral mínimo y un rango de frecuencias que permitan la extracción de características robustas y fiables. La magnitud de este impacto se cuantificará observando las variaciones en el rendimiento de algoritmos de clasificación al utilizar características derivadas de datos muestreados a distintas frecuencias.

### **1.5 Objetivos**

#### **1.5.1 Objetivo general**

El objetivo general de este estudio es evaluar el impacto de la frecuencia de muestreo de las IMUs de bajo

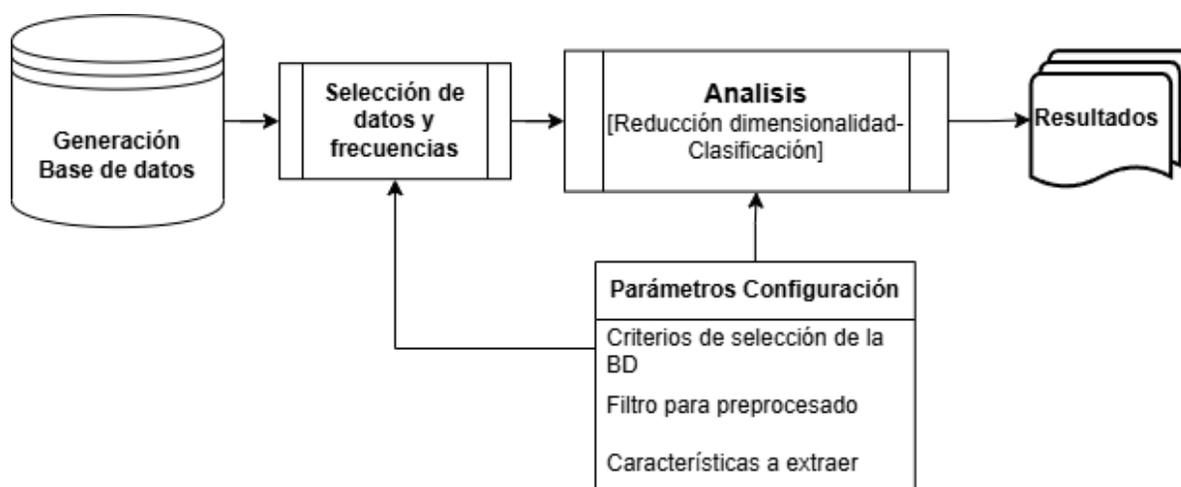
costo sobre la precisión de la clasificación del estilo de manejo, así como en el proceso de selección de características, diferenciando entre estilos agresivos y no agresivos, utilizando métodos de análisis de datos y técnicas de aprendizaje automático.

### 1.5.2 Objetivos específicos

- Evaluar y validar objetivamente la clasificación de estilos de manejo basada en la autoevaluación del conductor utilizando métricas de fuerza lateral resultantes de datos inerciales y GPS.
- Determinar el impacto de la frecuencia de muestreo en la clasificación del estilo de manejo con IMUs de bajo costo.
- Determinar el umbral mínimo de frecuencia de muestreo necesario y el rango de frecuencias de mayor efectividad para lograr una clasificación efectiva.
- Desarrollar una guía de recomendaciones preliminares para la selección y uso de IMUs de bajo costo en sistemas de detección de eventos y estilos de manejo, incluyendo características mínimas, rangos de operación recomendados y consideraciones de frecuencia de muestreo.

## Capítulo 2. Metodología

Esta investigación evalúa el impacto de la frecuencia de muestreo —un parámetro técnico clave y poco estudiado (ver Tabla 1)— en la precisión de la clasificación de estilos de conducción. Para ello, se diseñó un experimento controlado partiendo de datos adquiridos a 50 Hz en un circuito controlado. A partir de esta señal base, se simularon frecuencias de muestreo inferiores mediante un proceso de diezmado simple. Se optó por esta técnica para aislar el efecto de la densidad de puntos sobre una señal ya filtrada internamente por el sensor, aceptando un riesgo residual de aliasing para emular un escenario de consulta a baja frecuencia (ver justificación en Sección 2.4.1).



**Figura 1.** Diagrama de la metodología empleada en este trabajo de tesis.

La Figura 1 resume el flujo metodológico general, el análisis consistió en extraer características de los datos para cada frecuencia simulada. Posteriormente, se evaluó el desempeño desde dos perspectivas: 1) la precisión en la clasificación del estilo de manejo y 2) el número de características necesarias para alcanzar dicha precisión. Evaluar el rendimiento en cada frecuencia permitió determinar cómo este parámetro afecta la selección de características y la fiabilidad de la clasificación.

El desarrollo de un dispositivo de adquisición propio fue fundamental para el estudio. Este enfoque garantizó un control preciso sobre la frecuencia de muestreo y la consistencia entre experimentos, superando las limitaciones de transparencia y configurabilidad de dispositivos comerciales como los smartphones. Además, permitió seleccionar dos modelos de IMU específicos: el LSM6DS y el LSM9DS1, con el objetivo secundario de comparar su rendimiento.

El análisis comparativo reveló una similitud de rendimiento muy alta entre ambos sensores para esta aplicación. En consecuencia, y para favorecer la claridad de este trabajo, se decidió centrar la presentación de resultados en los datos del LSM6DS, considerándolo representativo. A lo largo de este documento, se utilizarán las etiquetas 'Accel1' para el sensor LSM6DS y 'Accel2' para el LSM9DS1, facilitando así la referencia en las discusiones comparativas. Esta estrategia no solo simplifica el análisis, sino que también mejora la comprensión de las características intrínsecas de esta clase de sensores.

La selección de estos modelos mejoró la reproducibilidad y el entendimiento de las características intrínsecas de los sensores. También, el diseño a medida facilitó la integración y, fundamentalmente, la sincronización precisa de estos múltiples sensores (Accel1, Accel2 y GPS) en paralelo bajo una referencia temporal común. Realizar nuestro propio dispositivo también permitió el montaje de las IMUs en una base física única, asegurando una alineación física conocida y consistente de sus ejes coordinados respecto al vehículo. Esto es un requisito indispensable para comparar mediciones de forma fiable y relacionarlas correctamente con la dinámica vehicular. Estas capacidades fueron esenciales para obtener datos con variables no controladas minimizadas y así realizar un análisis del impacto de los parámetros de adquisición.

Para llevar a cabo las fases de procesamiento, análisis y modelado de esta investigación, se utilizó un entorno computacional basado en el lenguaje de programación Python (versión 3.11.4). Las bibliotecas clave que facilitaron estos procesos, junto con sus versiones específicas para asegurar la reproducibilidad, incluyen: Pandas (2.2.3) para la gestión de datos; NumPy (1.26.4) para cálculo numérico; Matplotlib (3.10.3) y Seaborn (0.13.2) para visualización; SciPy (1.15.3) para cómputo científico y procesamiento de señales; Scikit-learn (1.6.1) para las tareas de aprendizaje automático; Statsmodels (0.14.4) para modelado estadístico; y Joblib (1.5.0) para optimización computacional. Los detalles de cómo se aplicaron estas herramientas se describirán en las secciones subsecuentes.

## **2.1 El problema de la clasificación**

Para abordar la clasificación de los estilos de conducción, se reconoció inicialmente la complejidad inherente a definir el "manejo agresivo". La literatura indica que, si bien existen umbrales técnicos que pueden sugerir agresividad tales como aceleraciones superiores a  $3 \text{ m/s}^2$  o frenadas bruscas mayores a  $4 \text{ m/s}^2$ , y fuerzas laterales superiores a 0.4G en giros a alta velocidad (Broughall, 2020). La conducción agresiva trasciende estos parámetros. Investigaciones de entidades como la NHTSA (National Highway

Traffic Safety Administration, 2024) señalan la correlación entre la velocidad excesiva y la gravedad de los accidentes, y estudios de (Davis & Aul, 2007) destacan el incremento del riesgo en intersecciones a velocidades elevadas (superiores a 64 km/h). Sin embargo, está documentado que la conducción agresiva es un fenómeno multidimensional, influenciado por factores psicosociales, culturales y contextuales que dificultan una definición matemática única y estandarizada (Poo et al., 2008).

De hecho, estudios como el de (Quintanilla & Rivera, 2017) evidencian cómo las actitudes, percepciones y emociones individuales influyen en la interpretación de una situación de conducción, lo que vuelve intrínsecamente subjetivos los enfoques basados únicamente en la percepción del conductor. Para abordar esto, se han desarrollado herramientas estandarizadas como el Driver Behaviour Questionnaire (DBQ) o perfiles de referencia (Chen et al., 2023; Parker et al., 1995; Reason et al., 1990), pero la naturaleza multifactorial persiste.

Ante esta naturaleza multifactorial y la dependencia de la interpretación individual, se optó por una estrategia metodológica mixta basada en la autoevaluación del estilo de manejo por parte de los participantes. Y un posterior análisis numérico de los resultados para explorar las relaciones objetivas entre ambos estilos de conducción. Esta aproximación se fundamentó en la premisa de que, dado que la agresividad al conducir es un fenómeno variable y dependiente de la historia personal, la comparación del comportamiento actual de un conductor con sus propios patrones históricos autodefinidos podría ofrecer una clasificación más adaptativa y precisa que los indicadores técnicos tradicionales o escalas estandarizadas (Dorantes Argandar, 2018).

### 2.1.1 Etiquetado del estilo de manejo

Tras una vuelta de "Reconocimiento" se solicitó a cada conductor que, para cada uno de los recorridos experimentales, manejara intencionadamente como "Normal", "Cauteloso" o "Agresivo" según su propio criterio. El objetivo de la investigación fue, por tanto, analizar los datos cinemáticos capturados por las IMUs para determinar si estas categorías auto informadas se correspondían con patrones estadísticos, permitiendo así capturar la complejidad y variabilidad inherentes al comportamiento humano en la conducción.

Esta aproximación metodológica, donde una categorización subjetiva inicial sirve de base para la posterior búsqueda y validación de correlatos objetivos cuantificables, es un desafío recurrente en la evaluación de

la interacción humano-vehículo. (Deubel et al., 2023) por ejemplo, en su revisión sobre la evaluación objetiva del confort de marcha, destacan un proceso similar donde la definición precisa del fenómeno subjetivo y los criterios de calificación son pasos fundamentales antes de establecer correlaciones matemáticas con datos físicos del vehículo.

### 2.1.2 Limitaciones de la estrategia de etiquetado

Si bien esta estrategia de autoevaluación ofrece ventajas significativas, como capturar la percepción e intención individual del conductor y permitir una clasificación potencialmente más adaptativa a su línea base personal que los umbrales técnicos fijos, es fundamental reconocer sus limitaciones inherentes. La principal limitación es la subjetividad, ya que la interpretación de 'Normal', 'No Agresivo' o 'Agresivo' puede variar entre individuos, incluso cuando se refieren a su propio comportamiento habitual. Además, pueden introducirse sesgos, como el de deseabilidad social (tendencia a reportar comportamientos más cautelosos o menos agresivos de lo que realmente fueron) o una falta de autoconciencia precisa sobre el propio estilo de manejo por parte del participante.

Es por ello por lo que se decidió seleccionar un orden de pruebas que resultara natural y contrastante para los participantes, primero se les solicitó familiarizarse con el recorrido sin ninguna pauta "Reconocimiento", posteriormente se les solicitó realizar las primeras tres vueltas manejando en modo "Normal" para posteriormente pedirles tres siendo sumamente "Cauteloso" siguiendo las normas de tránsito y finalmente tres siendo "Agresivo". Este flujo de instrucciones permite al mismo individuo contrastar sus comportamientos anteriores de manera que se espera permita homologar el desempeño de este a pesar de sus diferencias individuales.

No obstante, el propósito central de la investigación subsiguiente es precisamente evaluar si estas etiquetas auto informadas, a pesar de su naturaleza subjetiva, se correlacionan de manera consistente con patrones cinemáticos medibles. Se analizaron rigurosamente los datos capturados por las IMUs para determinar si estas categorías auto reportadas se relacionan estadísticamente entre los individuos, validando así la viabilidad de este enfoque pragmático para segmentar los datos. Para los análisis posteriores, estas etiquetas se agruparán principalmente en una clasificación binaria de 'Agresivo' vs. 'No Agresivo', utilizando diferentes esquemas que se detallan en la Sección 2.3.

La Figura 1 presenta el flujo metodológico general. Un componente clave de este flujo es la generación de la base de datos, cuyo proceso detallado se ilustra en la Figura 2. Allí se muestra cómo los datos, etiquetados mediante autoevaluación, son diezmados desde su frecuencia original de 50 Hz a una serie de frecuencias inferiores. Cada una de estas versiones frecuenciales es luego validada y clasificada mediante distintos métodos.

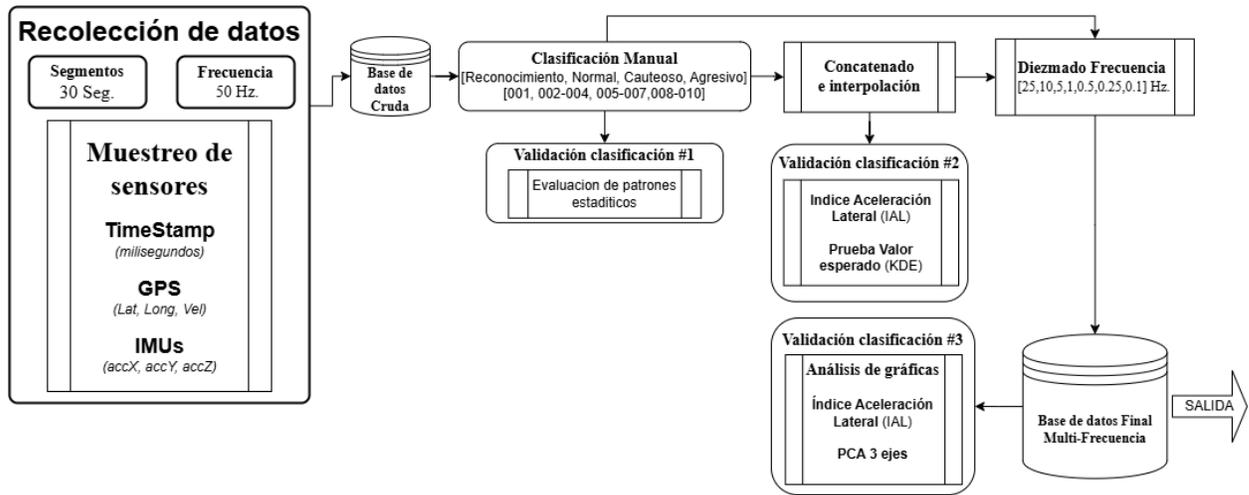


Figura 2. Diagrama de la generación de la base de datos.

Posteriormente, dentro del análisis que se desglosa en la Figura 3, se procedió al filtrado, extracción y selección de características relevantes, seguida del entrenamiento y evaluación rigurosa de modelos de clasificación, para finalmente analizar el impacto de la frecuencia en el rendimiento de la detección de estilos de conducción. Esto se realizó de igual manera para todos los análisis presentados en este trabajo.

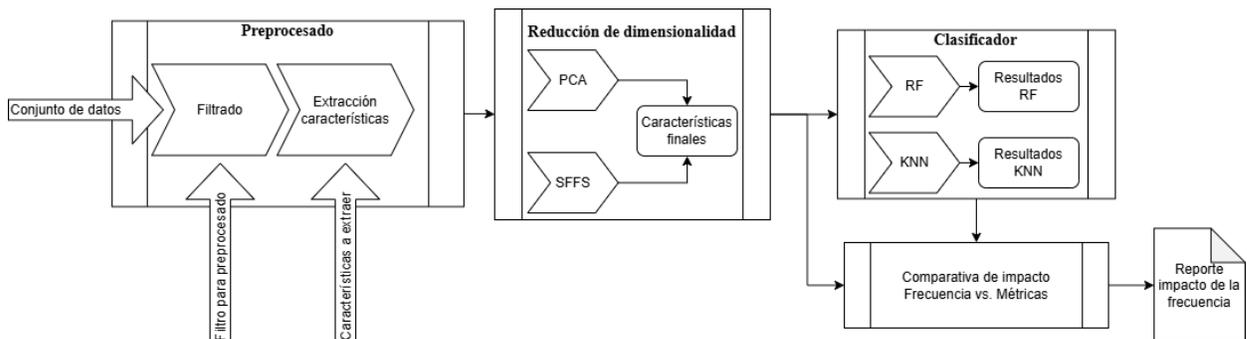


Figura 3. Diagrama descriptivo de proceso de análisis de datos ante determinada frecuencia.

## 2.2 Diseño experimental y adquisición de datos

Para la configuración de los acelerómetros integrados en las IMUs, la selección del rango de medición se basó en un análisis comparativo de las fuerzas G experimentadas en diversos escenarios vehiculares. Vehículos operando bajo condiciones de alto rendimiento, como los de Fórmula 1, pueden experimentar aceleraciones considerables: alrededor de 3-4g durante la aceleración, hasta 6g bajo frenado intenso, y entre 5 y 6.5g en curvas de alta velocidad (Balla, 2025). De manera aún más extrema, aeronaves de combate, como el F-16, pueden someter a sus pilotos a fuerzas de hasta 9g durante maniobras evasivas o de ataque (Pretorius, 2022).

En marcado contraste con estos escenarios de alta exigencia, las aceleraciones experimentadas por vehículos de pasajeros convencionales, que son el foco de este estudio, son significativamente menores. La literatura, como la presentada por (Gillespie, 2021), indica que las maniobras de conducción normal, tales como aceleraciones suaves o frenados moderados, generan aceleraciones que típicamente oscilan entre 0.1g y 0.3g, mientras que la aceleración lateral en giros comunes se mantiene entre 0.3g y 0.4g. Incluso bajo condiciones de conducción consideradas agresivas dentro de este contexto —por ejemplo, arranques rápidos desde un semáforo (que pueden alcanzar 0.5g - 0.6g) o frenados de emergencia (hasta 0.9g - 1g)— las aceleraciones rara vez exceden de forma sostenida 1g.

A modo de ilustración, se calculó que un giro brusco en una rotonda con un radio de 20 metros a una velocidad de 40 km/h (aproximadamente 11.1 m/s) induce una aceleración lateral de  $A_c = v^2/r = (11.11 \text{ m/s})^2/20 \text{ m} \approx 6.16 \text{ m/s}^2$ , lo que equivale a aproximadamente 0.63g (considerando  $g = 9.81 \text{ m/s}^2$ ).

Considerando esta disparidad entre los escenarios de alto desempeño y la conducción de vehículos de pasajeros, y que los eventos de interés en este último caso se encuentran predominantemente por debajo de 1g, se seleccionó y mantuvo fijo un rango de medición de  $\pm 2g$  a lo largo de todos los experimentos. Se concluyó que este rango resultaba suficiente para capturar la dinámica relevante de los estilos de manejo investigados, sin incurrir en la saturación del sensor. Adicionalmente, el uso de rangos superiores,  $\pm 4g$  u  $\pm 8g$ , no ofrecería ventajas significativas para esta aplicación específica.

Un rango mayor podría perjudicar la resolución efectiva de las mediciones, ya que, al distribuir el mismo número de bits del convertidor analógico-digital sobre un rango más amplio, la magnitud del paso de cuantización aumenta, lo que podría enmascarar diferencias sutiles en los patrones de aceleración, cruciales para distinguir estilos de manejo, especialmente los menos agresivos. Aunque este estudio no

varió experimentalmente el rango, la evidencia teórica y el éxito obtenido con  $\pm 2g$  proporcionaron una base sólida para esta elección. Al mantener constante el rango de medición y, por extensión, la resolución intrínseca del sensor para un número de bits determinado, se establecieron condiciones controladas que permitieron evaluar de forma específica el efecto de la frecuencia de muestreo sobre la señal digital.

La elección de un circuito cerrado y condiciones ambientales controladas fue una decisión metodológica fundamental para esta investigación. Este entorno permitió minimizar la influencia de variables exógenas y la variabilidad inherente a las mediciones inerciales y de posicionamiento, a diferencia de la conducción en entornos naturalistas. En estos últimos, una multiplicidad de factores no controlados (ruido, interferencias, respuestas a estímulos externos) puede generar artefactos cinemáticos que no son intrínsecos al estilo de manejo intencionado del participante.

Dicha contaminación de la señal comprometería la capacidad de atribuir inequívocamente las características de los datos IMU a los patrones de manejo específicos (Agresivo vs. No Agresivo) y, crucialmente, de evaluar de manera fiable el impacto aislado de la frecuencia de muestreo. Al operar en las instalaciones controladas del Parque de Investigación e Innovación Tecnológica (PIIT) —eliminando el tráfico externo y estandarizando la geometría del recorrido y las condiciones superficiales— se maximizó la integridad de la señal cinemática capturada.

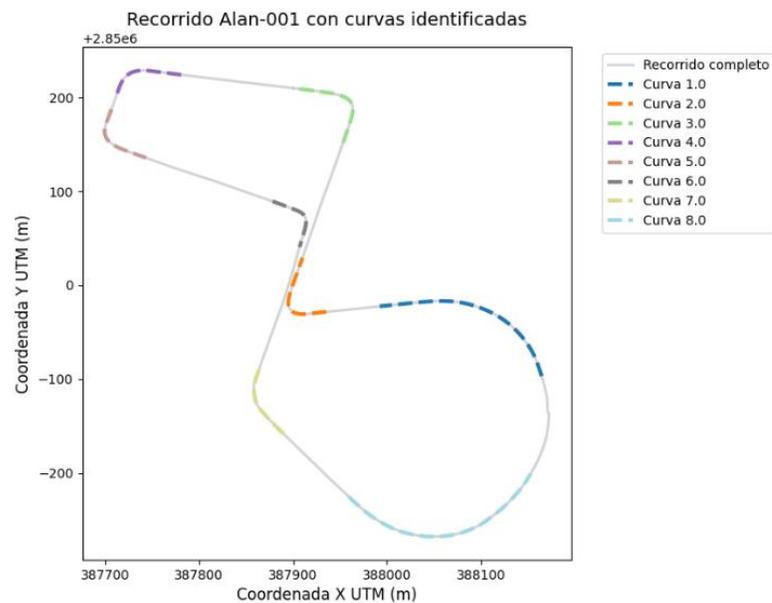
Esto aseguró que los datos reflejaran predominantemente las acciones del conductor al ejecutar los estilos instruidos, estableciendo una línea base de datos de alta fidelidad. Este riguroso control experimental fue, por lo tanto, esencial para un análisis preciso y robusto de cómo la reducción deliberada de la resolución temporal (mediante la variación de la frecuencia de muestreo) afecta la clasificación subsecuente.

Esta estandarización del entorno fue un pilar fundamental del diseño experimental, ya que permitió aislar de manera efectiva las variables de interés: el comportamiento intencional del conductor y el efecto de la frecuencia de muestreo. Al eliminar factores de confusión como la necesidad de reaccionar ante otros vehículos, peatones o cambios imprevistos en la señalización, se aseguró que las variaciones en los datos de aceleración y velocidad angular fueran atribuibles directamente a la ejecución de los estilos de conducción instruidos ("Normal", "Cauteloso" y "Agresivo"). Este nivel de control es difícil de alcanzar en estudios realizados en entornos naturalistas, donde la alta variabilidad del tráfico y las condiciones del camino pueden enmascarar las sutiles diferencias cinemáticas que definen cada estilo de manejo.



**Figura 4.** Circuito recorrido para el análisis de conducción dentro del Parque de Investigación e Innovación Tecnológica (PIIT); la flecha amarilla marca el inicio del recorrido.

El experimento se llevó a cabo en un circuito cerrado, ver Figura 4, definido dentro de las instalaciones del PIIT en Monterrey, Nuevo León, para controlar las condiciones de prueba (día seco, sin tráfico externo). El circuito tiene una longitud aproximada de 1.7 Km y consta de 8 curvas y secciones rectas. Dichas curvas, 5 a la izquierda y 3 a la derecha, cuentan con radios variados clasificados como amplio y pequeño (ver Figura 5).



**Figura 5.** Coordenadas UTM con las curvas identificadas del recorrido utilizado en las pruebas de estilo de conducción.

Participaron 6 conductores voluntarios con diversidad de género y rango de edad. Cada conductor realizó 10 recorridos en el circuito: 1 de familiarización "Reconocimiento", 3 bajo instrucción de conducción "Normal", 3 bajo instrucción de conducción "Cautelosa", y 3 bajo instrucción de conducción "Agresiva". El objetivo era capturar datos de manejo a velocidades entre 10 km/h y 60 km/h.

Es importante reconocer que el número de participantes (N=6) constituye una muestra relativamente pequeña. Si bien se buscó diversidad en género y rango de edad dentro de esta muestra, este tamaño es adecuado para los objetivos metodológicos de este estudio: evaluar el impacto de la frecuencia de muestreo y comparar clasificaciones dentro de un entorno experimental controlado.



**Figura 6.** Dispositivo de captura de datos inerciales utilizados en las pruebas de estudio.

El dispositivo captura de datos, con las IMUs (LSM6DS y LSM9DS1) montado dentro de un vehículo hatchback compacto modelo Honda "Fit Fun 2017" en una base impresa en 3D con soportes de goma en la consola central Figura 6. La orientación física de las IMUs dentro del vehículo fue cuidadosamente definida y mantenida constante: el Eje Y se alineó con la dirección longitudinal del vehículo (positivo hacia adelante), el Eje X con la dirección lateral, y el Eje Z con la dirección vertical (positivo hacia abajo incluyendo la componente de gravedad). Como se puede apreciar en la Figura 7, esta definición del sistema de coordenadas del sensor es fundamental y se mantuvo consistente para todas las mediciones inerciales registradas y analizadas en este trabajo.

Específicamente, la aceleración lateral ( $acc_X$ ), un parámetro clave utilizado posteriormente para el cálculo del Índice de Aceleración Lateral (IAL) y otros análisis, corresponde directamente a las mediciones a lo

largo de este Eje X físico definido, garantizando así que represente las fuerzas laterales experimentadas por el vehículo durante las maniobras. A su vez el GPS con antena externa se colocó en el centro del techo.



**Figura 7.** Orientación de los ejes de los sensores inerciales utilizados, dentro del vehículo de prueba

El dispositivo de captura se activó al inicio de cada recorrido. Los sensores fueron configurados para capturar datos a 50 Hz de manera continua en segmentos de 30 segundos, almacenados en una tarjeta microSD en formato CSV (Comma Separated Values) en una tarjeta microSD. Las variables registradas incluyeron *timestamp* (milisegundos), datos triaxiales de aceleración y velocidad angular para ambas IMUs latitud, longitud y velocidad del GPS. La base de datos final tiene una carpeta por piloto, que contiene subcarpetas por recorrido y cada una conteniendo archivos CSV por segmentos de 30 segundos (1500 muestras a 50 Hz).

### 2.3 Etiquetado de estilos de manejo y validación

Principalmente, se emplearán dos esquemas. El primero es un contraste balanceado, en el que la clase "No Agresivo" se define exclusivamente a partir de los recorridos "Cauteloso", y se compara directamente con la clase "Agresivo". El segundo es un contraste agrupado, donde la clase "No Agresivo" abarca los recorridos "Reconocimiento", "Normal" y "Cauteloso". Se indicará claramente qué esquema se utiliza en cada análisis. El etiquetado principal se realizó a nivel de recorrido completo, asociando cada conjunto de archivos CSV de un recorrido a uno de los estilos intencionados: "Reconocimiento", "Normal", "Cauteloso" y "Agresivo", acorde a las necesidades de los análisis.

Paralelamente, y con el fin de establecer un contexto de riesgo de derrape particularizado para la geometría de cada curva, se procedió a modelar cada una mediante un ajuste de círculo a sus correspondientes coordenadas GPS. Este ajuste se realizó empleando el método de mínimos cuadrados algebraicos, como se describe en la Ecuación (3) y se ilustra en la Figura 9. Dicho proceso permitió estimar el radio  $R$  característico de cada curva. A partir de este radio y la velocidad instantánea del vehículo ( $v$ , obtenida del sistema GPS) durante el tránsito por la curva, es posible calcular la aceleración centrípeta teórica  $a_c = v^2/R$  que el vehículo necesitaría para mantener dicha trayectoria. Se considera que, si esta aceleración centrípeta teórica  $a_c$  se aproxima o excede el umbral de  $0.8g$  el mismo valor de referencia utilizado en la normalización del Índice de Aceleración Lateral (IAL), existe un riesgo de derrape inherente a la maniobra bajo esas condiciones de velocidad y curvatura.

Utilizando las coordenadas GPS transformadas a UTM por medio de la librería de python "utm (versión 0.8.1)", se estimó la velocidad y aceleración lateral instantánea. Se calculó la IAL como la magnitud de la aceleración lateral, normalizada por el 80% de la aceleración de la gravedad ( $9.81 \text{ m/s}^2$ ), un umbral asociado al riesgo de derrape (Gillespie, 2021).

El propósito de este análisis de validación fue confirmar que la correspondencia entre la percepción subjetiva del conductor y las manifestaciones objetivas de su estilo de manejo era estadísticamente significativa. Para ello, se analizó el Índice de Aceleración Lateral (IAL), definido en la Ecuación (1) como la métrica cinemática principal. Adicionalmente, se empleó el ajuste de curvas, Ecuación (3), para comprender la geometría de la trayectoria, Sin embargo, para ir más allá de una simple comparación de umbrales y obtener una visión completa del comportamiento, se generaron Estimaciones de Densidad Kernel (KDE) de los valores de IAL.

Esta técnica permitió visualizar y comparar la distribución de probabilidad completa de las fuerzas laterales, creando una "huella dactilar" para cada estilo de conducción ("Agresivo" vs. "No Agresivo"). Una clara separación entre las curvas KDE de ambos grupos fue el criterio central para validar el etiquetado, demostrando de manera robusta que la percepción subjetiva se traduce en un perfil de manejo objetivamente diferente y justificando así el uso de estas etiquetas como base fiable para los modelos de clasificación. Los resultados detallados de esta validación, que demostraron dicha correspondencia, se presentarán en el Capítulo de Resultados.

El propósito de este análisis de validación fue determinar si los recorridos (y sus segmentos constitutivos) etiquetados como "Agresivos" por los conductores efectivamente exhibían comportamientos que

superaban con mayor frecuencia o magnitud ciertos umbrales cinemáticos (asociados al riesgo de derrape o a una conducción enérgica) en comparación con los recorridos etiquetados como "No Agresivos". Esta comparación buscaba confirmar la correspondencia entre la percepción subjetiva del conductor y las manifestaciones objetivas de su estilo de manejo. Los resultados detallados de esta validación, que demostraron dicha correspondencia, se presentarán en el Capítulo de Resultados.

$$IAL = \frac{|accX|}{0.8 g} \quad (1)$$

Para realizar este análisis de validación basado en el riesgo de derrape en curvas de manera contrastante además de utilizar los datos de las IMUs se comparan con una aproximación de aceleración basado en los datos del GPS. Fue necesario estimar la aceleración lateral experimentada por el vehículo utilizando únicamente los datos de posicionamiento y sus etiquetas de tiempo. El proceso comenzó con las coordenadas GPS (latitud, longitud) registradas durante cada recorrido. Estas coordenadas geográficas se transformaron primero al sistema de coordenadas UTM (Universal Transverse Mercator), utilizando la librería de Python 'utm 0.8.1', para obtener una representación bidimensional de la trayectoria del vehículo (X, Y) en un plano cartesiano, lo cual simplifica los cálculos cinemáticos.

### 1. Velocidad discreta

$$v_{x,i} = \frac{x_{i+1} - x_{i-1}}{2 \Delta t} \quad v_{y,i} = \frac{y_{i+1} - y_{i-1}}{2 \Delta t}$$

### 2. Aceleración discreta

$$a_{x,i} = \frac{v_{x,i+1} - v_{x,i-1}}{2 \Delta t} \quad a_{y,i} = \frac{v_{y,i+1} - v_{y,i-1}}{2 \Delta t} \quad (2)$$

### 3. Aceleración perpendicular (resultante)

$$a_{\perp,i} = a_i - (a_i \cdot T_i) T_i \quad \text{donde} \quad T_i = \frac{v_i}{||v_i||}$$

A partir de esta secuencia de posiciones UTM ( $X_i$ ,  $Y_i$ ) y sus correspondientes *timestamps* ( $t_i$ ), se estimó la velocidad instantánea del vehículo mediante derivación numérica. Subsecuentemente, se aplicó una segunda derivación numérica a las componentes de velocidad estimadas para obtener una estimación de la aceleración vectorial del vehículo en el plano UTM, Ecuación (2). Finalmente, para aislar la

componente de interés, se calculó la magnitud de la componente de esta aceleración estimada que actúa de forma perpendicular a la dirección de la velocidad instantánea estimada. Este valor resultante, que representa la aceleración lateral derivada exclusivamente de las coordenadas GPS/UTM, se contrastó contra los datos experimentales en un circuito controlado obtenidos desde las IMUs que se puede observar en la Figura 8.

**1. Medias y coordenadas centradas**

$$x_m = \frac{1}{n} \sum_{i=1}^n x_i \quad y_m = \frac{1}{n} \sum_{i=1}^n y_i \quad u_i = x_i - x_m \quad v_i = y_i - y_m$$

**2. Sumatorios Intermedios:**

$$S_{uu} = \sum_{i=1}^n u_i^2 \quad S_{vv} = \sum_{i=1}^n v_i^2 \quad S_{uv} = \sum_{i=1}^n u_i v_i$$

$$S_{uuu} = \sum_{i=1}^n u_i^3 \quad S_{vvv} = \sum_{i=1}^n v_i^3 \quad S_{uuv} = \sum_{i=1}^n u_i^2 v_i \quad S_{uvv} = \sum_{i=1}^n u_i v_i^2$$

**3. Sistema lineal para el centro desplazado:**

$$A = \begin{pmatrix} S_{uu} & S_{uv} \\ S_{uv} & S_{vv} \end{pmatrix} \quad B = \frac{1}{2} \begin{pmatrix} S_{uuu} + S_{uvv} \\ S_{vvv} + S_{uuv} \end{pmatrix} \quad (3)$$

Se resuelve

$$\begin{pmatrix} u_c \\ v_c \end{pmatrix} = A^{-1} B$$

$$x_c = x_m + u_c \quad y_c = y_m + v_c$$

**4. Radio medio**

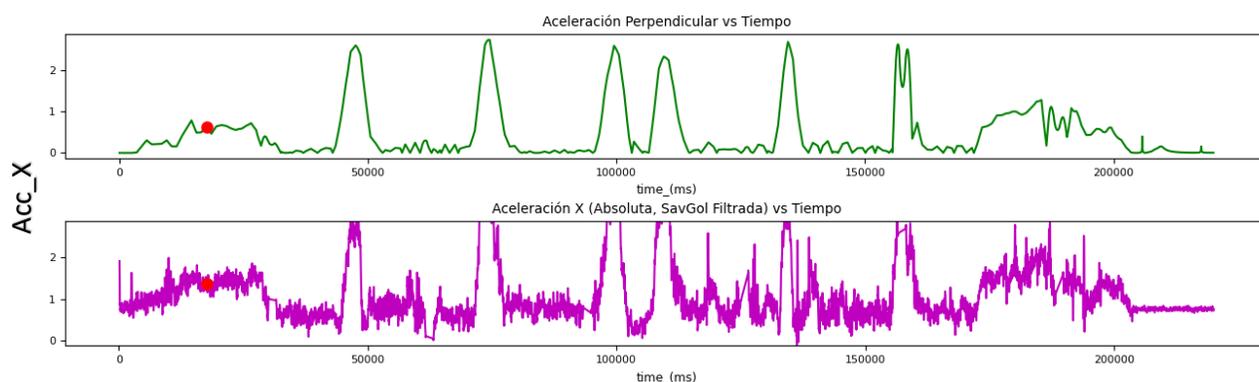
$$R = \frac{1}{n} \sum_{i=1}^n \sqrt{(x_i - x_c)^2 + (y_i - y_c)^2}$$

Se segmentaron los recorridos en 8 curvas independientes, identificadas mediante las coordenadas GPS de inicio y fin de cada una dentro del circuito experimental. Para cada una de estas curvas y en cada recorrido individual, se llevó a cabo un análisis detallado con el propósito fundamental de validar la consistencia entre las etiquetas de estilo de manejo autorreportadas por los conductores y el riesgo objetivo inferido a partir de los datos cinemáticos registrados.

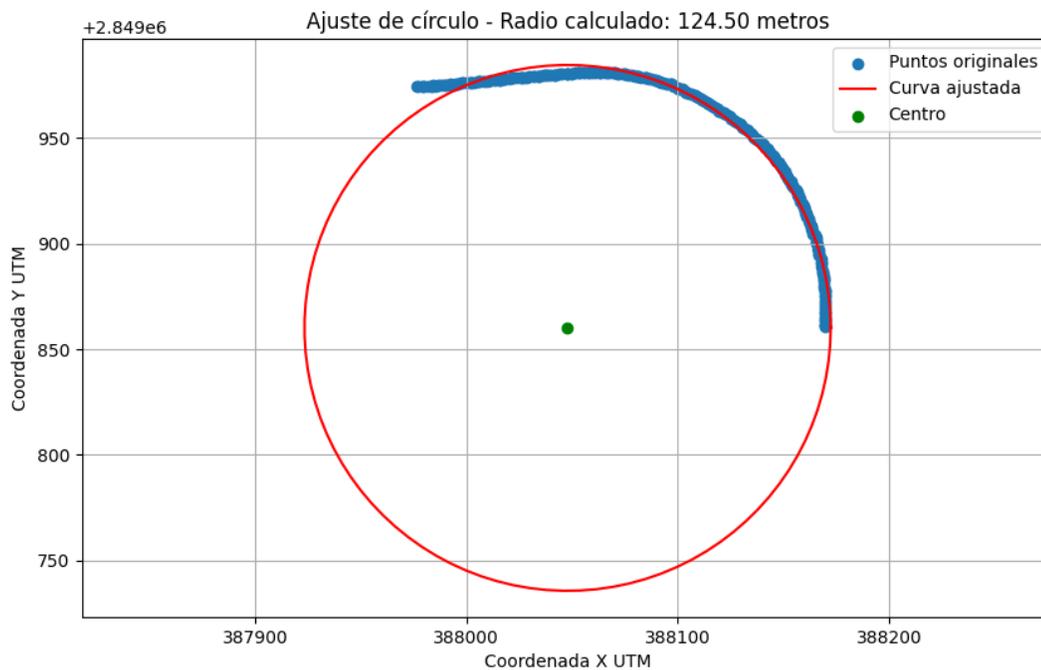
Este análisis se centró en el Índice de Aceleración Lateral (IAL), el cual se calcula según la Ecuación (1) utilizando la aceleración lateral experimentada por el vehículo (ya sea accX medida directamente por la IMU o la componente de aceleración lateral perpendicular estimada a partir de los datos GPS) normalizada por un umbral de 0.8g, asociado al inicio del riesgo de derrape. Para cada tránsito de curva en un recorrido específico, se determinó el valor promedio de IAL alcanzado.

El propósito de este análisis combinado fue doble, por un lado, cuantificar el comportamiento dinámico en curva donde se registraron los valores máximos de IAL efectivamente experimentados por el vehículo durante el paso por cada una de las 8 curvas, para cada tipo de recorrido instruido “Normal”, “Cauteloso”, “Agresivo”. Mientras por el otro validar la percepción subjetiva de agresividad donde se compararon estos IAL promedio experimentados con el umbral de riesgo de derrape de 0.8g. La hipótesis subyacente es que los recorridos etiquetados por los conductores como "Agresivos" exhibirían con mayor frecuencia y magnitud valores de IAL que se aproximasen o superasen dicho umbral, en contraste con los recorridos clasificados como "No Agresivos" (i.e., “Reconocimiento”, “Normales” o “Cautelosos”). Esta comparación permitiría verificar si los estilos de conducción más agresivos, según la autoevaluación, se traducen objetivamente en maniobras más cercanas al límite de adherencia del vehículo.

Además, como se mencionó se realizó un análisis estadístico preliminar usando media, desviación estándar, mínimo y máximo absolutos, de estos valores por piloto y por recorrido. Adicionalmente, se generó mediante una Estimación de Densidad por Kernel (KDE por sus siglas en inglés) una función de masa de probabilidad (PMF por sus siglas en inglés) para obtener el valor esperado, para establecer una métrica de riesgo o límite de agresividad independiente de la geometría de la curva. Los resultados se contrastaron visualmente con las etiquetas de autoevaluación para verificar la correlación entre la percepción del conductor y el riesgo objetivo medido. Este proceso de validación fue fundamental para confirmar que las etiquetas de autoevaluación, a pesar de su naturaleza subjetiva, tenían una correlación objetiva en el comportamiento cinemático, justificando su uso como variable dependiente en los modelos de clasificación posteriores.



**Figura 8.** Gráfico de  $|accX|$  estimado GPS (verde) vs. IMU filtrada con Savitzky-Golay (magenta).



**Figura 9.** Aproximación de radio curva a partir de coordenadas UTM

## 2.4 Preprocesamiento y ampliación de la base de datos

Para el preprocesamiento de las señales de aceleración, se exploraron diferentes enfoques de filtrado. Buscando replicar condiciones de estudios previos como (Jachimczyk et al., 2018), en las fases iniciales de análisis y para la generación del conjunto de características "Vaitkus-Inspired" y "Zylius-inspired" (Ver Sección 2.5) se aplicaron filtros pasa-bajos Butterworth de 4º orden en los ejes 'X' e 'Y' (frecuencia de corte de 0.8 Hz) y un filtro pasa-banda Butterworth en el eje 'Z' (0.1 Hz a 0.8 Hz) para mitigar vibraciones y efectos del terreno.

Sin embargo, para los análisis principales y de "Conjunto Extendido", se optó por utilizar un filtro Savitzky-Golay (SG) con una ventana temporal de 0.22 segundos y un orden polinomial de 2. Esta elección se fundamentó en la capacidad del filtro SG para suavizar las señales y mitigar el ruido de alta frecuencia preservando de manera más fidedigna la morfología y la dinámica de los transitorios presentes en la señal original (Savitzky & Golay, 1964), lo cual es crucial para la extracción de un conjunto amplio y detallado de características. El filtro SG se aplicó consistentemente después del proceso de diezmado a las diferentes frecuencias de muestreo simuladas. Esta decisión metodológica no convencional, justificada en detalle en

la Sección 2.5, busca emular una reducción en la tasa de consulta del sensor y aislar el efecto puro de la densidad de puntos sobre una señal ya preprocesada internamente.

$$\mathbf{Muestra\_diezmada}[k] = \mathbf{Muestra\_original}[k * (50/Fdeseada)] \quad (4)$$

Para evaluar el impacto de la frecuencia de muestreo, y preparar las bases de datos para la extracción de los distintos conjuntos de características que se detallarán en la Sección 2.5, se generaron bases de datos adicionales mediante submuestreo de la base de datos original de 50 Hz por diezmado simple utilizando la Ecuación (4). Se simularon las siguientes frecuencias de muestreo: 25 Hz, 10 Hz, 5 Hz, 1 Hz, 0.5 Hz, 0.25 Hz, y 0.1 Hz.

La elección de este método de diezmado simple, en lugar de la práctica estándar de aplicar un filtro anti-aliasing externo previo a cada etapa de submuestreo, se fundamenta en la arquitectura operativa de las IMUs digitales modernas empleadas en este estudio y en la naturaleza de la investigación.

A partir de la base de datos cruda adquirida a 50 Hz y procesada inicialmente (como se describe en las secciones anteriores), se generaron distintas estructuraciones o sub-bases de datos para abordar diferentes facetas del análisis de clasificación. Estas subbases de datos, antes de ser sometidas al diezmado a las frecuencias inferiores mencionadas, se organizaron de la siguiente manera:

- **Base de Datos por Recorrido Completo (DB\_Recorrido):** Cada instancia de datos representa un recorrido completo de un conductor, con una etiqueta de estilo de manejo “Agresivo” o “No Agresivo” asignada a todo el recorrido.
- **Base de Datos por Segmentos (DB\_Segmentos):** La base de datos se mantuvo organizada en los segmentos originales de 30 segundos. Cada segmento heredó la etiqueta de estilo de manejo del recorrido completo al que pertenecía. Esta aproximación permite un mayor número de instancias para el entrenamiento de modelos.
- **Base de Datos por Curvas (DB\_Curvas):** Se segmentaron los datos de cada recorrido en las 8 curvas identificadas en el circuito experimental (ver Sección 2.3). Cada instancia de curva heredó la etiqueta del recorrido.

Posteriormente, cada una de estas subbases de datos fue diezmada individualmente a las frecuencias de muestreo objetivo para evaluar el impacto de la frecuencia en los diferentes niveles de granularidad del análisis. La extracción de características y la clasificación se realizaron sobre estas múltiples versiones frecuenciales de cada subbase de datos.

Las unidades de medición inercial utilizadas (Accel1 y Accel2) son dispositivos digitales que ejecutan un sobre muestreo interno a elevadas frecuencias (e.g., hasta 6.7 kHz) e integran filtros digitales, incluyendo mecanismos *anti-aliasing* y filtros de paso bajo configurables, antes de que los datos procesados se almacenen en sus registros de salida. Consecuentemente, la señal de 50 Hz obtenida mediante la consulta ("*polling*") de estos registros representa una versión ya acondicionada y con limitación de banda del movimiento físico, donde la propia IMU ha realizado una etapa crítica de *anti-aliasing* con respecto a sus propias frecuencias de muestreo internas del orden de kHz.

#### 2.4.1 Justificación del método de submuestreo por diezmado simple

La decisión de utilizar diezmado simple, en lugar de la práctica estándar de aplicar un filtro anti-aliasing previo a cada submuestreo, es una elección metodológica deliberada. Se sustenta en tres principios clave diseñados para aislar con mayor precisión el efecto de la frecuencia de muestreo (o densidad de puntos) sobre la clasificación del estilo de manejo. A continuación, se detallan estos fundamentos:

**Emulación de Tasas de Consulta ("*Polling*") Reducidas:** El procedimiento de diezmar la señal original de 50 Hz —es decir, seleccionando cada  $N$ -ésima muestra para derivar una frecuencia de muestreo efectiva de  $50/N$  Hz— busca emular un escenario operativo en el cual la IMU es consultada directamente a dicha tasa inferior. En tal configuración, se confía en el acondicionamiento interno del sensor para proveer una muestra válida en cada instante de lectura. El efecto que se pretende aislar es, por lo tanto, el de la reducción de la densidad de puntos de una señal ya pre-procesada por el IMU.

**Foco en *Aliasing* Intra-Banda y Características del Fenómeno Estudiado:** Al diezmar una señal ya limitada en banda a 50 Hz, el principal riesgo de aliasing proviene de componentes frecuenciales dentro de la banda de 0-25 Hz que podrían plegarse a frecuencias más bajas. Dado que el fenómeno estudiado (estilos de conducción) se asocia predominantemente con maniobras de baja frecuencia, se considera que el impacto de este aliasing intra-banda, aunque teóricamente presente, forma parte de las distorsiones inherentes

que un sistema de baja frecuencia tendría que gestionar. El enfoque prioriza el análisis de este escenario realista sobre la pureza teórica de la señal.

**Aislamiento del Efecto de la Densidad de Puntos sobre una Señal Pre-Acondicionada:** Al omitir la introducción de un filtro *anti-aliasing* externo adicional previo al diezmado —cuyas características (e.g., orden, frecuencia de corte) se convertirían en variables de diseño adicionales dependientes de la frecuencia de muestreo objetivo y podrían interactuar con el efecto de interés—, la metodología se orienta a evaluar de manera más directa el impacto de la simple reducción en la cantidad de datos disponibles de una señal que la IMU ya ha acondicionado internamente.

Es importante reconocer que, a pesar de estas consideraciones, el diezmado simple, tal como se implementó, conlleva un riesgo residual de *aliasing*. Componentes de alta frecuencia que pudieran persistir en la señal de 50 Hz (ruido del sensor, vibraciones no completamente atenuadas por el hardware o el montaje) podrían teóricamente plegarse en la banda de interés al reducir significativamente la frecuencia de muestreo (especialmente por debajo de 5 Hz), distorsionando potencialmente las características espectrales o temporales extraídas. Esta posibilidad constituye una limitación inherente y reconocida de este enfoque metodológico simplificado, aceptada como un compromiso para lograr el objetivo primario de evaluar directamente el impacto de la densidad de muestreo sin la interferencia de filtros pre-diezmado variables.

Es importante reconocer que esta elección metodológica de diezmado simple difiere de la práctica estándar en el procesamiento de señales. La práctica habitual, para garantizar rigurosamente la prevención del aliasing, consiste en aplicar un filtro paso-bajo anti-aliasing antes del proceso de diezmado. Dicho filtro elimina o atenúa las componentes de frecuencia superiores a la mitad de la nueva frecuencia de muestreo (frecuencia de Nyquist), evitando que estas se "plieguen" (*fold back*) erróneamente en la banda de frecuencia de interés más baja.

Sin embargo, para los objetivos específicos de esta investigación, se optó intencionadamente por el diezmado simple por las siguientes razones:

1. **Aislamiento del Efecto de Interés:** El objetivo central era aislar y evaluar el efecto directo y puro de la reducción de la densidad de puntos (frecuencia de muestreo) sobre las características extraídas y el rendimiento subsiguiente de la clasificación. Aplicar un filtro anti-aliasing antes de diezmar introduciría un paso de procesamiento adicional cuyos efectos (principalmente, el

suavizado de la señal, con una intensidad que dependería de la frecuencia de corte elegida para cada nivel de diezmado) podrían confundirse o interactuar con el efecto que se buscaba aislar. Al aplicar el diezmado simple primero y un suavizado consistente (Savitzky-Golay con ventana temporal fija) después a todas las señales resultantes, se busca mantener una comparación más directa del impacto de la densidad de puntos en sí misma.

2. **Naturaleza de Baja Frecuencia del Fenómeno:** El fenómeno estudiado (estilos de manejo) se asocia predominantemente a movimientos y maniobras de baja frecuencia (giros, aceleraciones sostenidas, frenadas), como lo respalda la literatura (Gonzalez et al., 2014) y la propia naturaleza de la dinámica vehicular en conducción normal o incluso agresiva. Esto hace menos probable la presencia de componentes de alta frecuencia informativos y de gran amplitud que pudieran causar un *aliasing* severamente problemático, especialmente en las reducciones de frecuencia más moderadas (e.g., de 50 Hz a 25 Hz o 10 Hz).
3. **Filtrado Anti-Aliasing Implícito:** Es una característica inherente de muchas IMUs digitales modernas, como las utilizadas en este estudio (LSM6DS y LSM9DS1), que operan con altas frecuencias de muestreo internas (e.g., del orden de kHz) y aplican filtros digitales internos, incluyendo etapas de *anti-aliasing* con respecto a esas frecuencias internas. Esto resulta en que la señal de salida a la frecuencia seleccionada por el usuario (en este caso, 50 Hz) ya ha sido acondicionada y limitada en banda por el propio sensor. Junto con la adquisición inicial a 50 Hz, esto implica que la señal original ya posee una limitación de banda significativa, reduciendo el contenido energético a frecuencias muy altas que serían las más propensas a causar *aliasing* al diezmar.

A pesar de estas justificaciones, se reconoce explícitamente que el diezmado simple conlleva un riesgo residual de aliasing. Componentes de alta frecuencia que pudieran persistir en la señal de 50 Hz (ruido del sensor, vibraciones de alta frecuencia no completamente filtradas por el hardware o el montaje) podrían teóricamente plegarse en la banda de interés al reducir significativamente la frecuencia de muestreo (especialmente por debajo de 5 Hz), distorsionando potencialmente las características espectrales o temporales extraídas. Esta posibilidad constituye una limitación inherente y reconocida de este enfoque metodológico simplificado, aceptada como un compromiso necesario para lograr el objetivo primario de evaluar directamente el impacto de la densidad de muestreo sin la interferencia de filtros pre-diezrado variables.

Se priorizó preservar la estructura y densidad de puntos original relativa a cada nivel de frecuencia (evitando suavizados adicionales dependientes de la frecuencia) sobre la eliminación garantizada de todo posible *aliasing*. Una comparación futura con métodos que incluyan filtrado pre-diezrado podría cuantificar explícitamente el impacto (potencialmente menor) de este *aliasing* residual bajo el enfoque adoptado.

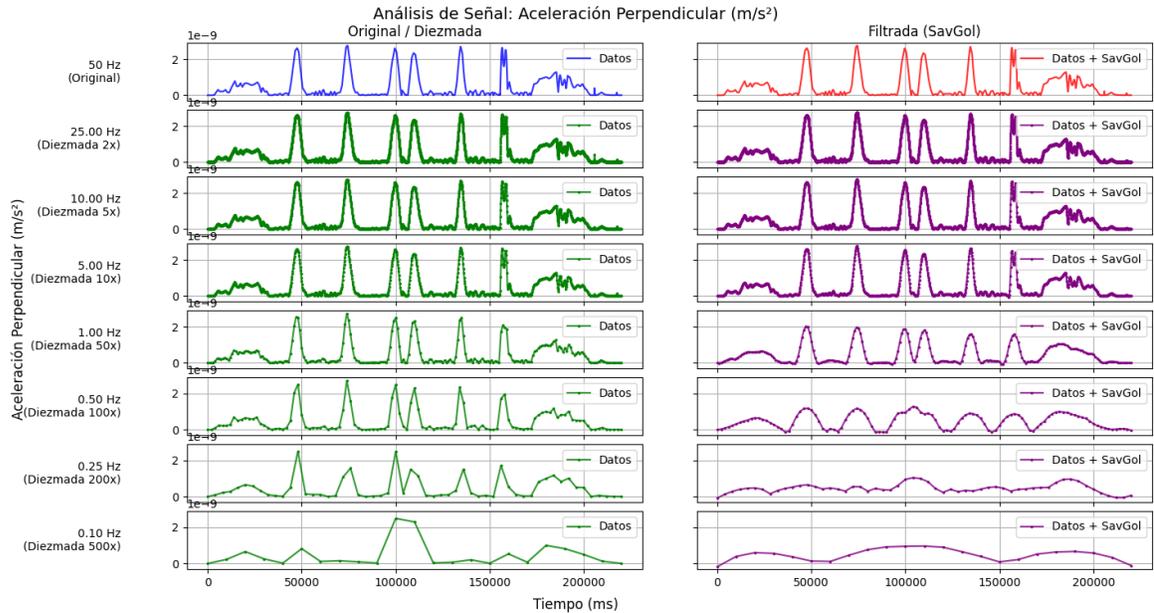


Figura 10. Comparación de señales de aceleración lateral capturadas y diezmadas versus filtradas.

## 2.5 Extracción y selección de características

A partir de los conjuntos de datos preprocesados y diezmados a diversas frecuencias, como se describió en la Sección 2.4, se procedió a la extracción de diferentes conjuntos de características de los datos de los acelerómetros, basándose en la revisión de la literatura, los cuales se definen a continuación. El efecto visual de este proceso de diezmado y el posterior filtrado se ilustra en la Figura 10, donde se compara la señal original con sus versiones a menor frecuencia.

- **Conjunto Vaitkus-Inspired (13 características por recorrido):** Inspirado en (Vaitkus et al., 2014), incluyendo estadísticas básicas (media, mediana, covarianza) y coeficientes de un polinomio de 5º orden ajustado a la inversa de la CDF (Función de Distribución Acumulada, por sus siglas en inglés) empírica de la señal. Este conjunto tiene como objetivo basarse estrechamente en el enfoque original y ampliarlo.

- **Conjunto Zylus-Inspired (78 características por recorrido):** Inspirado en (Zylus, 2017), cubriendo aspectos estadísticos (media, mediana, desviación estándar, cuantiles, asimetría, curtosis), temporales (DTV, Jerk) y frecuenciales (potencia espectral en bandas). Se adaptó la métrica DTV (Desviaciones del Umbral Típico) para no depender de una ruta o referencia externa. Para calcular el DTV en este código: primero, para cada piloto y frecuencia, se establecen umbrales de aceleración (mínimo y máximo por eje X, Y, Z) basados en sus trayectos etiquetados "Normal" por el conductor (previamente procesados). Luego, para cualquier segmento individual, se mide la proporción de sus puntos de datos (también procesados y por eje X, Y, Z) que caen fuera de estos umbrales de referencia específicos del piloto y frecuencia. Este conjunto representa una exploración más amplia de características.
- **Conjunto Zylus-OPTIM (6 características por recorrido):** Este conjunto consiste en un subconjunto de las 78 características del "Conjunto Zylus-Inspired". Específicamente, comprende las 6 características que (Zylus, 2017) reportó como las más relevantes o con mejor rendimiento en sus propios resultados. El objetivo es evaluar la eficacia de un conjunto altamente selectivo, identificado como óptimo en el estudio original.
- **Conjunto Extendido (aproximadamente 240 características por segmento):** Cubre dominios temporales, frecuenciales, de vector magnitud y de correlación inter-ejes, sobre segmentos de 30 segundos suavizados con Savitzky-Golay.

La estrategia de extracción de características se diseñó para evaluar el poder discriminatorio de distintos enfoques inspirados en la literatura, antes de analizar el impacto de la frecuencia de muestreo. Para ello, se definieron dos niveles de granularidad de análisis: por recorrido completo y por segmento.

Los conjuntos "Vaitkus-Inspired", "Zylus-Inspired" y "Zylus-OPTIM" se calculan a nivel de recorrido completo, donde cada viaje genera una única instancia de datos. Este enfoque permite una comparación directa entre estrategias exploratorias y amplias ("Inspired") y aquella altamente selectiva y optimizada en su estudio de referencia ("OPTIM"). En contraste, el "Conjunto Extendido" se calcula a nivel de segmento, donde cada tramo de 30 segundos de un recorrido es tratado como una instancia individual, heredando la etiqueta de estilo de manejo ("Agresivo" o "No Agresivo") del viaje completo. La principal ventaja de esta segmentación es que aumenta significativamente el número de muestras disponibles para el entrenamiento, lo cual es fundamental para construir modelos más robustos y mitigar el riesgo de sobreajuste, especialmente considerando el número limitado de recorridos totales.

Esta diferencia fundamental en la granularidad será un factor central en la comparación de resultados. El análisis no solo se centrará en el rendimiento de clasificación de cada enfoque, sino que también evaluará las implicaciones de su respectiva unidad de análisis y la ventaja que supone una mayor cantidad de muestras para discriminar eficazmente los estilos de manejo.

Para reducir la dimensionalidad y seleccionar las características más discriminativas, se utilizaron:

- **Análisis de Componentes Principales (PCA):** Aplicado a las características escaladas para estimar la dimensionalidad intrínseca de los datos y visualizar la separabilidad de clases.
- **Sequential Forward Feature Selection (SFFS):** Utilizado para seleccionar automáticamente un subconjunto óptimo de características basado en el rendimiento de un clasificador base (KNN) mediante validación cruzada.

## 2.6 Modelos de clasificación y evaluación

Es importante recordar que el objetivo de este trabajo no es encontrar el mejor algoritmo para la clasificación del estilo de manejo, sino evaluar el impacto de la frecuencia en la clasificación. Por lo tanto, para la evaluación se consideraron dos algoritmos de aprendizaje automático comúnmente utilizados para la clasificación de estilos de manejo, seleccionados por su robustez y simplicidad (Bouhsissin et al., 2023; Vaitkus et al., 2014; Zylius, 2017):

- **K-Nearest Neighbors (KNN):** Es un algoritmo basado en instancias que clasifica un nuevo punto de datos según la clase mayoritaria de sus 'k' vecinos más cercanos en el espacio de características. La simplicidad de su principio lo hace altamente intuitivo, pero su eficacia depende de la métrica de distancia utilizada y de una adecuada elección del hiperparámetro 'k'. En este estudio, se implementó con k=5 vecinos.
- **Random Forest (RF):** Es un método de aprendizaje de conjunto (ensemble) que opera construyendo múltiples árboles de decisión durante el entrenamiento. La clasificación final se determina por el voto mayoritario de los árboles individuales. Al introducir aleatoriedad tanto en el muestreo de los datos para cada árbol como en la selección de características en cada nodo, Random Forest mitiga eficazmente el sobreajuste y mejora la capacidad de generalización en

comparación con un único árbol de decisión. Para este trabajo, se implementó con 100 estimadores y una profundidad máxima ilimitada (`max_depth=None`).

Para una descripción detallada de los fundamentos teóricos y la implementación práctica de ambos algoritmos, K-Nearest Neighbors y Random Forest, se puede consultar la obra de referencia (Géron, 2022). La elección de estos modelos se fundamenta en su probada eficacia y simplicidad, lo que permite establecer una base de comparación sólida para el objetivo central de este estudio: evaluar el impacto de la frecuencia de muestreo.

La evaluación del rendimiento de los modelos se realizó utilizando:

- **Validación Cruzada Repetida Estratificada (*Repeated Stratified K-Fold*):** para obtener estimaciones robustas de *exactitud* (*accuracy* o *Acc*) y F1-score ponderado (F1w).
- **División Train/Test:** Una única división estratificada (70% entrenamiento, 30% test) para evaluar el rendimiento final en datos no vistos (*Accuracy*, F1-Weighted, Área Bajo la Curva ROC (AUC)).
- **Prueba T pareada:** para comparar estadísticamente los *scores* de *Accuracy* y F1w obtenidos en las estratificaciones (*folds*) de la validación cruzada repetida, comparando KNN vs RF para cada frecuencia, y Accel1 vs Accel2 para cada clasificador y frecuencia. Se utilizó un nivel de significancia  $\alpha = 0.05$ .

Si bien la validación cruzada estratificada y el F1-score ponderado ayudan a identificar el efecto del desbalanceo de clases, se tuvo en consideración la posibilidad de emplear técnicas adicionales como el ajuste de pesos de clase (e.g., `class_weight='balanced'`) en los modelos si el desbalanceo resultara ser un factor limitante significativo en la interpretación de los resultados.

En síntesis, la adquisición de datos experimentales en un circuito controlado, complementada por una estrategia de etiquetado autoevaluado y validado objetivamente con métricas cinemáticas, sentó las bases para el estudio de los efectos de las frecuencias de muestreo sobre la clasificación del estilo de manejo. La aplicación subsiguiente y consistente de técnicas de preprocesamiento, la extracción de características inspiradas en trabajos previos (Vaitkus et al., 2014; Zylius, 2017), y el empleo de modelos de clasificación robustos, como KNN y Random Forest —ampliamente aceptados en el análisis del comportamiento del conductor (Bouhsissin et al., 2023; Ferreira et al., 2017)— a través de cada condición de frecuencia, se

orientó a garantizar la fiabilidad de los análisis comparativos. De este modo, el diseño experimental integral, al articular componentes metodológicos validados para la investigación específica del impacto de la frecuencia de muestreo, proporciona una plataforma robusta para la obtención e interpretación de los resultados, sentando además un precedente para futuros estudios sobre las características mínimas requeridas en las IMUs.

## Capítulo 3. Resultados

---

Este capítulo se estructura en dos partes fundamentales para presentar los hallazgos de manera lógica y progresiva.

En la primera parte (Secciones 3.1 a 3.4), se establece la validez de los datos y la estrategia de etiquetado. Mediante análisis estadísticos y cinemáticos detallados, como el Índice de Aceleración Lateral (IAL) y la KDE, se demuestra que las etiquetas de autoevaluación del conductor (ej. "Agresivo", "Cauteloso") se correlacionan de manera robusta con métricas objetivas. Este paso es crucial, pues consolida dichas etiquetas como *una referencia fiable* para los análisis de clasificación posteriores.

La segunda parte (Sección 3.5) constituye el núcleo de la investigación y se dedica a la evaluación computacional del impacto de la frecuencia de muestreo. Se presentan los resultados de cuatro análisis de clasificación, cada uno diseñado para explorar una faceta específica del problema:

- **Análisis #1 y #2:** Validan la eficacia de conjuntos de características inspirados en la literatura (Vaitkus-inspired y Zylius-OPTIM), estableciendo una línea base de rendimiento y demostrando la viabilidad de la clasificación con los datos recopilados.
- **Análisis #3:** Investiga el impacto de la frecuencia sobre un conjunto completo de 78 características, introduciendo una selección adaptativa (SFFS) para determinar qué descriptores son más informativos en cada nivel de resolución temporal.
- **Análisis #4:** Expande esta investigación al conjunto de características más extenso (~240 descriptores) para determinar si una mayor riqueza de información mejora aún más la clasificación y si modifica el rango de frecuencia óptimo identificado.

Es importante notar que se emplean dos definiciones de la clase "No Agresivo". Los análisis iniciales (#1 y #2) utilizan una definición balanceada ("Cauteloso" vs. "Agresivo") para establecer una línea base de rendimiento. Posteriormente, para los análisis de frecuencia más exhaustivos (#3 y #4), se adopta una definición más amplia que agrupa todos los recorridos "No Agresivos", con el fin de maximizar el tamaño de la muestra y evaluar la robustez del modelo en condiciones más realistas, aunque esto introduzca un desbalance de clases. Esta decisión y sus implicaciones se discuten en las secciones correspondientes.

### 3.1 Validación del etiquetado de estilos de manejo y análisis preliminar de datos

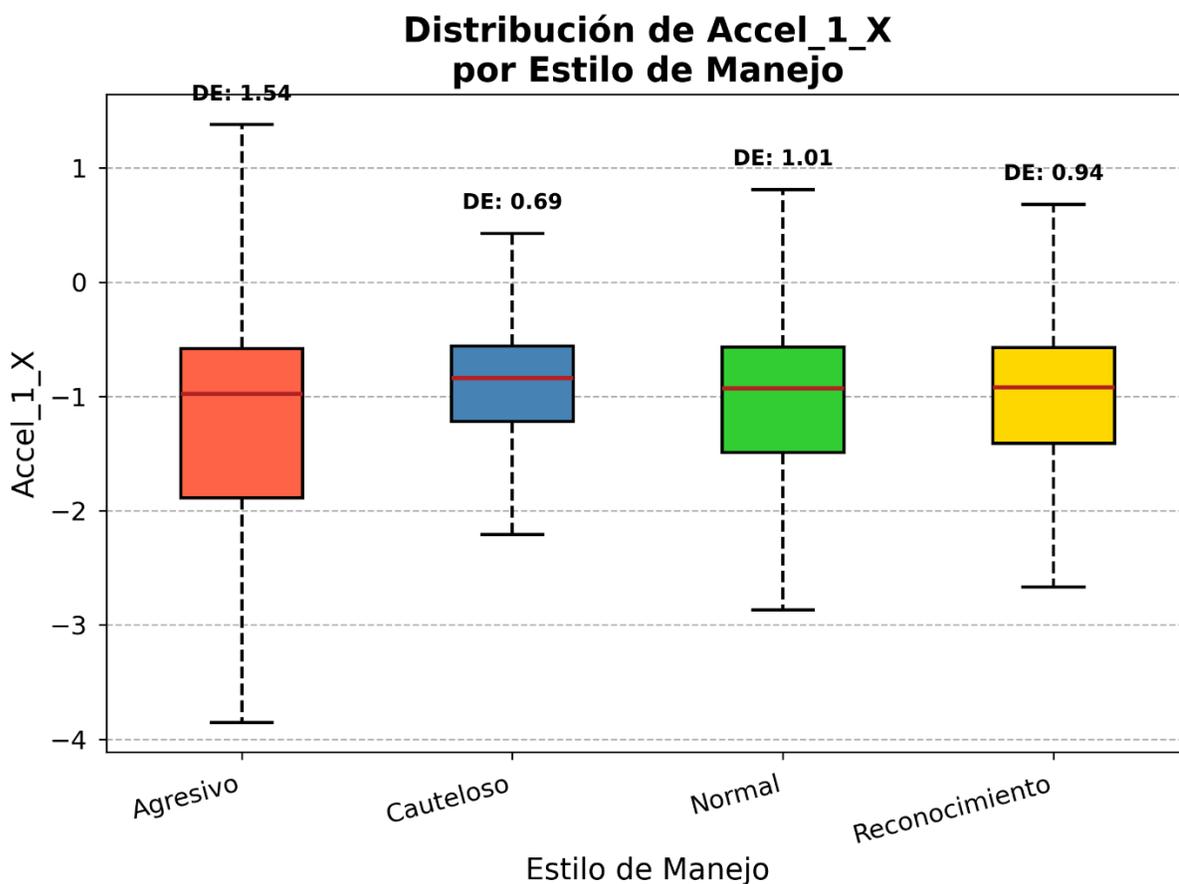
Esta sección presentará los resultados que validan la consistencia entre el etiquetado auto reportado (autoevaluación del conductor: "Reconocimiento", "Normal", "Cauteloso", "Agresivo") y las métricas cinemáticas objetivas.

#### 3.1.1 Análisis estadístico de aceleraciones

Como paso inicial para comprender las características intrínsecas de los datos recolectados y comenzar a validar la segmentación de estilos de manejo auto informados, se realizó un análisis estadístico sobre las señales de aceleración. Específicamente, se examinaron las estadísticas descriptivas de la componente de aceleración lateral (Accel\_1\_X, proveniente del sensor Accel1) para cada uno de los 60 recorridos (10 por cada uno de los 6 pilotos). Los resultados se encuentran resumidos en la Tabla 2.

Una observación destacada de este análisis se centra en la dispersión de los datos, particularmente la desviación estándar de Accel\_1\_X. Se encontró que los recorridos etiquetados por los conductores como "Agresivo" (recorridos 008-010) exhibieron consistentemente una mayor desviación estándar, promediando aproximadamente  $1.5 \text{ m/s}^2$ . En contraste, los recorridos catalogados como "Cauteloso" (recorridos 005-007) mostraron una dispersión significativamente menor, con una desviación estándar promedio cercana a  $0.7 \text{ m/s}^2$ . Los recorridos "Normal" (002-004) y el de "Reconocimiento" (001) se situaron en un punto intermedio, con desviaciones estándar alrededor de  $1.0 \text{ m/s}^2$ . Ver Figura 11.

Esta disparidad en la desviación estándar no es meramente una diferencia numérica, sino que refleja directamente la física de las maniobras realizadas. Un valor más alto en los recorridos "Agresivos" sugiere un patrón de conducción con maniobras de mayor brusquedad y frecuencia, como giros cerrados a mayor velocidad o correcciones de trayectoria más repentinas, que generan picos de aceleración lateral más variados y de mayor magnitud. Por el contrario, la menor dispersión en el estilo "Cauteloso" es consistente con una conducción más suave y predecible, donde las transiciones en curva se realizan de manera más progresiva. Este hallazgo es de suma importancia, ya que proporciona una validación cuantitativa inicial y fundamental: las etiquetas subjetivas de autoevaluación de los pilotos no son arbitrarias, sino que se correlacionan de manera medible con el comportamiento cinemático del vehículo.



**Figura 11.** Distribución del valor de aceleración lateral Accel\_1\_X entre los grupos de estilos de manejo definidos (Agresivo, Cauteloso, Normal, Reconocimiento).

Esta diferencia en la variabilidad de la aceleración lateral sugiere que los estilos de manejo auto informados, especialmente en los extremos de "Agresivo" y "No Agresivo", podrían manifestarse a través de distintos patrones de dispersión en las aceleraciones. Una mayor desviación estándar en los recorridos "Agresivos" podría indicar maniobras más "agresivas" (e.g., giros más bruscos, correcciones más frecuentes o de mayor amplitud), mientras que una menor dispersión en los recorridos "No Agresivos" podría reflejar una conducción más suave y contenida. Aunque este es un análisis inicial, proporciona un primer indicio de que las etiquetas subjetivas de los conductores tienen un correlato objetivo en las características estadísticas de los datos de las IMUs, lo cual se explorará con mayor profundidad en las siguientes secciones de validación.

Para una visualización más clara de estas diferencias en la dispersión, la Figura 11 presenta diagramas de caja comparando las distribuciones de los valores de aceleración lateral entre los grupos de estilos de manejo definidos. Estas diferencias se resumen en la Tabla 2 y se visualizan en la Figura 11, mientras que

la Tabla 3 presenta las estadísticas descriptivas agregadas por piloto, ofreciendo una visión de la variabilidad individual basal.

**Tabla 2.** Tabla de estadísticas por recorrido para la componente de aceleración lateral (Accel\_1\_X).

| Tipo de conducción | Recorrido | Media   | Mediana | Mínimo | Máximo | Rango | Varianza | Desv. Estándar |
|--------------------|-----------|---------|---------|--------|--------|-------|----------|----------------|
| “Reconocimiento”   | 001       | -0.9880 | -0.92   | -15.88 | 13.73  | 29.61 | 0.8743   | 0.935          |
| “Normal”           | 002       | -1.0119 | -0.92   | -15.61 | 6.46   | 22.07 | 1.0322   | 1.016          |
| “Normal”           | 003       | -1.0201 | -0.93   | -19.60 | 10.44  | 30.04 | 0.9961   | 0.9981         |
| “Normal”           | 004       | -1.0330 | -0.95   | -11.77 | 10.53  | 22.30 | 1.051    | 1.0252         |
| “Cauteloso”        | 005       | -0.8914 | -0.84   | -12.25 | 7.54   | 19.79 | 0.4766   | 0.6904         |
| “Cauteloso”        | 006       | -0.9006 | -0.84   | -12.66 | 10.92  | 23.58 | 0.4652   | 0.682          |
| “Cauteloso”        | 007       | -0.9065 | -0.85   | -6.00  | 14.88  | 20.88 | 0.4961   | 0.7043         |
| “Agresivo”         | 008       | -1.1711 | -0.96   | -19.60 | 19.52  | 39.12 | 2.2027   | 1.4841         |
| “Agresivo”         | 009       | -1.2079 | -1.00   | -15.12 | 19.34  | 34.46 | 2.4787   | 1.5744         |
| “Agresivo”         | 010       | -1.2151 | -0.99   | -11.9  | 19.59  | 31.49 | 2.4087   | 1.5520         |

**Tabla 3.** Tabla de estadísticas por piloto. Valores estadísticos por piloto de base de datos original.

| Piloto | Media   | Mediana | Mínimo | Máximo | Rango | Varianza | Desv. Estándar |
|--------|---------|---------|--------|--------|-------|----------|----------------|
| 1      | -0.9639 | -0.84   | -12.78 | 19.59  | 32.37 | 1.2700   | 1.1270         |
| 2      | -0.9984 | -0.90   | -19.6  | 19.52  | 39.12 | 1.0118   | 1.0059         |
| 3      | -1.0133 | -0.89   | -15.88 | 10.44  | 26.32 | 1.3543   | 1.1637         |
| 4      | -1.053  | -0.94   | -19.6  | 19.34  | 38.94 | 1.1677   | 1.0806         |
| 5      | -1.0058 | -0.91   | -10.31 | 13.73  | 24.04 | 1.0665   | 1.0327         |
| 6      | -1.056  | -0.95   | -14.38 | 10.53  | 24.91 | 0.9388   | 0.9689         |

### 3.1.2 Validación del etiquetado mediante métrica de riesgo en curvas (IAL y KDE)

Para complementar la evaluación mediante patrones estadísticos, esta sección introduce y valida métricas de riesgo específicas para la conducción en curvas. El objetivo es cuantificar cómo los diferentes estilos de conducción y las características de las curvas influyen en la proximidad a los límites de adherencia del vehículo. Primero, se examinará en detalle el Índice de Aceleración Lateral (IAL), una medida normalizada de la utilización del agarre lateral, analizando su comportamiento en función del estilo de manejo, las

particularidades de cada curva y las diferencias individuales entre pilotos. Posteriormente, se explorará el uso de la Estimación de Densidad Kernel (KDE) aplicada a los datos de aceleración lateral para identificar patrones y zonas de mayor concentración de esfuerzo dinámico, ofreciendo una perspectiva complementaria sobre el riesgo asociado a cada maniobra.

### 3.1.2.1 Impacto del estilo de manejo en el IAL

En esta sección se presentan los resultados obtenidos del análisis del Índice de Aceleración Lateral (IAL). El IAL, definido en la Ecuación (5) como la relación entre la aceleración lateral promedio medida (proveniente del sensor Accel1) durante el paso por curva y la aceleración lateral máxima teórica (calculada con  $\mu=0.8$  y  $g=9.81 \text{ m/s}^2$ ), sirve como un indicador normalizado de la utilización del agarre disponible del vehículo.

$$IAL_{\text{curva}} = \frac{\frac{1}{N} \sum_{i=t_{\text{inicio}}}^{t_{\text{fin}}} a_{\text{lat}}(i)}{\mu \cdot g}$$

$$\begin{aligned} IAL_{\text{curva}} &= \text{Relación medida/teórica.} \\ a_{\text{lat}}(i) &= \text{Aceleración lateral en el instante } (i) \\ \mu &= \text{Coeficiente de fricción lateral (0.8).} \\ g &= \text{Aceleración gravitacional (9.81 m/s}^2\text{).} \end{aligned} \quad (5)$$

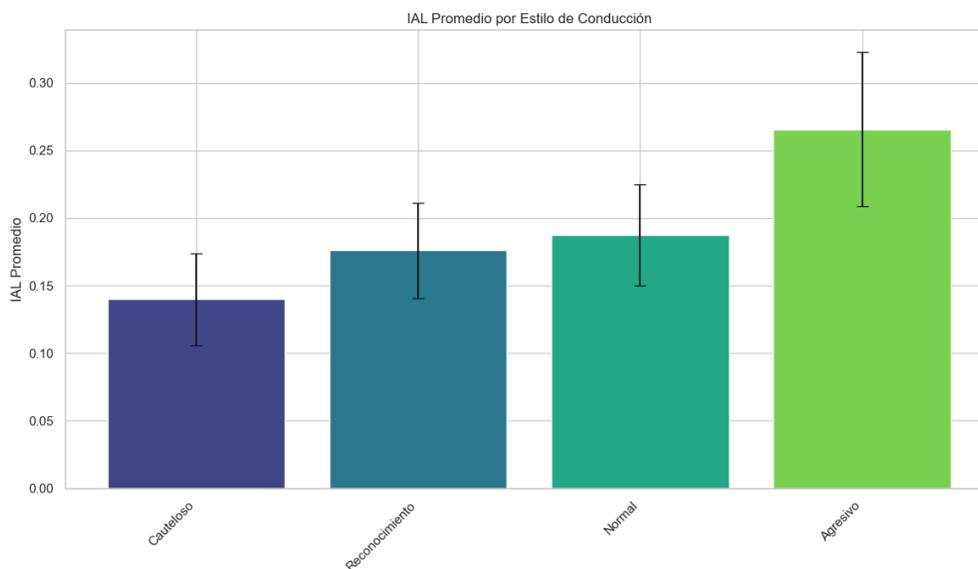
Un IAL más alto sugiere una conducción más cercana a los límites de adherencia, es decir, una mayor probabilidad de derrape. Los análisis se realizaron sobre un total de 480 muestras (calculadas como 6 pilotos \* 10 recorridos/piloto \* 8 curvas/recorrido). Los 10 recorridos por piloto se dividieron en: 1 de Reconocimiento, 3 Normales, 3 Cautelosos y 3 Agresivos.

El análisis se centró en determinar cómo el estilo de manejo general afecta el IAL. La Tabla 4 resume los valores promedio del IAL (Sumatoria de los  $IAL_i$  de todos los recorridos  $i$  pertenecientes al grupo, dividida por el número  $N$  de recorridos en ese grupo), su desviación estándar y el número de recorridos considerados para cada estilo de manejo.

**Tabla 4.** IAL Promedio y Desviación Estándar por estilo de manejo en recorridos completos.

| Estilo de manejo | IAL Promedio | Desv. Estándar IAL | N° de muestras |
|------------------|--------------|--------------------|----------------|
| Cauteloso        | 0.1399       | 0.0340             | 144            |
| Reconocimiento   | 0.1761       | 0.0352             | 48             |
| Normal           | 0.1874       | 0.0376             | 144            |
| Agresivo         | 0.2657       | 0.0570             | 144            |

En la Figura 12 se observa una clara tendencia ascendente en el IAL promedio a medida que el estilo de manejo se vuelve más agresivo. El estilo "Agresivo" presenta el IAL promedio más alto (0.2657), lo que indica una utilización significativamente mayor del agarre disponible, siendo este valor aproximadamente un 90% superior al IAL del estilo "Cauteloso (0.1399)". Los estilos "Reconocimiento" (0.1761) y "Normal" (0.1874) se sitúan en niveles intermedios, con el estilo "Normal" mostrando un IAL ligeramente superior al de "Reconocimiento", lo cual es coherente con la naturaleza exploratoria de este último. Las barras de error, representando la desviación estándar, también tienden a ser mayores para el estilo "Agresivo", sugiriendo una mayor variabilidad en la ejecución de maniobras dentro de este estilo.

**Figura 12.** IAL promedio por estilo de manejo.

Para profundizar en el análisis, se examinó cómo el IAL varía no solo con el estilo de manejo sino también con la geometría específica de cada curva. La Tabla 5 presenta estos resultados detallados.

**Tabla 5.** IAL promedio por curva y estilo de manejo seleccionado, con radio promedio de Curva.

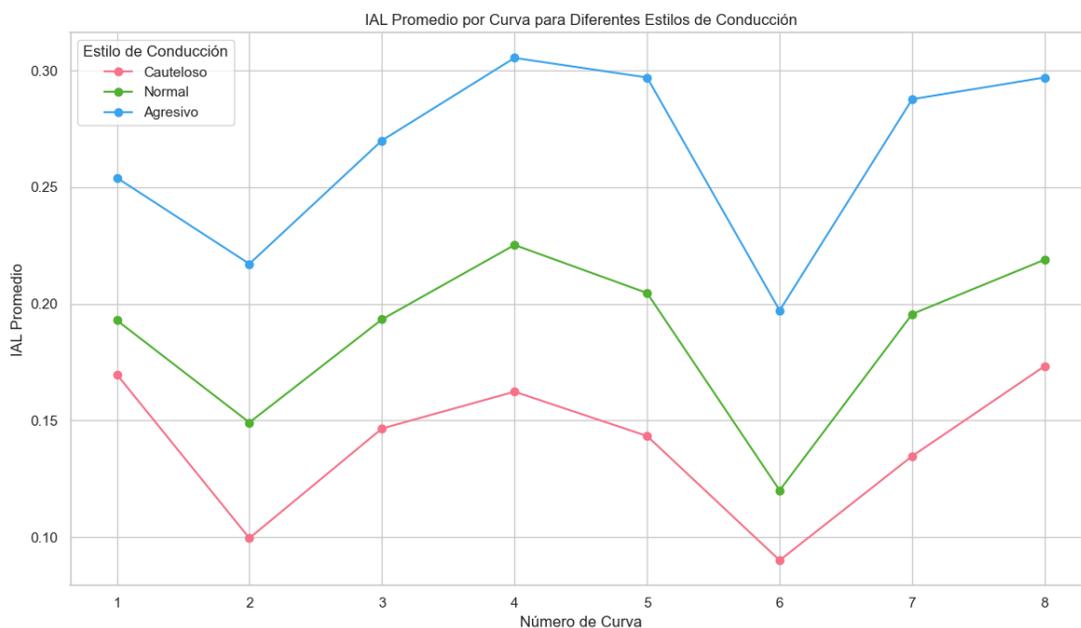
| Curva | Radio Prom.<br>(m) |  | IAL<br>(Cauteloso) | IAL<br>(Normal) | IAL<br>(Agresivo) |
|-------|--------------------|--|--------------------|-----------------|-------------------|
| 1     | 124.47             |  | 0.1697             | 0.1929          | 0.2540            |
| 2     | 26.58              |  | 0.0995             | 0.1491          | 0.2171            |
| 3     | 33.30              |  | 0.1465             | 0.1933          | 0.2700            |
| 4     | 42.95              |  | 0.1623             | 0.2252          | 0.3054            |
| 5     | 30.55              |  | 0.1433             | 0.2046          | 0.2970            |
| 6     | 26.62              |  | 0.0900             | 0.1200          | 0.1971            |
| 7     | 47.00              |  | 0.1347             | 0.1956          | 0.2877            |
| 8     | 112.01             |  | 0.1733             | 0.2189          | 0.2970            |

\* Para una comparación más clara de los niveles de agresión, se omite el estilo "Reconocimiento" en este análisis.

En la Figura 13 se puede observar que, independientemente de la curva, el estilo "Agresivo" resulta consistentemente con el IAL más alto, seguido por el "Normal" y luego el "Cauteloso". Este patrón refuerza la dominancia del estilo de manejo sobre el IAL.

Un análisis más detallado de la Tabla 5 revela una interacción fascinante entre la geometría de la curva, expresada por su radio, y el comportamiento del conductor. Es notable que, para cada una de las ocho curvas analizadas, se mantiene una jerarquía consistente: el IAL del estilo "Agresivo" es siempre superior al "Normal", y este a su vez, al "Cauteloso". Esta robustez del patrón subraya que el estilo de manejo es un factor dominante, independientemente del contexto geométrico específico.

Sin embargo, la geometría actúa como un modulador crucial de la intensidad. Por ejemplo, en curvas muy cerradas como la Curva 6 (Radio  $\approx$  26.62 m), los valores de IAL son universalmente más bajos, lo que indica que la exigencia de la curva impone un límite físico que obliga incluso a los conductores más agresivos a moderar su velocidad y esfuerzo lateral.



**Figura 13.** IAL Promedio por Curva para Diferentes Estilos de manejo

Al analizar curvas específicas, la curva 4 (Radio  $\approx 42.95$  m) destaca por registrar el IAL más elevado bajo conducción "agresiva" (0.3054). Las curvas 5 (Radio  $\approx 30.55$  m) y 8 (Radio  $\approx 112.01$  m) también muestran IALs significativamente altos en este estilo (0.2970 para ambas). Es interesante notar que la curva 8, a pesar de tener el radio más amplio, induce un IAL tan alto como la curva 5 (radio mucho menor) en modo agresivo, sugiriendo que radios amplios pueden invitar a velocidades mayores que resultan en una alta utilización del agarre.

En contraste, la curva 6, que presenta uno de los radios más cerrados del circuito ( $\approx 26.62$  m), muestra consistentemente los IALs más bajos en todos los estilos de manejo, alcanzando solo 0.1971 en modo "Agresivo". Esto indica que la exigencia por la geometría de la curva obliga a los conductores a reducir significativamente la velocidad, limitando el esfuerzo lateral independientemente de su estilo de manejo instruido. La curva 2, con un radio similar a la 6, también muestra IALs bajos, especialmente en los estilos "No Agresivo" y "Normal".

El comportamiento individual de los pilotos también fue examinado, analizando el IAL promedio que cada piloto alcanzó para los diferentes estilos de manejo definidos. La Tabla 6 resume estos resultados.

**Tabla 6.** IAL Promedio por Piloto (Codificado Numéricamente) y estilo de manejo.

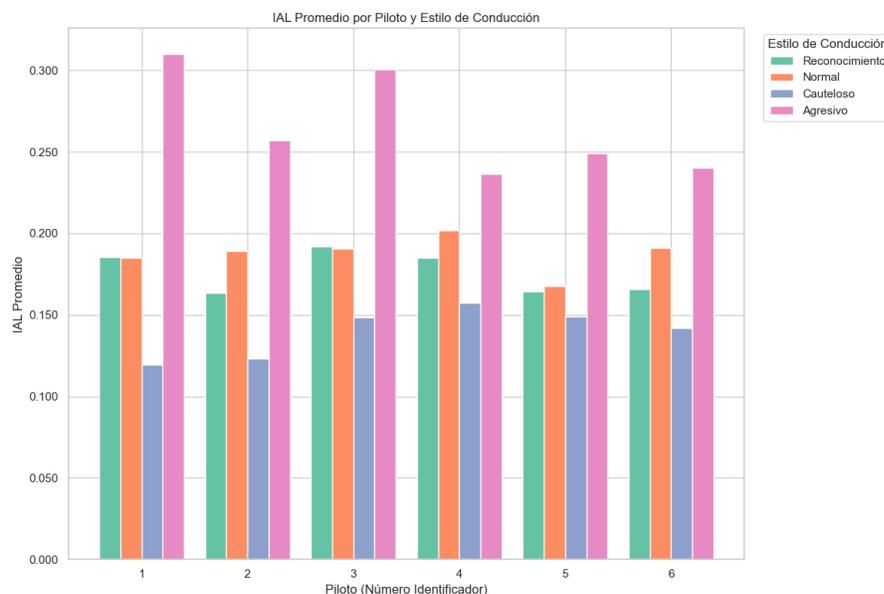
| Piloto | IAL<br>(Reconocimiento) | IAL<br>(Normal) | IAL<br>(Cauteloso) | AL<br>(Agresivo) |
|--------|-------------------------|-----------------|--------------------|------------------|
| 1      | 0.1854                  | 0.1848          | 0.1194             | 0.3102           |
| 2      | 0.1635                  | 0.1892          | 0.1232             | 0.2570           |
| 3      | 0.1921                  | 0.1904          | 0.1487             | 0.3004           |
| 4      | 0.1852                  | 0.2017          | 0.1573             | 0.2367           |
| 5      | 0.1643                  | 0.1676          | 0.1488             | 0.2493           |
| 6      | 0.1658                  | 0.1909          | 0.1420             | 0.2403           |

La Figura 14 presenta visualmente el IAL promedio por piloto mediante barras agrupadas. Se confirma que todos los pilotos siguen la tendencia general de incrementar su IAL a medida que el estilo de manejo se vuelve más agresivo.

Es igualmente revelador analizar la variabilidad entre pilotos dentro de cada estilo. Mientras que en el modo "Cauteloso" las diferencias son relativamente contenidas, en el modo "Agresivo" la brecha entre el piloto más y menos intenso se amplía significativamente. Esto sugiere que, si bien la conducción prudente puede converger hacia un patrón de comportamiento más homogéneo y predecible, el concepto de "agresividad" es altamente personal y se manifiesta en un espectro mucho más amplio

Dentro del estilo "Agresivo", se observan diferencias notables: los pilotos 1 y 3 son quienes alcanzan los IALs promedio más altos, con 0.3102 y 0.3004 respectivamente, indicando que tienden a llevar el vehículo más cerca de sus límites de adherencia en este modo. En el otro extremo, dentro del mismo estilo "Agresivo", los pilotos 4 y 6 muestran los IALs más bajos (0.2367 y 0.2403), sugiriendo una conducción comparativamente más conservadora incluso cuando se les instruye ser agresivos.

En el estilo "Cauteloso", el piloto 1 registra el IAL más bajo (0.1194), mientras que el piloto 4 presenta el más alto (0.1573), aunque las diferencias absolutas son menores en este estilo en comparación con el "Agresivo". Estas observaciones sugieren que, además del estilo de manejo impuesto, existen características intrínsecas a cada piloto que influyen en su forma de utilizar el agarre disponible.



**Figura 14.** IAL promedio por piloto y estilo de manejo.

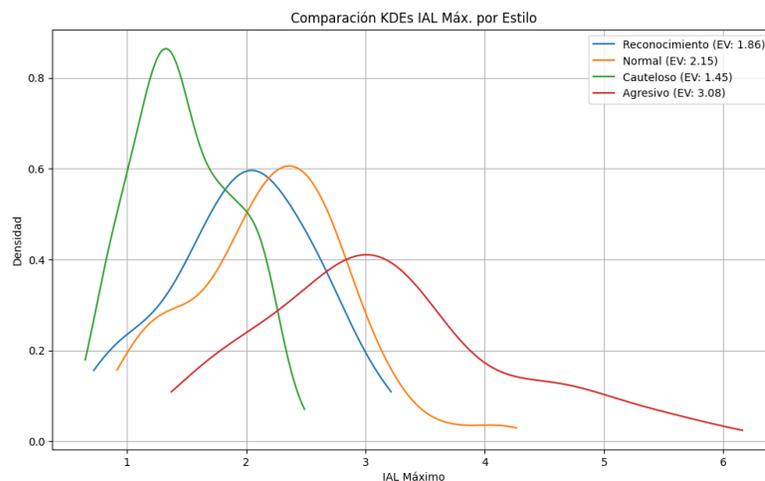
En conjunto, los resultados presentados en esta sección demuestran claramente la capacidad del Índice de Aceleración Lateral (IAL) para capturar y cuantificar objetivamente las diferencias en el comportamiento del conductor asociadas a los estilos de manejo auto informados. La clara tendencia ascendente del IAL promedio conforme aumenta la agresividad del estilo —observada consistentemente a través de diferentes geometrías de curva y entre distintos pilotos— subraya la utilidad de esta métrica. Por lo tanto, el IAL no solo refleja la intensidad con la que se abordan las maniobras en curva, sino que lo consideraremos como un indicador fiable de la intención y ejecución del estilo de manejo, validando su utilidad como herramienta para discriminar y caracterizar objetivamente las conductas al volante en el contexto de este estudio experimental.

### 3.1.2.2 Impacto del estilo de manejo en la distribución de los datos

Para complementar el análisis del IAL y obtener una perspectiva más detallada sobre la distribución del riesgo asociado a diferentes estilos de manejo, se empleó la Estimación de Densidad Kernel (KDE por sus siglas en inglés). El KDE permite estimar la función de masa de probabilidad (PMF) del IAL máximo por curva, ofreciendo una visión de qué valores de "estrés" vehicular son más frecuentes para cada estilo de manejo y si estos tienden a concentrarse cerca o lejos de umbrales de riesgo.

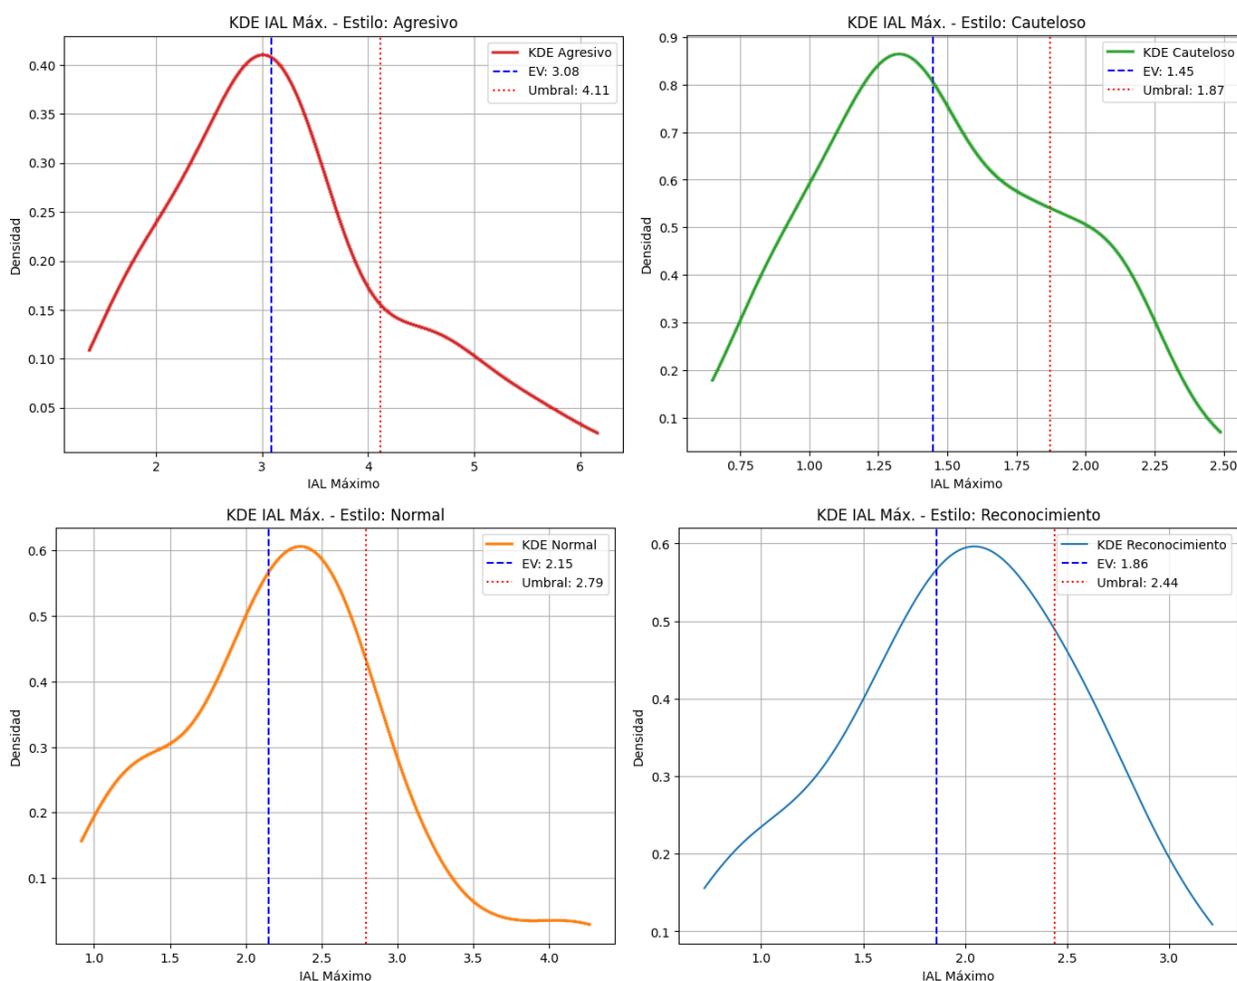
Para cada estilo de manejo, se encontró la PMF utilizando la KDE y los valores de IAL máximo registrados en cada una de las curvas durante los recorridos correspondientes a dicho estilo. Se definió un umbral de riesgo específico para cada estilo correspondiente al valor esperado (EV) del IAL máximo más una desviación estándar (DE) de dicho IAL máximo para ese estilo ( $EV_{\text{estilo}} + 1.0 * DE_{\text{estilo}}$ ).

La Figura 15 muestra la comparación de las distribuciones obtenidas con KDE para los cuatro estilos de manejo. Se observa claramente cómo la distribución se desplaza hacia valores de IAL máximo más altos a medida que aumenta la agresividad del estilo. El estilo “Cauteloso” presenta su pico de densidad (moda) en valores de IAL más bajos y una distribución más concentrada. En contraste, el estilo “Agresivo” no solo tiene su pico (y valor esperado) considerablemente más a la derecha, sino que también muestra una mayor dispersión (una cola más larga hacia la derecha), indicando una mayor probabilidad inherente de alcanzar valores de IAL más elevados y variados. Los estilos “Reconocimiento” y “Normal” se sitúan en posiciones intermedias, con el estilo “Normal” mostrando valores esperados ligeramente superiores al de “Reconocimiento”.



**Figura 15.** Comparación de las gráficas de densidad de kernel del índice de aceleración Lateral máxima por estilo de manejo.

La Figura 16 presenta las distribuciones individuales para cada estilo, donde se visualizan con mayor claridad el valor esperado (EV, línea azul discontinua) y el umbral de riesgo calculado (línea roja punteada) para cada uno. Estas gráficas individuales permiten apreciar la forma específica de cada distribución y la posición relativa de su umbral de riesgo.



**Figura 16.** Densidad de kernel del índice de aceleración Lateral máxima por estilo de manejo, Valor esperado (EV) y umbral de violacion (EV + STDev).

La Tabla 7 resume cuantitativamente estos resultados. Los valores esperados (EV) del IAL Máximo son: “Cauteloso” (1.446), “Reconocimiento” (1.859), “Normal” (2.149) y “Agresivo” (3.084). Esta progresión confirma la tendencia observada en los promedios de IAL (Tabla 4) y en la Figura 15.

Las desviaciones estándar (DE IAL Máx.) también reflejan la dispersión observada: “Cauteloso” (DE = 0.427), “Reconocimiento” (DE = 0.580), “Normal” (DE = 0.646) y “Agresivo” (DE = 1.031), siendo la más alta para el estilo “Agresivo”.

Consecuentemente, los umbrales de riesgo (EV + 1 DE) siguen la misma tendencia ascendente: “Cauteloso” (1.873), “Reconocimiento” (2.439), “Normal” (2.795) y “Agresivo” (4.114).

**Tabla 7.** Resumen de Estadísticas KDE y Violaciones por estilo de manejo.

| Estilo de manejo | Valor Esperado IAL Max (EV) | STD DEV. de IAL Max. (DE) | Umbral de Riesgo (Estilo) | % Violaciones (vs Umbral Estilo) |
|------------------|-----------------------------|---------------------------|---------------------------|----------------------------------|
| Reconocimiento   | 1.859                       | 0.58                      | 2.439                     | 22.92% (11/48)                   |
| Normal           | 2.149                       | 0.646                     | 2.795                     | 13.89% (20/144)                  |
| Cauteloso        | 1.446                       | 0.427                     | 1.873                     | 20.14% (29/144)                  |
| Agresivo         | 3.084                       | 1.031                     | 4.114                     | 19.44% (28/144)                  |

Es particularmente interesante la columna "% Violaciones (vs Umbral Estilo)" en la Tabla 7. Esta métrica indica la proporción de veces que, dentro de un estilo de manejo específico, se superó el umbral de riesgo definido para ese mismo estilo. El estilo 'Normal' presenta el menor porcentaje de violaciones de su propio umbral (13.89%), sugiriendo que cuando los conductores intentan conducir 'normalmente', tienden a mantenerse dentro de lo que se considera 'normal' para ellos en términos de esfuerzo lateral máximo. Los estilos "Reconocimiento" (22.92%), "Cauteloso" (20.14%) y "Agresivo" (19.44%) muestran porcentajes de "violación de umbrales" similares entre sí, pero más altos que el "Normal". Para el estilo "Agresivo", esto implica que en casi el 20% de las maniobras clasificadas como agresivas, los conductores superaron incluso el límite superior de lo que sería su comportamiento agresivo 'típico' (definido aquí por su EV+DE).

Adicionalmente, la Figura 17 presenta un panorama detallado de las violaciones de umbral, pero en este caso, el umbral se calcula para cada curva individualmente ( $EV_{\text{curva}} + 1.0 * DE_{\text{curva}}$ ), no para el estilo general. Aunque el análisis principal de esta sección se centra en los valores esperados por estilo, esta figura complementa la visión mostrando cómo, recorrido por recorrido y piloto por piloto, se manifiestan estas superaciones de umbrales de riesgo en curvas específicas. Se observa que los recorridos etiquetados como 'Agresivo' (008, 009, 010) tienden a tener una mayor densidad de celdas rojas ('Sí' violó el umbral de la curva), lo cual es consistente con las expectativas.

| Recorrido             | Piloto | C1 | C2 | C3 | C4 | C5 | C6 | C7 | C8 |
|-----------------------|--------|----|----|----|----|----|----|----|----|
| 001<br>Reconocimiento | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 002<br>Normal         | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 003<br>Normal         | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 004<br>Normal         | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 005<br>Cauteloso      | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 006<br>Cauteloso      | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 007<br>Cauteloso      | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 008<br>Agresivo       | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 009<br>Agresivo       | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |
| 010<br>Agresivo       | 1      |    |    |    |    |    |    |    |    |
|                       | 2      |    |    |    |    |    |    |    |    |
|                       | 3      |    |    |    |    |    |    |    |    |
|                       | 4      |    |    |    |    |    |    |    |    |
|                       | 5      |    |    |    |    |    |    |    |    |
|                       | 6      |    |    |    |    |    |    |    |    |

**Figura 17.** Matriz de violaciones de umbral de riesgo por curva individual. El color rojo corresponde a un valor superior al umbral de riesgo, teniendo así, una violación.

En conjunto, estos resultados del análisis refuerzan la validez de las etiquetas de autoevaluación. Las distribuciones de probabilidad del IAL máximo se alinean consistentemente con la naturaleza de cada estilo de manejo instruido, mostrando no solo diferencias en los valores centrales (EV) y la dispersión (DE), sino también en cómo los conductores se comportan en relación con los umbrales de riesgo derivados de sus propios patrones de conducción para cada estilo.

### **3.2 Validación de la clasificación basada en autoevaluación**

Los resultados presentados en la Sección 3.1 establecen de manera concluyente la premisa fundamental de este estudio: las etiquetas de estilo de manejo autorreportadas por los conductores no son arbitrarias, sino que se correlacionan con patrones cinemáticos objetivos y cuantificables.

La evidencia para la validación de la Clasificación Basada en Autoevaluación incluye:

- La dispersión estadística de la aceleración lateral, que es significativamente mayor en la conducción agresiva (refiérase el lector a la sección 3.1.1).
- El Índice de Aceleración Lateral (IAL), que muestra una clara y consistente jerarquía de agresividad a través de diferentes curvas y pilotos (refiérase el lector a la sección 3.1.2.1).
- Las distribuciones de riesgo (obtenidas mediante KDE), que confirman que los estilos más agresivos no solo alcanzan picos de esfuerzo dinámico más altos, sino que lo hacen con mayor variabilidad (refiérase el lector a la sección 3.1.2.2).

En conjunto, estas métricas demuestran que las etiquetas subjetivas reflejan un comportamiento medible en el vehículo. Esta correlación validada nos permite utilizar las etiquetas autorreportadas como una referencia fiable para el entrenamiento y la evaluación de los modelos de clasificación en las secciones subsiguientes.

### **3.3 Análisis exploratorio de la dimensionalidad y separabilidad de clases**

Tras la validación de la estrategia de etiquetado subjetivo de los estilos de manejo (refiérase el lector a las

secciones 3.1 y 3.2), se llevó a cabo un PCA con fines exploratorios. Este análisis tuvo como objetivos principales: primero, reducir la dimensionalidad de las características extraídas de los recorridos para facilitar su visualización. Segundo, evaluar visualmente si existe una separación natural entre las clases de recorrido autorreportadas ("Reconocimiento", "Normal", "Cauteloso" y "Agresivo") en este espacio de características reducido. Y tercero, cuantificar la varianza explicada por los primeros componentes principales. Finalmente, de forma complementaria, comparar la estructura de los datos con un agrupamiento no supervisado mediante agrupamiento de modelos de mezcla gaussiana (GMM) utilizando el índice Rand ajustado (ARI).

### 3.3.1 Metodología del PCA exploratorio

En este trabajo no se tiene como objetivo encontrar los componentes más relevantes para la clasificación de estilo de manejo. Sin embargo, es importante explorar la viabilidad de la reducción de dimensionalidad, ya que más adelante se mostrará el impacto de la frecuencia de muestreo en este proceso (ver Sección 3.4).

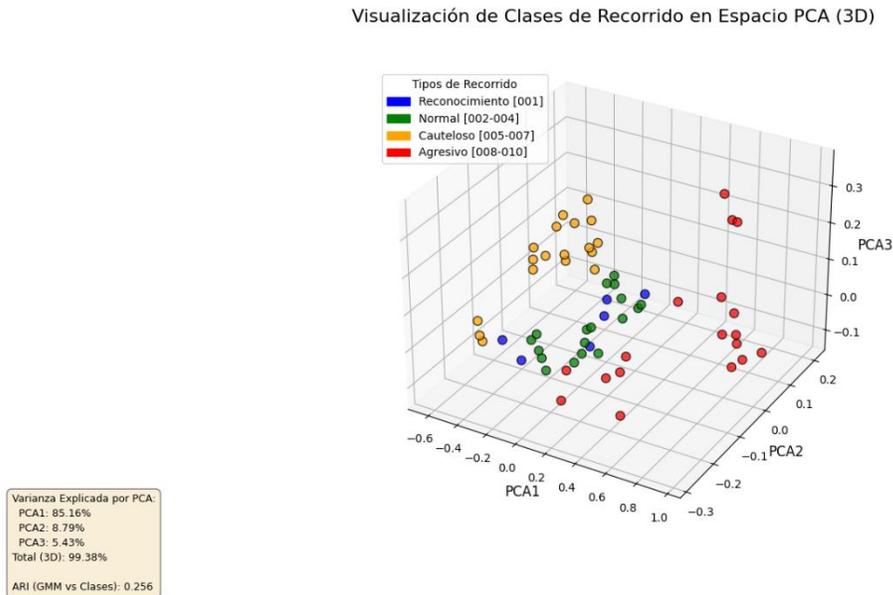
Para este análisis, se procesaron los datos del sensor Accel1 (LSM6DS) provenientes de cada archivo CSV de recorrido. De cada recorrido completo, se extrajeron seis características estadísticas básicas: la media y la desviación estándar de las señales de los tres ejes del acelerómetro (Accel\_1\_X, Accel\_1\_Y, Accel\_1\_Z). Este conjunto de seis características por recorrido fue la entrada para el PCA.

El PCA se configuró para obtener tres componentes principales, lo que permite una visualización en un espacio tridimensional. Adicionalmente, se aplicó un GMM con un número de componentes igual al número de clases de recorrido definidas a los datos transformados por PCA. La concordancia entre los clústeres generados por GMM y las clases de recorrido predefinidas se midió utilizando el ARI.

Las características seleccionadas –media y desviación estándar de cada eje del acelerómetro Accel1– fueron escogidas por su capacidad para resumir la tendencia central y la dispersión de las señales de aceleración, aspectos que ya mostraron ser informativos en los análisis preliminares (ver Sección 3.1.1). El uso de tres componentes principales para el PCA permite una visualización directa de la estructura de los datos en 3D. El GMM se utilizó para explorar la estructura de agrupamiento inherente en los datos, y el ARI proporciona una medida cuantitativa de cuán bien este agrupamiento no supervisado se alinea con las etiquetas de estilo de manejo asignadas por los conductores.

### 3.3.2 Resultados visuales y cuantitativos del PCA

Los resultados del análisis de componentes principales se presentan visualmente en la Figura 18, cuantitativamente a través de la varianza explicada y el índice ARI.



**Figura 18.** Visualización de Clases de Recorrido en Espacio PCA (3D)

La Figura 18 ilustra la distribución de los diferentes tipos de recorrido en el espacio tridimensional definido por los primeros tres componentes principales. Se observa una tendencia clara a la separación de los estilos de manejo. Los recorridos 'Agresivos' (puntos rojos) tienden a agruparse en una región distintiva, generalmente separada de los demás estilos. Los recorridos "Cautelosos" (puntos naranjas) también forman un grupo relativamente cohesivo. Los recorridos "Normales" (puntos verdes) se sitúan en una zona intermedia, a veces mostrando cierto traslape con los recorridos "Cautelosos" y "Reconocimiento" (puntos azules). El estilo "Reconocimiento", representado por un menor número de muestras, aparece más cercano a los grupos "Normal" y "Cauteloso". En general, la visualización sugiere que las características estadísticas básicas, transformadas por PCA, retienen suficiente información para discriminar entre los estilos de manejo.

**Tabla 8.** Varianza Explicada por PCA y ARI.

| <b>Métrica</b>                      | <b>Valor</b> |
|-------------------------------------|--------------|
| Varianza Explicada por PCA1         | 85.16%       |
| Varianza Explicada por PCA2         | 8.79%        |
| Varianza Explicada por PCA3         | 5.43%        |
| Varianza Total Explicada (3D)       | 99.38%       |
| Adjusted Rand Index (GMM vs Clases) | 0.256        |

Como se detalla en la Tabla 8 y se muestra en la Figura 18, los tres primeros componentes principales logran explicar un 99.38% de la varianza total de las seis características originales. El primer componente principal (PCA1) es dominante, capturando el 85.16% de la varianza, lo que sugiere que una gran parte de la distinción entre recorridos puede proyectarse sobre un único eje. Los componentes PCA2 y PCA3 aportan un 8.79% y un 5.43% adicional, respectivamente, contribuyendo a refinar la separación en el espacio 3D.

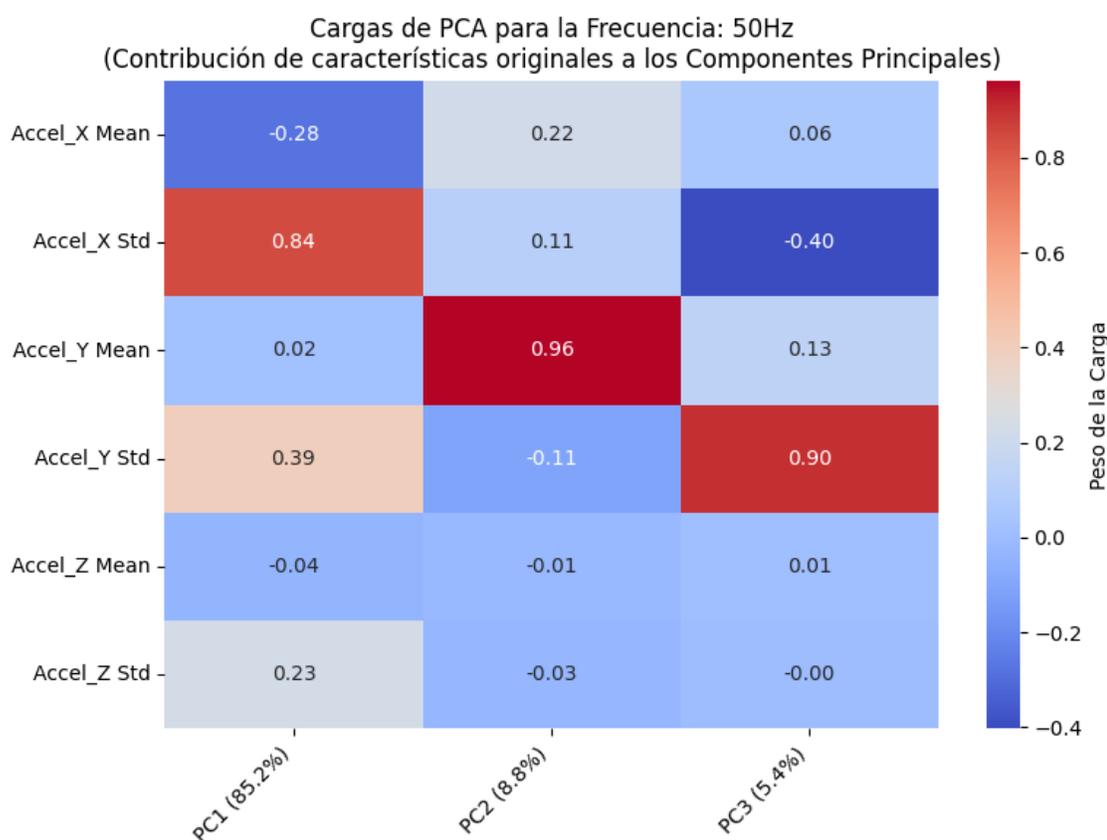
El análisis detallado de las cargas de los componentes, como se muestra en la Figura 19, revela lo siguiente: El Componente Principal 1 (PC1), está fuertemente influenciado por la desviación estándar de la aceleración en el eje X (Accel\_X Std con una carga de 0.84). Esto sugiere que la mayor parte de la variabilidad en los datos a 50Hz está relacionada con la magnitud de las fluctuaciones (o la "agitación") en la dirección X. En menor medida, la desviación estándar en Y (Accel\_Y Std, carga 0.39) también contribuye positivamente, mientras que la media de aceleración en X (Accel\_X Mean, carga -0.28) tiene una influencia negativa moderada.

El Componente Principal 2 (PC2), está casi exclusivamente definido por la media de la aceleración en el eje Y (Accel\_Y Mean con una carga muy alta de 0.96). Esto indica que PC2 captura principalmente la

información sobre el promedio del movimiento o la fuerza neta en la dirección Y.

Finalmente, el Componente Principal 3 (PC3) está dominado por una fuerte carga positiva de la desviación estándar de la aceleración en el eje Y (Accel\_Y Std, carga 0.90), y una carga negativa moderada de la desviación estándar en el eje X (Accel\_X Std, carga -0.40). Esto implica que PC3 distingue variaciones en la "agitación" del eje Y, y que esta tiende a ser opuesta a la variabilidad en el eje X para este componente.

En resumen, a 50Hz, la variabilidad en la aceleración del eje X (su desviación estándar) es la característica más distintiva (PC1). El movimiento promedio en el eje Y (PC2) y la variabilidad en el eje Y (PC3) son las siguientes fuentes de variación más importantes, siendo las características del eje Z mucho menos influyentes en estos tres componentes principales. En resumen, el PCA revela que la distinción principal entre estilos de manejo a 50 Hz reside en la magnitud de la 'agitación' lateral (PC1), seguida del patrón general de aceleración y frenado longitudinal (PC2).



**Figura 19.** Mapa de calor de las cargas del Análisis de Componentes Principales para datos a 50 Hz.

El ARI obtenido al comparar los clústeres del GMM con las clases predefinidas fue de 0.256. Un valor de ARI de 1 indica una concordancia perfecta, mientras que un valor cercano a 0 sugiere una concordancia aleatoria. El valor de 0.256, aunque no es alto, indica una similitud superior a la aleatoria entre la estructura de agrupamiento encontrada por el GMM y las etiquetas de los conductores. Esto sugiere que, si bien hay una señal de agrupamiento natural que se alinea parcialmente con las clases, la distinción no es perfectamente clara para un método no supervisado basado únicamente en estas seis características y con el número de componentes GMM fijado a priori. La separación visual observada en la Figura 18, donde se utilizan las etiquetas directas de los recorridos, parece más definida que la que sugiere el GMM por sí solo.

### 3.3.3 Implicaciones del PCA exploratorio

Este análisis exploratorio mediante PCA ofrece las siguientes implicaciones:

- **Viabilidad de Reducción de Dimensionalidad:** Los datos de aceleración, representados por estadísticas básicas, pueden reducirse efectivamente a un espacio de menor dimensionalidad (3D en este caso) reteniendo casi la totalidad de su varianza original. Esto es beneficioso para la visualización y potencialmente para la eficiencia de los algoritmos de clasificación.
- **Separabilidad de Clases:** Existe una estructura discernible en el espacio PCA que se correlaciona con los estilos de manejo autorreportados. Los estilos, especialmente el "Agresivo", tienden a ocupar regiones distintas, lo que apoya la hipótesis de que estos estilos son objetivamente diferenciables a partir de los datos de la IMU.
- **Complejidad de la Discriminación:** Si bien hay separación visual, el valor moderado del ARI sugiere que la distinción entre todos los estilos, particularmente para un método no supervisado como GMM, no es trivial y podría beneficiarse de características más discriminativas o de una supervisión directa (como en los modelos de clasificación). El solapamiento observado, especialmente entre "Normal", "Cauteloso" y "Reconocimiento", indica áreas donde la distinción es más sutil.

### **3.4 Evaluación del impacto de la frecuencia de muestreo**

Partiendo de la base de datos original, muestreada a 50 Hz como referencia capturando con alta fidelidad la dinámica de la conducción, incluyendo vibraciones y maniobras abruptas. Se generaron conjuntos de datos equivalentes a frecuencias de muestreo progresivamente más bajas: 25 Hz, 10 Hz, 5 Hz, 1 Hz, 0.5 Hz, 0.25 Hz y 0.1 Hz. Este proceso se realizó mediante un diezmado simple (seleccionando una de cada N muestras), una técnica que simula directamente el uso de sensores con menores capacidades de adquisición, permitiendo aislar el efecto de la densidad de información.

#### **3.4.1 Metodología del análisis PCA multifrecuencia**

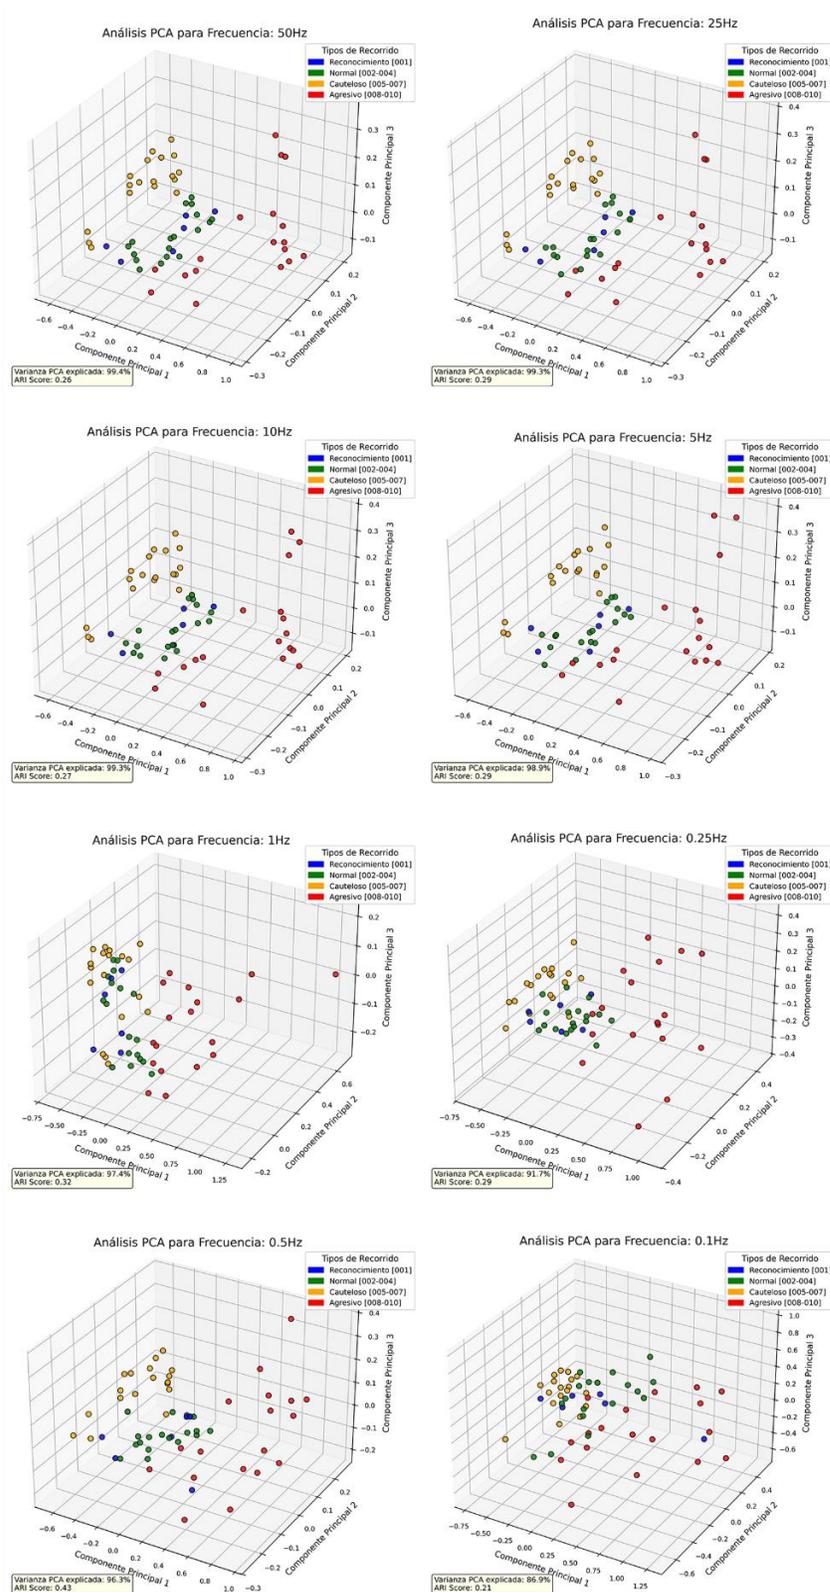
Se partió de la base de datos original muestreada a 50 Hz. Mediante un proceso de diezmado simple (seleccionando una de cada N muestras), se generaron conjuntos de datos equivalentes a frecuencias de muestreo inferiores: 25 Hz, 10 Hz, 5 Hz, 1 Hz, 0.5 Hz, 0.25 Hz y 0.1 Hz.

**Para cada una de estas frecuencias:**

- Se extrajeron las mismas seis características estadísticas por recorrido que en el análisis anterior (Ver Sección 3.3.1): media y desviación estándar de las señales de los tres ejes del acelerómetro (Accel\_1\_X, Accel\_1\_Y, Accel\_1\_Z).
- Se aplicó PCA para reducir la dimensionalidad a tres componentes principales.
- Se calculó la varianza total explicada por estos tres componentes.
- Se aplicó un Modelo de GMM con cuatro componentes (correspondientes a las clases "Reconocimiento", "Normal", "Cauteloso" y "Agresivo") a los datos transformados por PCA.
- Se calculó el ARI para comparar los clústeres del GMM con las clases de recorrido predefinidas.

Este enfoque permite observar directamente cómo la reducción en la densidad de puntos, inherente a frecuencias de muestreo más bajas, influye en la capacidad del PCA para capturar la estructura que diferencia los estilos de manejo.

### 3.4.2 Resultados visuales y cuantitativos del análisis multifrecuencia



**Figura 20.** Análisis Comparativo por frecuencia de muestreo de la Visualización de Clases de Recorrido en Espacio PCA (3D).

La Figura 20, muestra una serie de proyecciones PCA 3D, una para cada frecuencia de muestreo analizada. Al contar con una frecuencia de muestreo alta (50 Hz, 25 Hz, 10 Hz, 5 Hz), la separación visual entre los estilos de manejo, particularmente entre "Agresivo" (rojo) y los demás, es relativamente clara y consistente. Los grupos "Cauteloso" (naranja) y "Normal" (verde) también tienden a formar conglomerados distinguibles, aunque con mayor proximidad entre sí y con "Reconocimiento" (azul). La varianza explicada por los tres componentes principales se mantiene muy alta, consistentemente por encima del 98% en este rango."

A medida que la frecuencia de muestreo disminuye por debajo de 5 Hz, comienzan a observarse cambios sutiles. A 1 Hz, la estructura general de los clústeres aún es reconocible, y la varianza explicada sigue siendo alta (97.4%). Sin embargo, los puntos dentro de cada clúster pueden parecer ligeramente más dispersos o los límites entre clústeres menos definidos.

La degradación se vuelve más pronunciada a 0.5 Hz y 0.25 Hz. Aunque todavía se puede inferir una tendencia general de separación (especialmente para el grupo "Agresivo"), el traslape entre los grupos "Normal" y "Cauteloso" aumenta, y la forma de los clústeres se vuelve menos cohesiva. La varianza explicada por PCA comienza a disminuir más notablemente (96.3% a 0.5 Hz, 91.7% a 0.25 Hz), indicando que los tres primeros componentes capturan una proporción menor de la información original.

Finalmente, a 0.1 Hz, la estructura de clases se pierde en gran medida. Los puntos de diferentes estilos se mezclan considerablemente, y resulta difícil distinguir agrupaciones claras. La varianza explicada por los tres componentes PCA cae a 86.9%, y los clústeres son visualmente indistinguibles, sugiriendo una pérdida significativa de la información relevante para la discriminación de estilos.

El comportamiento del ARI, que mide la concordancia entre el agrupamiento GMM y las clases reales, refleja estas observaciones visuales. A 50 Hz, el ARI es de 0.26. Este valor fluctúa ligeramente en las frecuencias altas (0.29 a 25Hz, 0.27 a 10Hz, 0.29 a 5Hz), e incluso muestra un pico a 0.5 Hz (ARI = 0.43) y 1 Hz (ARI = 0.32). Es importante notar que el GMM es un método no supervisado y su rendimiento puede ser sensible a la forma de los clústeres. El aumento temporal del ARI a 0.5 Hz podría indicar que, a esa resolución, la forma de los clústeres naturales se alinea fortuitamente mejor con los supuestos del GMM para estas 6 características, o que la reducción de ruido de alta frecuencia mejora la definición de los clústeres para GMM, antes de que la pérdida de información útil por submuestreo domine. No obstante, a 0.25 Hz (ARI = 0.29) y especialmente a 0.1 Hz (ARI = 0.21), el ARI disminuye, indicando una menor concordancia, lo que es consistente con la pérdida de separabilidad visual.

### 3.4.3 Implicaciones del PCA multifrecuencia

Este análisis visual comparativo del PCA a través de diferentes frecuencias de muestreo sugiere lo siguiente:

1. **Robustez a Altas Frecuencias:** La estructura de clases, tal como la capturan las seis características estadísticas básicas, es bastante robusta a frecuencias de muestreo desde 50 Hz hasta aproximadamente 5 Hz. En este rango, la separabilidad visual y la varianza explicada por PCA son consistentemente altas.
2. **Umbral de Degradación:** Una degradación en la separabilidad de los clústeres comienza a ser visualmente evidente, con un mayor traslape entre ellos y en la varianza explicada comienza a ser evidente alrededor de 0.5 Hz - 0.25 Hz.
3. **Pérdida de Información Discriminativa:** A 0.1 Hz, la información discriminativa contenida en estas seis características parece ser insuficiente para mantener una estructura de clases clara en el espacio PCA. Esto es un comportamiento esperado, considerando menos de 1 muestra por segundo podría no capturar la dinámica de manejo, donde los eventos suceden en el orden de segundos.
4. **Comportamiento del ARI:** El ARI, si bien es una métrica útil, debe interpretarse con cautela en análisis exploratorios como este, ya que el GMM no supervisado puede no capturar la misma estructura que la supervisión directa por etiquetas. No obstante, su tendencia general (disminución a frecuencias muy bajas) apoya la idea de pérdida de estructura.

### 3.4.4 Resumen y validación metodológica integral

Las secciones exploratorias precedentes han cumplido un objetivo crucial, el de validar integralmente los datos y los enfoques metodológicos antes de la evaluación exhaustiva de los modelos de clasificación. Por lo que se ha establecido firmemente que:

**Las etiquetas son significativas:** La estrategia de etiquetado auto informado posee una base cinemática objetiva y consistente, validada a través de métricas de dispersión, riesgo en curva (IAL) y distribuciones de esfuerzo, lo que la consolida como una referencia fiable (Ver Secciones 3.1 y 3.2).

**Los datos poseen una estructura discernible:** El análisis de componentes principales (PCA) ha demostrado que, incluso con características estadísticas básicas, los datos de aceleración pueden reducirse dimensionalmente reteniendo su varianza y mostrando una separación visual entre las clases de manejo, especialmente a frecuencias de muestreo altas (Ver Sección 3.3).

**La frecuencia de muestreo es un factor crítico:** La multifrecuencia PCA ha revelado de forma preliminar que la estructura de clases es robusta en el rango de 5-50 Hz, pero comienza a degradarse visiblemente por debajo de este umbral, anticipando su impacto en el rendimiento de la clasificación (Ver Sección 3.4).

En conclusión, los datos adquiridos son representativos, las etiquetas son válidas y la estructura inherente de los datos es sensible a la frecuencia de muestreo. Con estos fundamentos metodológicos establecidos, se justifica plenamente su uso para los análisis computacionales que se detallan a continuación, los cuales se centrarán en cuantificar rigurosamente el impacto de la frecuencia en la capacidad de clasificación.

### **3.5 Resultados de los análisis computacionales de clasificación**

En las siguientes secciones, se presentarán de manera exhaustiva los resultados obtenidos de los cuatro análisis computacionales diseñados para evaluar el impacto de diferentes conjuntos de características, estrategias de selección y, fundamentalmente, la frecuencia de muestreo en la precisión de la clasificación de estilos de manejo (“Agresivo” vs. “No Agresivo”).

Antes de detallar los resultados de cada análisis, es importante contextualizar el propósito de los dos primeros (Análisis #1 y #2). Estos análisis iniciales se concibieron con un objetivo fundamental: validar la aplicabilidad y efectividad de enfoques de caracterización inspirados en la literatura (específicamente, los trabajos de (Vaitkus et al., 2014), y (Zylius, 2017)) utilizando el conjunto de datos experimentales recopilados para esta investigación. La intención primordial no era optimizar exhaustivamente ni superar los rendimientos reportados en dichos estudios originales, sino más bien confirmar que nuestros datos poseían la calidad y la información discriminativa necesarias para obtener resultados de clasificación coherentes y válidos con estas metodologías establecidas. Consideramos que alcanzar un desempeño

razonable en estas etapas preliminares constituía un paso crucial. Esto proporcionaría la confianza necesaria de que el conjunto de datos era robusto y que las investigaciones subsiguientes, centradas en el impacto de la frecuencia de muestreo (Análisis #3 y #4), se construirían sobre una base sólida y verificada empíricamente. En esencia, los Análisis #1 y #2 sirvieron como una etapa de calibración y validación de los datos y las técnicas de extracción de características base, antes de abordar las preguntas centrales de investigación relacionadas con los parámetros de adquisición de datos.

### 3.5.1 Análisis #1: evaluación con características "Vaitkus-Inspired"

Este primer análisis computacional tuvo como objetivo establecer una línea base de rendimiento utilizando un conjunto compacto de características inspiradas en el trabajo de (Vaitkus et al., 2014). Un aspecto crucial de este análisis fue la evaluación de la sensibilidad de los modelos de clasificación a diferentes estrategias de partición de los datos, prestando especial atención al balanceo de clases para una comparación más equitativa.

#### 3.5.1.1 Metodología específica del análisis #1

Para este análisis, se utilizaron los datos de los acelerómetros adquiridos a una frecuencia original de 50 Hz. Para asegurar un balance de clases en la mayoría de las particiones, se definieron las clases de la siguiente manera:

- **Clase "No Agresivo" (etiqueta 0):** Compuesta por los recorridos etiquetados como "Cautelosos" (originalmente recorridos 005-007).
- **Clase "Agresivo" (etiqueta 1):** Compuesta por los recorridos etiquetados como "Agresivos" (originalmente recorridos 008-010).
- Los recorridos "Reconocimiento" (001) y "Normal" (002-004) fueron excluidos de las particiones principales para este análisis inicial centrado en el contraste directo entre cauteloso y agresivo.

Se consideraron cuatro esquemas de partición, con nombres de reporte mapeados para mayor claridad:

- **DB\_Recorrido\_BIN:** Datos de recorridos completos. Cada recorrido (005-007 y 008-010) se trata como una única instancia, con su respectiva etiqueta binaria.
- **DB\_Segmentos\_BIN:** Datos segmentados en archivos de 30 segundos, con etiquetas binarias (0 o 1) heredadas del estilo del recorrido completo al que pertenecen.
- **DB\_Curva\_KDE\_BIN:** Datos de recorridos completos, pero aquí las etiquetas binarias (0 o 1) se asignan a cada curva según si el valor esperado obtenido del análisis de KDE supera o no un umbral de riesgo predefinido.
- **DB\_Curvas\_BIN:** Datos segmentados por las 8 curvas identificadas en el circuito, con etiquetas binarias (0 o 1) heredadas del estilo del recorrido completo al que pertenecen.

**Características extraídas ("Vaitkus-Inspired"):** Se extrajo un conjunto de 13 características por cada archivo de recorrido o segmento, inspirado en Vaitkus et al. (2014) y enfocado en el sensor Accel\_1. Estas características fueron:

1. Media de la aceleración longitudinal (eje Y filtrado): mean\_accel\_long
2. Media de la aceleración vertical (eje Z filtrado): mean\_accel\_vert
3. Mediana de la aceleración vertical (eje Z filtrado): median\_accel\_vert
4. Covarianza entre aceleración longitudinal (Y) y lateral (X): cov\_long\_lat
5. Nueve (9) características provenientes de los tres primeros coeficientes ( $p_0$ ,  $p_1$ ,  $p_2$ ) de un polinomio de 5º orden ajustado a la inversa de la Función de Densidad Acumulativa (CDF) empírica de la señal de aceleración (del sensor Accel\_1) para cada uno de los tres ejes (X, Y, Z). Específicamente:
  - poly5\_coef0\_X, poly5\_coef1\_X, poly5\_coef2\_X
  - poly5\_coef0\_Y, poly5\_coef1\_Y, poly5\_coef2\_Y
  - poly5\_coef0\_Z, poly5\_coef1\_Z, poly5\_coef2\_Z

**Preprocesamiento de señales:** Previo a la extracción de características, las señales de aceleración del sensor Accel\_1 fueron preprocesadas de la siguiente manera, asumiendo una frecuencia de muestreo de 50 Hz:

- **Ejes X (Accel\_1\_X) e Y (Accel\_1\_Y):** Se aplicó un filtro Butterworth pasa-bajos de 4º orden con frecuencia de corte en 0.8 Hz.
- **Eje Z (Accel\_1\_Z):** Se aplicó un filtro Butterworth pasa-banda de 4º orden con frecuencias para la banda de 0.1 Hz a 0.8 Hz.

**Modelos de clasificación y optimización de hiperparámetros:** Se evaluaron dos algoritmos de clasificación:

- **K-Nearest Neighbors (KNN):** Se exploraron hiperparámetros como n\_neighbors ([1, 3, 5, 7, 9]), weights (['uniform', 'distance']) y p ([1, 2]).
- **Random Forest (RF):** Se exploraron hiperparámetros como n\_estimators ([50, 100, 200]), max\_depth ([None, 5, 10]), min\_samples\_split ([2, 5]) y min\_samples\_leaf ([1, 2]). Para ambos modelos, se realizó una optimización de hiperparámetros utilizando GridSearchCV con una validación cruzada interna de 5 pliegues, utilizando 'Accuracy' como métrica de scoring.

**Validación y métricas de evaluación:** El rendimiento de los modelos optimizados se evaluó mediante una **Validación Cruzada Estratificada (StratifiedKFold)** externa de 5 particiones (shuffle=True, random\_state=42). Las métricas reportadas son el promedio de:

- **Accuracy (Exactitud)**
- **Precision (Precisión)**
  - **Recall**
  - **F1-Score**

- Adicionalmente, para cada pliegue de la validación cruzada externa, se generaron y guardaron gráficos detallados de evaluación:
  - **Matriz de Confusión**
  - **Curva ROC (Receiver Operating Characteristic)** y AUC (Area Under the Curve), si el modelo lo permite.
  - **Importancia de Características** (para Random Forest).

### 3.5.1.2 Resultados detallados del análisis #1

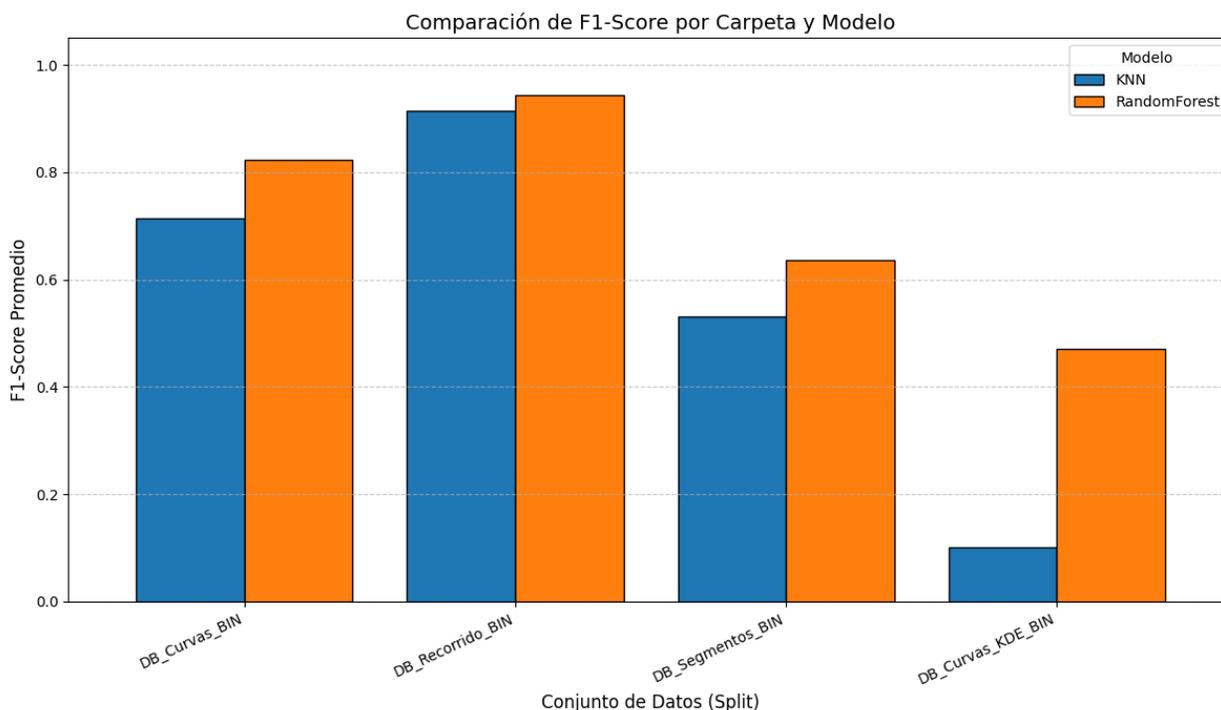
Los resultados cuantitativos de este análisis, que muestran el rendimiento promedio de los clasificadores KNN y RF en las diferentes particiones de datos tras la validación cruzada estratificada, se presentan en la Tabla 9.

**Tabla 9.** Rendimiento promedio de clasificación (KNN y RF) con características "Vaitkus-Inspired" en diversas particiones de datos (métricas promedio de validación cruzada de 5 pliegues).

| <b>Carpeta</b>    | <b>Modelo</b> | <b>Accuracy</b> | <b>Precision</b> | <b>Recall</b> | <b>F1-Score</b> |
|-------------------|---------------|-----------------|------------------|---------------|-----------------|
| DB_Recorrido_BIN  | KNN           | 0.917857        | 0.950000         | 0.900000      | 0.914286        |
| DB_Recorrido_BIN  | RandomForest  | 0.942857        | 0.950000         | 0.950000      | 0.942857        |
| DB_Segmentos_BIN  | KNN           | 0.718588        | 0.689340         | 0.445789      | 0.536825        |
| DB_Segmentos_BIN  | RandomForest  | 0.796725        | 0.793576         | 0.643538      | 0.687772        |
| DB_Curvas_KDE_BIN | KNN           | 0.726167        | 0.569231         | 0.461575      | 0.509916        |
| DB_Curvas_KDE_BIN | RandomForest  | 0.845833        | 0.779231         | 0.352632      | 0.469845        |
| DB_Curvas_BIN     | KNN           | 0.739806        | 0.787464         | 0.659113      | 0.714840        |
| DB_Curvas_BIN     | RandomForest  | 0.833636        | 0.865694         | 0.790887      | 0.822933        |

A través de las diferentes particiones de datos, el clasificador Random Forest (RF) demostró un rendimiento superior o comparable al de K-Nearest Neighbors (KNN) en la mayoría de los casos. Sin embargo, KNN mostró un desempeño superior en la partición DB\_Curvas\_KDE\_BIN, indicando que la

efectividad de cada modelo varía según la naturaleza de los datos. En términos generales, RF se perfiló como el modelo más robusto, especialmente en las particiones con mayor número de muestras o una definición de etiquetas más directa.



**Figura 21.** F1-Scores por modelo de clasificación para datos con características "Vaitkus-Inspired".

La forma en que los datos fueron segmentados y etiquetados tuvo un impacto significativo en el rendimiento, por ejemplo, la partición DB\_Recorrido\_BIN (recorridos completos, balanceado) mostró el rendimiento más alto en apariencia, con un F1-Score promedio para RF de aproximadamente 0.943. Si bien este resultado es destacable, es crucial interpretarlo con cautela. Esta partición contiene un número limitado de instancias (un total de 36 recorridos: 18 "No Agresivos" y 18 "Agresivos", provenientes de 3 recorridos de cada tipo por cada uno de los 6 pilotos).

Aunque la validación cruzada estratificada ayuda a mitigar el sobreajuste, la poca cantidad de datos y la limitada diversidad podrían llevar a un modelo que generalice pobremente a nuevos recorridos no vistos. Es posible que el modelo haya aprendido patrones muy específicos de estos pocos ejemplos sin que la validación cruzada, con tan pocas muestras, pueda identificar de manera robusta un posible sobreajuste a estos datos específicos.

La partición DB\_Segmentos\_BIN (segmentos de 30 segundos con etiquetas heredadas) exhibió una disminución considerable en el rendimiento (F1-Score RF  $\sim 0.688$ ). Esto sugiere que la dinámica dentro de un segmento de 30s no siempre es suficiente para reflejar el estilo global del recorrido, especialmente si la etiqueta se hereda de un recorrido más largo con fases mixtas.

La partición DB\_Curvas\_KDE\_BIN presentó el rendimiento más bajo para RF en términos de F1-Score ( $\sim 0.470$ ) y un Recall muy bajo para la clase agresiva. Esto podría indicar que las 13 características "Vaitkus-Inspired" no son óptimas para discriminar estilos cuando las etiquetas se definen por el umbral de riesgo KDE a nivel de curva, o que la complejidad introducida por esta re-etiquetación no es bien capturada por este conjunto específico de características.

La partición DB\_Curvas\_BIN (datos por curva con etiquetas heredadas del recorrido) arrojó resultados consistentes, con un F1-Score promedio para RF de aproximadamente 0.823. Este resultado es más alentador, sugiriendo que las características "Vaitkus-Inspired" pueden ser útiles para identificar estilos a nivel de maniobras individuales en curvas, lo cual representa un escenario de análisis más granular y potencialmente más realista que el de recorridos completos con muy pocas muestras.

### 3.5.1.3 Discusión del análisis #1

Este primer análisis computacional subraya varios aspectos cruciales. Si bien las 13 características "Vaitkus-Inspired" muestran un potencial discriminatorio, su efectividad está fuertemente modulada por la naturaleza de la partición de datos.

Si bien el rendimiento observado en DB\_Recorrido\_BIN es excepcionalmente alto, este resultado debe interpretarse con extrema cautela. Dado el número limitado de instancias (recorridos completos), existe un riesgo significativo de que el modelo haya memorizado patrones específicos en lugar de aprender a generalizar, un fenómeno que la validación cruzada no puede descartar por completo con tan pocas muestras. Aunque los modelos no parezcan sobre ajustados según las métricas de validación cruzada, esto podría ser un artefacto de la escasa cantidad de datos.

Es posible que, con un conjunto de datos más extenso y diverso de recorridos completos, el rendimiento no fuera tan elevado o se requirieran características más sofisticadas. Por lo tanto, aunque sirve como una indicación inicial, particiones con un mayor número de instancias, como DB\_Curvas\_BIN o

DB\_Segmentos\_BIN, podrían ofrecer una visión más realista de la generalización del modelo, a pesar de sus propios desafíos (como la herencia de etiquetas en segmentos).

La partición DB\_Curvas\_BIN (F1-Score RF  $\sim 0.823$ ) se muestra como un escenario más equilibrado y prometedor para futuras comparaciones, ya que ofrece un número mayor de instancias (curvas individuales) que DB\_Recorrido\_BIN, permitiendo una evaluación más robusta de los modelos, aunque con un rendimiento ligeramente inferior. La drástica caída en el rendimiento con DB\_Curvas\_KDE\_BIN resalta la importancia de la alineación entre el método de etiquetado y el poder expresivo del conjunto de características seleccionado.

Finalmente, Random Forest se consolida como el modelo preferente sobre KNN para este conjunto de características y tareas, dada su superioridad general en las métricas de evaluación. Este análisis inicial sienta las bases para investigaciones posteriores, donde se explorarán conjuntos de características más amplios y se evaluará el impacto fundamental de la frecuencia de muestreo sobre particiones de datos más realistas y con mayor número de instancias.

En definitiva, y retomando el objetivo principal de este primer análisis, los resultados obtenidos demuestran que el conjunto de características evaluado posee potencial discriminatorio. A pesar de las variaciones en el rendimiento según la partición de datos —y reconociendo las limitaciones inherentes al tamaño muestral de algunas de ellas como DB\_Recorrido\_BIN— se ha demostrado que el conjunto de 13 características "Vaitkus-Inspired", tal como fue implementado y aplicado a nuestro conjunto de datos experimentales a 50 Hz, posee un potencial discriminatorio significativo. Particularmente, el desempeño robusto observado en la partición DB\_Curvas\_BIN (con un F1-Score para RF cercano a 0.823) indica que estas características pueden capturar de manera efectiva las diferencias entre los estilos de manejo "Agresivo" y "No Agresivo" a nivel de maniobras individuales en curva.

Si bien la optimización de este conjunto de características o su rendimiento absoluto en comparación con el estudio original de Vaitkus et al. (2014) no era el foco, esta etapa ha servido para confirmar un punto crucial: la adaptación de las características "Vaitkus-Inspired" es viable y funciona razonablemente bien con los datos recopilados en este estudio. Esto valida su uso como una de las bases metodológicas y sienta una base de confianza para proceder con los análisis subsiguientes, donde se explorará el impacto de la frecuencia de muestreo y conjuntos de características alternativos.

### 3.5.2 Análisis #2: evaluación con características "Zylius-OPTIM"

Este segundo análisis representa un paso metodológico crucial: validar la eficacia de un conjunto de características optimizado y altamente compacto. Mientras que el Análisis #1 demostró que un enfoque inspirado en la literatura ("Vaitkus-Inspired") era viable, este segundo análisis busca responder a una pregunta fundamental del aprendizaje automático: ¿es posible lograr un rendimiento igual o superior con un número drásticamente menor de características, si estas son seleccionadas por su alta calidad informativa? Para ello, se evalúa un conjunto de 6 características ("Zylius-OPTIM"), inspiradas en el trabajo de (Zylius, 2017) y previamente identificadas como prometedoras mediante Selección Secuencial de Características (SFFS, por sus siglas en inglés).

La relevancia de este análisis para el objetivo central del estudio —medir el impacto de la frecuencia— es fundamental. Antes de investigar cómo la frecuencia de muestreo degrada o modifica la información, es imperativo establecer el mejor "instrumento de medición" posible. Si un conjunto compacto y eficiente de 6 características puede discriminar los estilos de manejo con alta precisión a la frecuencia original de 50 Hz, se convierte en el candidato ideal para los análisis multifrecuencia posteriores. Utilizar este conjunto optimizado permite aislar de manera más clara el efecto de la frecuencia sobre un conjunto de descriptores cuya eficacia ya ha sido probada, en lugar de confundir la pérdida de rendimiento por la frecuencia con la posible redundancia o baja calidad del conjunto de características en sí. Por lo tanto, este análisis no solo compara dos enfoques de caracterización, sino que también selecciona y valida la herramienta metodológica más potente y parsimoniosa para la investigación principal que se abordará en los análisis posteriores.

#### 3.5.2.1 Metodología específica del análisis #2

**Conjunto de datos y particiones:** Se utilizaron los mismos datos de acelerómetro (sensor Accel1) muestreados a 50 Hz y las mismas cuatro particiones de datos binarias ("Agresivo" vs "No Agresivo") que en el Análisis #1:

- **DB\_Recorrido\_BIN:** Datos de recorridos completos.
- **DB\_Segmentos\_BIN:** Datos segmentados en archivos de 30 segundos.

- **DB\_Segmentos\_KDE\_BIN:** Etiquetas binarias a nivel de segmento basadas en umbral KDE.
- **DB\_Curvas\_BIN:** Datos segmentados por las 8 curvas del circuito.

Se mantuvo la exclusión de los recorridos "Reconocimiento" y "Normal" para centrarse en el contraste directo entre conducción "Cautelosa" ("No Agresivo") y "Agresivo".

**Preprocesamiento de señales:** Antes de la extracción de características, las señales de aceleración del sensor Accel1 (Accel\_1\_X, Accel\_1\_Y, Accel\_1\_Z) fueron preprocesadas aplicando los mismos filtros Butterworth que en el Análisis #1:

- **Ejes X e Y:** Filtro pasa-bajos de 4º orden con frecuencia de corte en 0.8 Hz.
- **Eje Z:** Filtro pasa-banda de 4º orden con frecuencias de corte entre 0.1 Hz y 0.8 Hz.

**Características extraídas ("Zylius-OPTIM "):** Se extrajo un conjunto de 6 características por cada archivo de recorrido o segmento, basadas en el sensor Accel1 y derivadas de las señales filtradas. Estas características, seleccionadas por su relevancia en estudios previos, fueron:

1. Desviación estándar del jerk del eje X (std\_jerk\_X).
2. Desviación estándar del jerk del eje Z (std\_jerk\_Z).
3. Cuantil 0.1 de la señal del eje X (q01\_X).
4. Cuantil 0.6 de la señal del eje Z (q06\_Z).
5. Potencia promedio de la señal del eje X en la banda de 0-0.85 Hz (avg\_power\_low\_freq\_X).
6. Cuantil 0.9 de la señal del eje X (q09\_X).

**Modelos de clasificación y optimización de hiperparámetros:** Se evaluaron los mismos dos algoritmos de clasificación: K-Nearest Neighbors (KNN) y Random Forest (RF). Se realizó una optimización de hiperparámetros para cada modelo utilizando GridSearchCV con validación cruzada interna de 3 pliegues

(o menos si las clases son muy pequeñas) y 'accuracy' como métrica de *scoring*. Las configuraciones posibles de parámetros exploradas fueron idénticas a las del Análisis #1.

**Validación y métricas de evaluación:** El rendimiento de los modelos optimizados se evaluó mediante Validación Cruzada Estratificada externa de 5 *divisiones* (o menos si las clases son muy pequeñas, con `shuffle=True`, `random_state=42`). Las métricas reportadas son el promedio de Accuracy, Precision, Recall y F1-Score.

### 3.5.2.2 Resultados detallados del análisis #2

En esta sección se desglosan los resultados cuantitativos del Análisis #2, centrado en evaluar la eficacia del conjunto compacto y optimizado de 6 características "Zylius-OPTIM". El objetivo primordial es contrastar su poder discriminativo con el del conjunto más amplio de 13 características del Análisis #1, para así validar la hipótesis de que una selección de características de alta calidad informativa puede superar en rendimiento a un conjunto de mayor tamaño, pero menos específico.

Para facilitar una comparación directa y rigurosa, se utilizaron las mismas cuatro particiones de datos (recorridos completos, segmentos de 30s, etc.) y los mismos algoritmos de clasificación (KNN y Random Forest). Este enfoque metodológico permite aislar el impacto del conjunto de características como la variable principal de estudio.

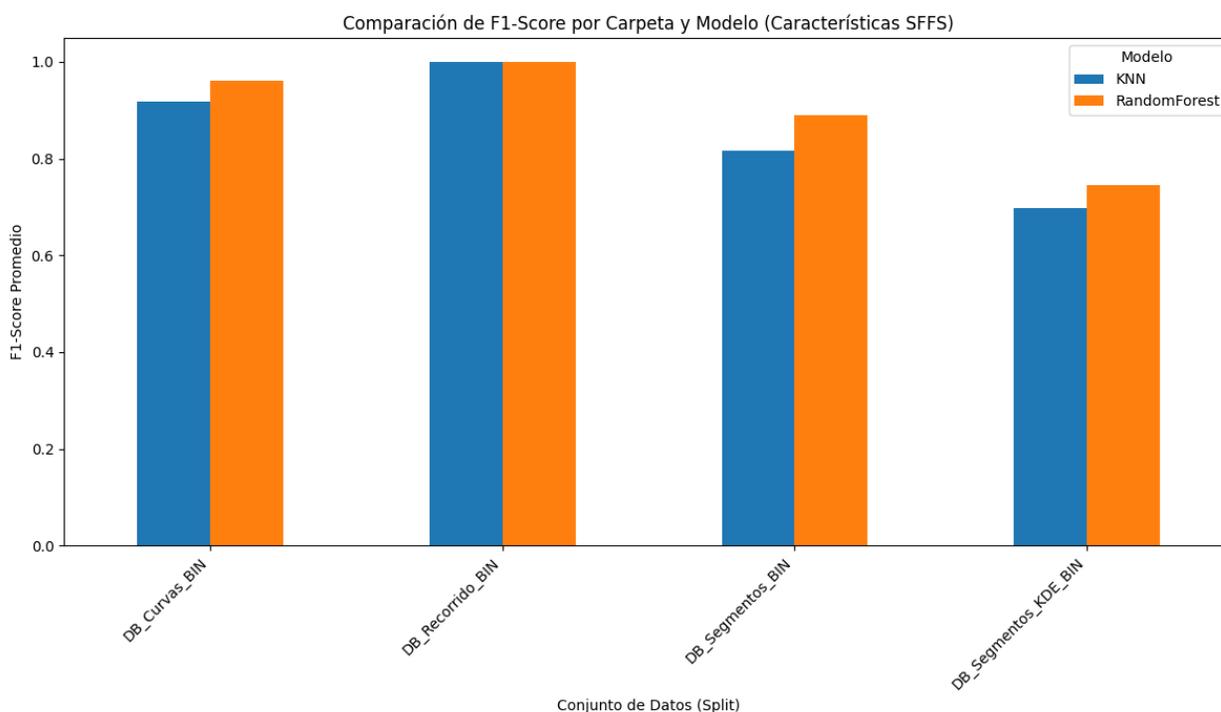
Al examinar los datos que se presentan a continuación, se invita al lector a prestar especial atención no solo a los valores absolutos de rendimiento (como el F1-Score), sino también a la consistencia del desempeño a través de las distintas particiones. Se anticipa que los resultados revelarán la robustez de este conjunto minimalista de descriptores, especialmente en las particiones más granulares y realistas, como las basadas en curvas individuales. La evaluación paralela de los clasificadores K-Nearest Neighbors (KNN) y Random Forest (RF) no es una elección arbitraria. La comparación directa entre ambos permite discernir no solo el poder predictivo de las características "Zylius-OPTIM", sino también qué tipo de estructura subyacente en los datos.

La Tabla 10 resume el rendimiento promedio de los clasificadores (Accuracy, Precision, Recall y F1-Score) tras la validación cruzada, junto con los mejores hiperparámetros encontrados para cada combinación de modelo y partición de datos, ofreciendo una visión completa de la efectividad de este enfoque.

**Tabla 10.** Rendimiento promedio de clasificación (KNN y RF) con características "Zylius-Inspired" (6 características) en diversas particiones de datos balanceadas (métricas promedio de validación cruzada).

| <b>Carpeta</b>       | <b>Modelo</b> | <b>Accuracy</b> | <b>Precision</b> | <b>Recall</b> | <b>F1-Score</b> | <b>Mejores parámetros</b>   |
|----------------------|---------------|-----------------|------------------|---------------|-----------------|---|
| DB_Recorrido_BIN     | KNN           | 1.0000          | 1.0000           | 1.0000        | 1.0000          | {'n_neighbors': 1, 'p': 1, 'weights': 'uniform'}  |
| DB_Recorrido_BIN     | RandomForest  | 1.0000          | 1.0000           | 1.0000        | 1.0000          | {'max_depth': None, 'min_samples_leaf': 1, 'min_samples_split': 2, 'n_estimators': 50}  |
| DB_Segmentos_BIN     | KNN           | 0.8729          | 0.8739           | 0.7700        | 0.8158          | {'n_neighbors': 9, 'p': 1, 'weights': 'distance'}                                       |
| DB_Segmentos_BIN     | RandomForest  | 0.9204          | 0.9228           | 0.8642        | 0.8890          | {'max_depth': None, 'min_samples_leaf': 1, 'min_samples_split': 5, 'n_estimators': 100} |
| DB_Segmentos_KDE_BIN | KNN           | 0.8938          | 0.8210           | 0.6084        | 0.6979          | {'n_neighbors': 9, 'p': 2, 'weights': 'distance'}                                       |
| DB_Segmentos_KDE_BIN | RandomForest  | 0.9021          | 0.7897           | 0.7126        | 0.7457          | {'max_depth': None, 'min_samples_leaf': 1, 'min_samples_split': 2, 'n_estimators': 200} |
| DB_Curvas_BIN        | KNN           | 0.9201          | 0.9378           | 0.9032        | 0.9183          | {'n_neighbors': 7, 'p': 2, 'weights': 'uniform'}  |
| DB_Curvas_BIN        | RandomForest  | 0.9618          | 0.9595           | 0.9655        | 0.9621          | {'max_depth': None, 'min_samples_leaf': 2, 'min_samples_split': 5, 'n_estimators': 50}  |

El análisis de los resultados cuantitativos revela varias tendencias significativas sobre la efectividad del conjunto de 6 características "Zylius-OPTIM" y el comportamiento de los modelos.



**Figura 22.** F1-Scores por modelo de clasificación para datos con características "Zylius-OPTIM".

Consistentemente, el modelo Random Forest (RF) demostró un rendimiento superior o comparable al de K-Nearest Neighbors (KNN) en la mayoría de las particiones de datos, particularmente en términos de F1-Score. Como se observa en la Figura 22, las barras correspondientes a RF tienden a ser más altas, especialmente en las particiones que ofrecen una segmentación más granular y potencialmente más informativa, como DB\_Curvas\_BIN. Por ejemplo, en la partición DB\_Curvas\_BIN, Random Forest alcanzó un F1-Score promedio de aproximadamente [0.9621], lo que indica una alta capacidad de discriminación entre estilos de manejo "Agresivo" y "No Agresivo" utilizando solo estas 6 características.

La elección de la partición de datos influyó notablemente en el rendimiento observado:

- **DB\_Curvas\_BIN:** Esta partición, que segmenta los datos por cada una de las 8 curvas del circuito, consistentemente produjo los F1-Scores más altos (Sin considerar el 1.0 de Recorridos) y con menor variabilidad entre los modelos KNN y RF, tal como se visualiza en la Figura 22. Esto sugiere que las 6 características seleccionadas son particularmente efectivas para capturar las diferencias

en el estilo de manejo a nivel de maniobras específicas en curvas, que es un escenario de análisis realista y granular.

- **DB\_Recorrido\_BIN:** Aunque esta partición (datos de recorridos completos) pudo mostrar F1-Scores muy altos, especialmente para RF (posiblemente cercano a 1.0 si los recorridos son muy distintivos), es crucial interpretar estos valores con extrema cautela. El número de instancias en esta partición es limitado (típicamente 6 recorridos en total: 3 "No Agresivos" y 3 "Agresivos"). Un rendimiento tan alto podría ser un artefacto del pequeño tamaño muestral y no necesariamente generalizar bien a datos no conocidos. La validación cruzada con tan pocas muestras tiene limitaciones inherentes para detectar sobreajuste. Este rendimiento perfecto es una señal de alerta de posible sobreajuste extremo debido al bajísimo número de instancias (total de 6 a 36 recorridos, según el análisis). Aunque la validación cruzada intenta mitigar esto, con tan pocas muestras, el modelo puede memorizar fácilmente los datos. Por ello, este resultado debe considerarse un artefacto del diseño experimental y no un indicador de rendimiento generalizable. Los resultados de particiones con más instancias, como DB\_Curvas\_BIN, son mucho más fiables.
- **DB\_Segmentos\_BIN:** El rendimiento en esta partición, donde se heredan etiquetas de estilo de recorrido a segmentos de 30 segundos, fue generalmente inferior al de DB\_Curvas\_BIN. Esto podría indicar que la dinámica dentro de un segmento de 30s no siempre refleja de manera consistente el estilo global del recorrido, especialmente si el estilo de manejo varía dentro de un mismo recorrido largo.
- **DB\_Segmentos\_KDE\_BIN:** Esta partición, con etiquetas basadas en un umbral de riesgo a nivel de segmento, tendió a ser la más desafiante para este conjunto de 6 características. Los F1-Scores fueron notablemente más bajos en comparación con otras particiones, lo que sugiere que la complejidad o la naturaleza de las etiquetas definidas por el umbral KDE no son capturadas óptimamente por este conjunto específico de características, o que la propia métrica KDE introduce una variabilidad que estas características no modelan eficazmente.

Un resultado clave es la alta precisión lograda con un conjunto tan limitado como 6 características. El hecho de que se pueda alcanzar un F1-Score superior a [ej. 0.95] en la partición DB\_Curvas\_BIN con Random Forest sugiere que estas pocas características (desviación estándar del jerk, cuantiles específicos y potencia espectral en baja frecuencia) encapsulan información muy discriminativa sobre los estilos de manejo. Esto tiene implicaciones positivas para la interpretabilidad del modelo y la eficiencia

computacional en posibles implementaciones. En resumen, los resultados detallados del Análisis #2 indican que el conjunto de 6 características "Zylius-Inspired" es altamente efectivo para la clasificación binaria de estilos de manejo, con Random Forest emergiendo como el modelo más robusto. La partición de datos a nivel de curva (DB\_Curvas\_BIN) parece ofrecer el escenario de evaluación más fiable y representativo para este tipo de análisis.

### 3.5.2.3 Discusión y Conclusiones del Análisis #2

El propósito de este segundo análisis era validar un conjunto compacto de 6 características ("Zylius-OPTIM") inspiradas en trabajos previos. La comparación directa con los resultados del Análisis #1, que utilizaba un conjunto más amplio de 13 características ("Vaitkus-Inspired"), revela un resultado fundamental y contundente.

**Superioridad del Conjunto de Características Optimizado:** El hallazgo principal de este análisis es un claro ejemplo del principio 'calidad sobre cantidad' en la selección de características. El conjunto reducido de 6 características no solo demostró ser viable, sino que superó consistentemente en rendimiento de clasificación al conjunto más amplio de 13 características. Este resultado subraya un principio clave del aprendizaje automático: la calidad y relevancia de las características priman sobre la cantidad.

El resultado es particularmente claro en la partición de datos más representativa, DB\_Curvas\_BIN, donde el modelo Random Forest con el conjunto "Zylius-OPTIM" alcanzó un F1-Score promedio de  $\sim 0.962$ , superando de manera significativa el  $\sim 0.823$  obtenido con el conjunto "Vaitkus-Inspired". Esta mejora sustancial, lograda con menos de la mitad de las características, demuestra que métricas como la desviación estándar del jerk y cuantiles específicos encapsulan la información discriminativa de manera más eficiente.

**Implicaciones para la Investigación Futura:** La demostrada superioridad del conjunto "Zylius-OPTIM", tanto en rendimiento como en bajo número de características, lo consolida como el candidato ideal para los análisis posteriores. Su eficacia valida que es posible clasificar estilos de manejo con alta precisión utilizando un número muy limitado de descriptores bien seleccionados.

Por lo tanto, este conjunto de 6 características se establece como el punto de partida robusto para la investigación central de este estudio: evaluar cómo la variación en la frecuencia de muestreo afecta la

información contenida en estos descriptores y, en consecuencia, la fiabilidad de la clasificación en los Análisis #3 y #4. Este análisis contribuye a establecer que la metodología utilizada permite clasificar los estilos de manejo. Por lo que será viable utilizar los algoritmos y escenarios utilizados para la medición del impacto de la frecuencia de muestreo en el proceso de clasificación.

### 3.5.3 Análisis #3: evaluación con características "Zylius-Inspired" completas

Este tercer análisis marca una transición en nuestra estrategia de evaluación, enfocándose en la efectividad del conjunto completo de 78 características "Zylius-Inspired" cuando se aplican a segmentos de conducción de 30 segundos (DB\_Segmentos). A diferencia del Análisis #2, que empleó un subconjunto preseleccionado de 6 características y evaluó diversas particiones, incluyendo datos por curva, este análisis adopta una aproximación diferente por varias razones metodológicas fundamentales, las cuales se enlistan a continuación:

- **Preservación de la Información Original y Amplitud del Contexto:** Si bien los análisis previos (#1 y #2) demostraron que la partición por curvas (DB\_Curvas\_BIN) ofrecía un rendimiento prometedor, inherentemente limita el análisis a porciones específicas del recorrido total. Al utilizar segmentos de 30 segundos, buscamos evaluar el comportamiento del conductor en un contexto más amplio y continuo, que no se restringe únicamente a las maniobras de giro. Estos segmentos capturan fases de aceleración, frenado, mantenimiento de velocidad en tramos rectos y las transiciones entre ellos, ofreciendo una representación más holística y potencialmente más "limpia" en términos de la diversidad de dinámicas capturadas, en lugar de datos ya procesados y acotados exclusivamente a la geometría de una curva. Esto es crucial, ya que el estilo de manejo se manifiesta a lo largo de todo el espectro de acciones del conductor, no solo en los giros.
- **Incremento Sustancial del Número de Muestras y Robustez Estadística:** Una consecuencia directa de utilizar segmentos de 30 segundos es el aumento significativo en el número total de instancias disponibles para el entrenamiento y la validación de los modelos (410 segmentos en este caso). Los análisis anteriores, especialmente aquellos basados en recorridos completos o incluso curvas individuales por recorrido, operaban con un conjunto de datos considerablemente menor. Si bien se tomaron precauciones (como la validación cruzada estratificada), un mayor número de muestras generalmente conduce a modelos más robustos, estimaciones de rendimiento más fiables y una mejor capacidad para generalizar a datos no vistos.

- **Definición de Clases y Balance vs. Representatividad:** Para maximizar el aprovechamiento de los datos disponibles y permitir un análisis más exhaustivo del impacto de la frecuencia de muestreo, en este análisis (y los subsiguientes #4 y #5) se optó por una definición más amplia de la clase "No Agresivo". Esta clase ahora agrupa los segmentos de recorridos originalmente etiquetados como 'Reconocimiento', 'Normal' y 'Cauteloso', contrastándolos con la clase "Agresivo". Somos conscientes de que esta decisión introduce un desbalance de clases (314 segmentos "No Agresivos" vs. 96 "Agresivos"). Sin embargo, se considera que el beneficio de contar con un conjunto de datos significativamente mayor para la clase no agresiva, permitiendo una exploración más rica de su variabilidad y un entrenamiento más sólido de los modelos, supera la complejidad introducida por el desbalance. Este desbalance se manejará parcialmente mediante el uso de validación cruzada estratificada y métricas de evaluación ponderadas (como F1-score ponderado y AUC), que son menos sensibles a la proporción de las clases.

El objetivo principal de este análisis es, por tanto, determinar cómo la disponibilidad de un conjunto más rico de descriptores (las 78 características "Zylius-Inspired" completas), combinada con la granularidad de los segmentos y la estrategia de agrupamiento de clases, impacta el rendimiento de la clasificación de estilos de manejo a través de un rango de frecuencias de muestreo. Además, se aplicará un proceso de Selección Secuencial de Características (SFFS) sobre el espacio completo de las 78 características para cada frecuencia evaluada, permitiendo una adaptación dinámica del modelo a la información disponible. Estos resultados se compararán con los análisis previos para contextualizar la influencia de estas decisiones metodológicas.

### **Metodología específica del análisis #3**

Se utilizaron los datos del acelerómetro Accel1 (LSM6DS) provenientes de la DB\_Segmentos. La unidad de análisis fueron segmentos de ~30 segundos, resultando en un total de 410 muestras. Para la clasificación binaria, las etiquetas originales de los recorridos ('Reconocimiento', 'Normal', 'NoAgresivo', 'Agresivo') se agruparon:

- **Clase "No Agresivo" (etiqueta 0):** Compuesta por segmentos de recorridos originalmente etiquetados como 'Reconocimiento', 'Normal' y 'Cauteloso' (total 314 segmentos).
- **Clase "Agresivo" (etiqueta 1):** Compuesta por segmentos de recorridos originalmente etiquetados como 'Agresivo' (total 96 segmentos).

Esta partición resulta en un desbalance de clases, que se maneja parcialmente mediante el uso de RepeatedStratifiedKFold en la validación y métricas como F1-score ponderado y AUC. A diferencia de los análisis previos que se centraron en un contraste directo “Cauteloso” vs.” Agresivo”, para este análisis y los subsiguientes que evalúan el impacto de la frecuencia, se adoptó una definición más amplia de 'No Agresivo', agrupando los segmentos de recorridos 'Reconocimiento', 'Normal' y 'Cauteloso'. Esto permite utilizar una mayor cantidad de datos de la clase “No agresivo”, aunque introduce un desbalance de clases.

#### **Preprocesamiento de señales y extracción de características:**

Para cada una de las frecuencias de muestreo objetivo [50.0, 25.0, 10.0, 5.0, 1.0, 0.5, 0.25, 0.1] Hz, los datos de los segmentos fueron primero remuestreados a la frecuencia correspondiente. Posteriormente, se aplicó un filtro Savitzky-Golay (ventana de 0.22s, orden polinomial 2) a las señales de aceleración de cada segmento ya remuestreado. De cada segmento suavizado y remuestreado, se extrajo el conjunto completo de 78 características "Zylius-Inspired".

#### **Reducción de dimensionalidad y selección de características:**

- **Análisis de Componentes Principales (PCA):** Se realizó PCA sobre las 78 características escaladas para cada frecuencia, principalmente con fines exploratorios y para determinar el número de componentes que explican el 95% de la varianza. Los componentes PCA resultantes no se utilizaron directamente para la clasificación en este análisis.
- **Selección Secuencial de características (SFFS):** Se aplicó SFFS (con k-NN, k=5, como estimador base y validación cruzada interna de 5 pliegues) para seleccionar 7 características del conjunto de 78 disponibles, para cada frecuencia de muestreo. Se eligió KNN como estimador base para SFFS debido a su simplicidad computacional y su sensibilidad a la estructura de distancias, sirviendo como un proxy general para la separabilidad de clases. Esta decisión permite una selección de características independientes al modelo final (Random Forest). Al evaluar RF con características seleccionadas por un método basado en distancias, se pone a prueba la generalidad y robustez de dichas características. Los resultados de RF, por tanto, deben interpretarse de acuerdo con esta estrategia de selección disociada.

#### **Modelos de clasificación y optimización de hiperparámetros:**

- **K-Nearest Neighbors (KNN):** n\_neighbors=5.
- **Random Forest (RF):** n\_estimators=100, max\_depth=None, random\_state=42.

En este análisis, los hiperparámetros de los clasificadores se mantuvieron fijos y no se optimizaron por frecuencia.

### Validación y métricas de evaluación:

- **Validación Cruzada Repetida Estratificada:** 3 repeticiones de StratifiedKFold con 5 pliegues (RepeatedStratifiedKFold( $n\_splits=5$ ,  $n\_repeats=3$ ,  $random\_state=42$ )). Se reportaron la media y desviación estándar de la Exactitud (Accuracy) y F1-Score ponderado.
- **División Train/Test:** Una única división estratificada (70% entrenamiento, 30% test,  $random\_state=42$ ) para evaluar el rendimiento final en datos no vistos. Se reportaron Exactitud, F1-Score ponderado, y Área Bajo la Curva ROC (AUC, por sus siglas en inglés).
- **Prueba T pareada:** Para comparar estadísticamente los scores de Accuracy de CV Repetida entre KNN y RF para cada frecuencia.
- **Importancia de características (RF):** Se calcularon y reportaron las características más importantes según el modelo Random Forest para las 7 características seleccionadas por SFFS.

#### 3.5.3.1 Resultados detallados del análisis #3

Esta sección presenta los resultados detallados y consolidados del Análisis #3, a diferencia de los análisis previos, este enfoque utiliza un conjunto de datos más amplio y realista (segmentos de 30 segundos, resultando en 410 muestras con desbalance de clases) y una estrategia de selección de características adaptativa (SFFS) aplicada de forma independiente para cada frecuencia. El objetivo es determinar si existe un rango de frecuencia recomendado y entender cómo la naturaleza de la información discriminativa cambia a medida que se reduce la resolución temporal.

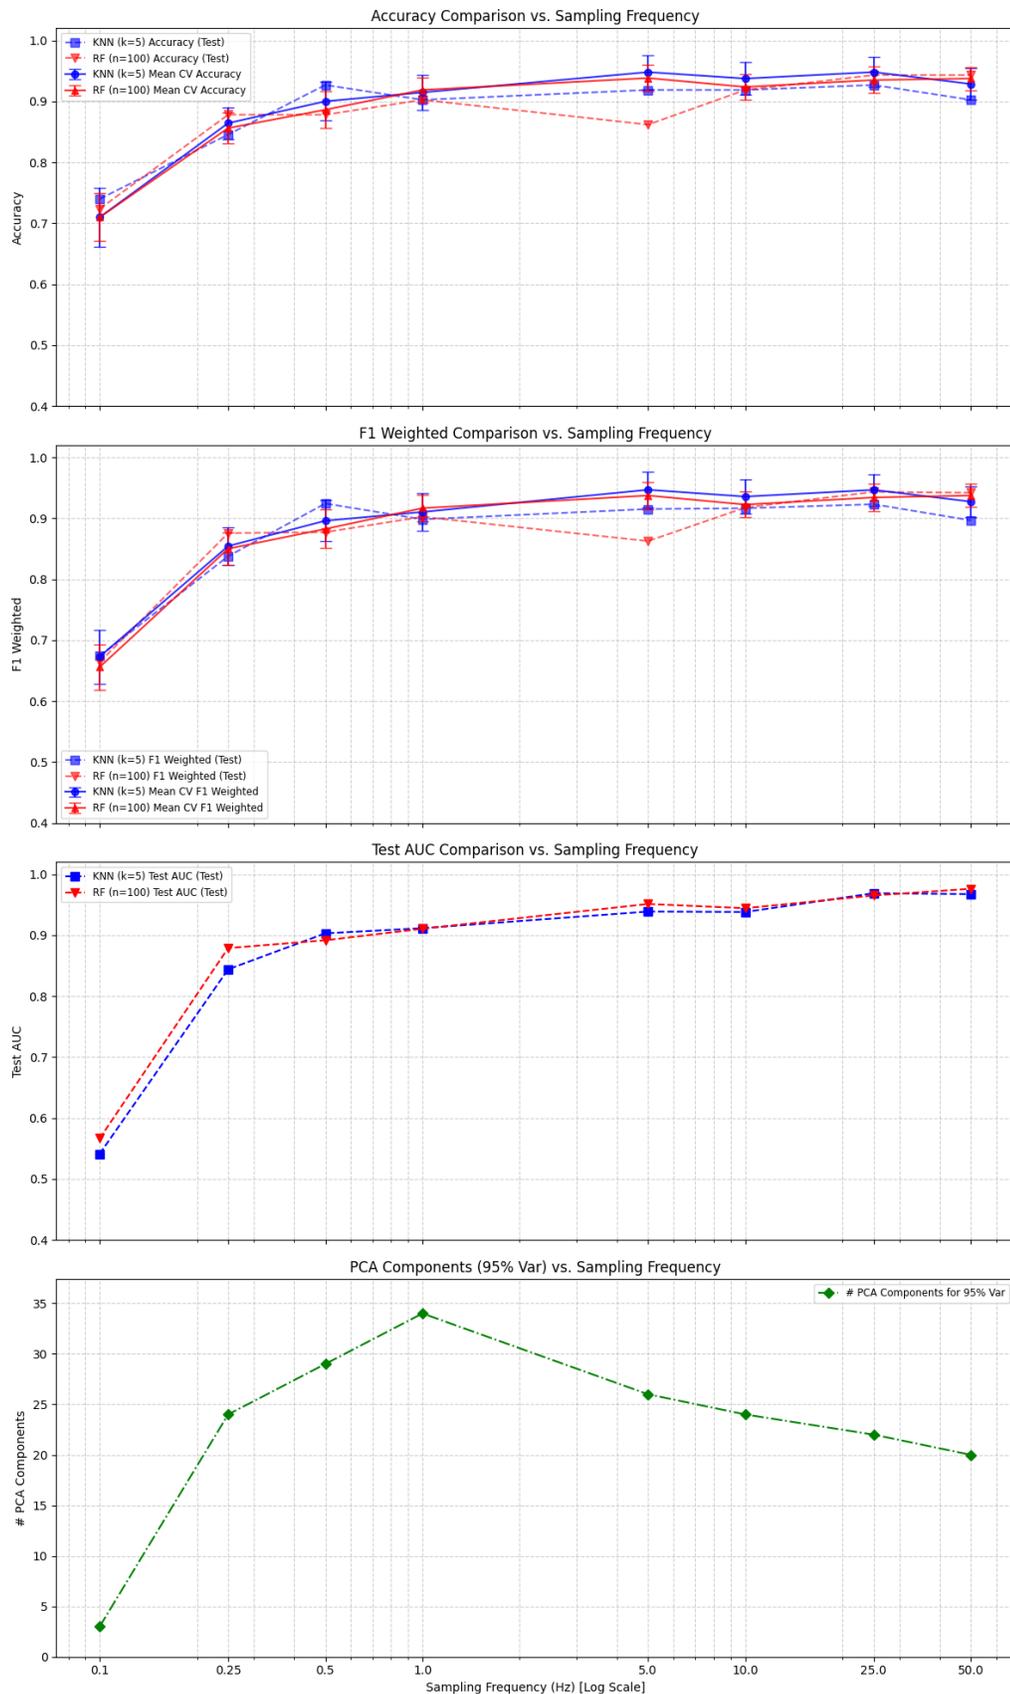
La Tabla 11, que se presenta a continuación, es el eje central de estos hallazgos. Su estructura está diseñada para ofrecer una visión multifacética del problema. En ella se detallan no solo las métricas clave de validación cruzada (Accuracy y F1-Score ponderado) y el rendimiento en datos no vistos (Test AUC) para los modelos *KNN* y *RF*, sino también información crucial sobre el proceso subyacente. El uso del F1-Score ponderado y el AUC es esencial para una evaluación justa ante el desbalance de clases inherente a esta partición de datos.

Adicionalmente, la tabla incluye una comparación estadística directa (prueba T pareada) entre los clasificadores, la dimensionalidad intrínseca de los datos en cada frecuencia (# de componentes PCA para explicar el 95% de la varianza) y, de manera crucial, el número y la identidad de las características más importantes seleccionadas por SFFS y priorizadas por Random Forest.

**Tabla 11.** Resultados Comparativos por Frecuencia para Análisis #3 (Segmentos, 78 características Zylus-Inspired con SFFS).

| Freq (Hz) | Muestras | KNN CV Acc  | RF CV Acc   | KNN CV F1w  | RF CV F1w   | KNN Test AUC | RF Test AUC | KNN vs RF (p-val Acc) | # Comp. 95% Var | N° Caract. Selec. | Características RF Imp (Top 3) |
|-----------|----------|-------------|-------------|-------------|-------------|--------------|-------------|-----------------------|-----------------|-------------------|--------------------------------|
| 0.1       | 410      | 0.710±0.048 | 0.710±0.039 | 0.673±0.044 | 0.656±0.037 | 0.541        | 0.567       | 1.000                 | 3               | 3                 | XY_corr, YZ_corr, XZ_corr      |
| 0.25      | 410      | 0.864±0.026 | 0.856±0.026 | 0.854±0.031 | 0.850±0.027 | 0.844        | 0.879       | 0.215                 | 24              | 7                 | X_psd_bin3, Y_q0.8, Y_q0.7     |
| 0.5       | 410      | 0.900±0.032 | 0.886±0.030 | 0.896±0.034 | 0.883±0.032 | 0.903        | 0.892       | 0.076                 | 29              | 7                 | X_psd_bin2, Y_q0.9, X_psd_bin4 |
| 1.0       | 410      | 0.915±0.029 | 0.919±0.020 | 0.910±0.031 | 0.917±0.021 | 0.912        | 0.911       | 0.475                 | 34              | 7                 | X_q0.3, X_jerk_std, Z_qdiff_28 |
| 5.0       | 410      | 0.948±0.028 | 0.938±0.022 | 0.947±0.029 | 0.937±0.023 | 0.939        | 0.951       | 0.090                 | 26              | 7                 | Z_qdiff_28, X_psd_bin1, X_q0.3 |
| 10.0      | 410      | 0.937±0.026 | 0.924±0.021 | 0.936±0.028 | 0.923±0.021 | 0.938        | 0.944       | 0.042 *               | 24              | 7                 | Z_q0.2, X_psd_bin1, X_qdiff_28 |
| 25.0      | 410      | 0.948±0.025 | 0.935±0.022 | 0.947±0.026 | 0.934±0.023 | 0.969        | 0.965       | 0.096                 | 22              | 7                 | Z_qdiff_28, Z_psd_bin1, X_q0.3 |
| 50.0      | 410      | 0.928±0.026 | 0.937±0.019 | 0.927±0.026 | 0.937±0.019 | 0.968        | 0.976       | 0.060                 | 20              | 7                 | Z_psd_bin1, X_q0.3, Y_psd_bin1 |

\* Indica que la diferencia es estadísticamente significativa ( $p < 0.05$ ).



**Figura 23.** Métricas de rendimiento (a) Accuracy CV, b) F1-Weighted CV, c) Test AUC para KNN y RF) y d) número de componentes PCA (95% varianza) en función de la frecuencia de muestreo para el Análisis #3.

Adicionalmente, la Figura 23 ilustra visualmente las tendencias de las métricas de rendimiento (*Accuracy CV*, *F1-Weighted CV*, *Test AUC*) y el número de componentes PCA para el 95% de varianza, en función de la frecuencia de muestreo.

Observando la Tabla 11y la Figura 23, se pueden destacar varias tendencias, las cuales se mencionan a continuación:

#### **Impacto de la frecuencia en el rendimiento:**

- **Frecuencias muy bajas (0.1 Hz):** El rendimiento es significativamente bajo para ambos clasificadores, con métricas de *CV* y *Test AUC* relativamente bajo para la clase minoritaria “Agresivo”. Notablemente, a esta frecuencia, SFFS recurrió a un *fallback*, seleccionando solo 3 características (las correlaciones inter-eje: *XY\_corr*, *YZ\_corr*, *XZ\_corr*), ya que probablemente el resto de las 75 características carecían de información discriminativa suficiente o presentaban problemas numéricos. El número de componentes PCA para explicar el 95% de la varianza también es mínimo (3), indicando una drástica pérdida de información.
- **Frecuencias bajas (0.25 Hz - 0.5 Hz):** Se observa una mejora sustancial en el rendimiento. A 0.25 Hz, la prueba *AUC* para *RF* alcanza 0.879, y a 0.5 Hz, el *KNN Test AUC* es 0.903. Esto sugiere que incluso a estas bajas frecuencias, los segmentos contienen información útil que puede ser explotada, especialmente si se seleccionan características adecuadas (SFFS seleccionó 7 características, principalmente espectrales y cuantiles).
- **Frecuencias medias (1.0 Hz - 5.0 Hz):** El rendimiento continúa mejorando y se estabiliza en niveles altos. Alrededor de 1.0 Hz y 5.0 Hz, ambos clasificadores muestran una prueba *AUC* superior a 0.91. Las métricas de *CV* (*Accuracy* y *F1w*) superan el 0.91 para ambas frecuencias. Para 5.0 Hz, *KNN* alcanza un *CV Acc* de 0.948 y *RF* una prueba *AUC* de 0.951, indicando un punto de máxima efectividad o cercano a este.
- **Frecuencias altas (10.0 Hz, 25.0 Hz, 50.0 Hz):** El rendimiento se mantiene consistentemente alto, con prueba *AUC* para *RF* y *KNN* generalmente por encima de 0.93 y alcanzando hasta 0.976 (*RF* a 50Hz). Las métricas de *CV* también son robustas. A 10Hz, *KNN* fue estadísticamente superior a *RF* en términos de *Accuracy de CV* ( $p=0.042$ ). A 50Hz, *RF* fue marginalmente superior en *F1w de CV* ( $p=0.0397$ , aunque el  $p$ -valor de *Acc* no fue significativo).

**Comparación entre *KNN* y *RF*:** En general, *RF* tiende a mostrar un rendimiento ligeramente superior o más estable, especialmente en términos de Prueba *AUC* en las frecuencias más altas (25Hz, 50Hz) y en algunas frecuencias bajas (0.25Hz).

*KNN*, sin embargo, es competitivo e incluso supera a *RF* en algunas configuraciones específicas (e.g., *CV Acc* a 10Hz, *Test AUC* a 0.5Hz). Las desviaciones estándar de las métricas de *CV* son relativamente pequeñas para ambos clasificadores en el rango de 0.25Hz a 50Hz, indicando una estabilidad en la validación cruzada repetida.

**Selección de Características e Importancia:** *SFFS* consistentemente seleccionó 7 características para frecuencias desde 0.25Hz hasta 50Hz. Solo a 0.1Hz recurrió al fallback de 3 características.

Las características más importantes según ***RF*** (Top 3) varían con la frecuencia, pero a menudo incluyen una mezcla de características que se enlistan a continuación:

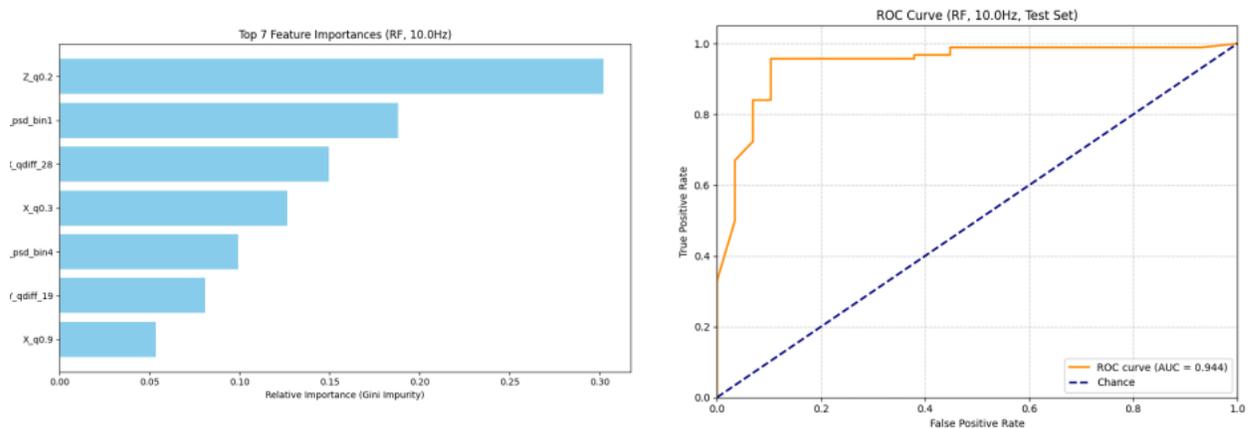
- **Características espectrales (PSD bins):** Prominentes a frecuencias de 0.25Hz, 0.5Hz, y también importantes en frecuencias más altas (e.g., *X\_psd\_bin3*, *Z\_psd\_bin1*).
- **Cuantiles y diferencias de cuantiles:** Aparecen consistentemente en el top, como *Y\_q0.8*, *X\_q0.3*, *Z\_qdiff\_28*.
- **Jerk std:** *X\_jerk\_std* es relevante a 1.0 Hz.
- **Correlaciones:** Dominantes a 0.1 Hz, como era de esperar por el fallback de *SFFS*.

Es interesante notar que las características seleccionadas por *SFFS* (basado en *KNN*) y las más importantes para *RF* (basado en Gini) no siempre coinciden perfectamente, pero a menudo hay solapamiento, sugiriendo que ambos métodos capturan aspectos relevantes de los datos. Por ejemplo, a 0.25Hz, *X\_psd\_bin3*, *Y\_q0.7*, *Y\_q0.8* están en ambas listas (*SFFS* y top *RF*).

**Componentes PCA:** El número de componentes PCA necesarios para explicar el 95% de la varianza aumenta desde 3 (a 0.1Hz) hasta un pico de 34 (a 1.0Hz), y luego disminuye ligeramente a 20-26 en las frecuencias más altas (5Hz-50Hz). Esto sugiere que a 1.0Hz, la información está más distribuida entre las 78 características originales, mientras que, a frecuencias muy altas, podría haber más redundancia o colinealidad que PCA captura más eficientemente en menos componentes (relativo al total de información).

### Análisis específico por frecuencias de interés:

- **A 50.0 Hz (Frecuencia original):** RF muestra una excelente prueba AUC de 0.976. Las características principales incluyen  $Z\_psd\_bin1$  y cuartil 0.3 del eje x ( $X\_q0.3$ ). SFFS seleccionó un conjunto diverso que incluye cuantiles y características espectrales.
- **A 5.0 Hz (Rendimiento de alta efectividad):** KNN presenta un CV Acc de 0.948 y RF una prueba AUC de 0.951. Las características clave incluyen diferencia entre cuantiles 2 y 8 para eje Z ( $Z\_qdiff\_28$ ) y  $X\_psd\_bin1$ . La Figura 24 muestra un ejemplo de este alto rendimiento, presentando la importancia de las características y la curva ROC para el modelo Random Forest a esta frecuencia.
- **A 1.0 Hz (Pico de componentes PCA):** Ambos clasificadores tienen un buen rendimiento (Test AUC  $\sim 0.91$ ).  $X\_jerk\_std$  y  $Z\_qdiff\_28$  son importantes.
- **A 0.25 Hz (Límite inferior de buen rendimiento):** RF todavía logra un Test AUC de 0.879. Las características espectrales del eje X ( $X\_psd\_bin3$ ) y cuantiles del eje Y ( $Y\_q0.8$ ,  $Y\_q0.7$ ) son cruciales.
- **A 0.1 Hz (Fallo de SFFS y bajo rendimiento):** El rendimiento se desploma. Solo las correlaciones inter-eje son seleccionadas, lo que indica que la información temporal y espectral detallada se ha perdido o es inutilizable. Los reportes de clasificación detallados (mostrados en el resumen del script) confirman que la predicción de la clase "Agresivo" es muy pobre.



**Figura 24.** Importancia de características (RF Gini) y curva ROC (Test Set) para el clasificador Random Forest a 10 Hz.

Este análisis, al utilizar el conjunto completo de 78 características "Zylius-Inspired" sobre segmentos de  $\sim 30$ s y aplicar SFFS para cada frecuencia, ofrece varias perspectivas importantes: La combinación de un amplio conjunto de características candidatas y una selección posterior (SFFS) demuestra ser una estrategia poderosa. Permite adaptar el subconjunto de características a la información disponible en cada frecuencia de muestreo.

Comparado con el Análisis #2 (6 características "Zylius-Inspired SFFS" preseleccionadas, con base a datos muestreados a 50 Hz y recorridos completos o curvas), este Análisis #3, al reelegir características por frecuencia sobre segmentos, logra un rendimiento comparable o incluso superior en las frecuencias óptimas. Por ejemplo, a 5.0Hz, RF en Análisis #3 alcanza una prueba AUC de 0.951 y un F1w de CV de 0.937, lo cual es altamente competitivo y demuestra la adaptabilidad de SFFS. La granularidad de los segmentos (410 muestras) proporciona una base de datos más grande para el entrenamiento y la evaluación en comparación con análisis basados en recorridos completos (como probablemente fue el caso para la preselección del Análisis #2).

Más allá del rendimiento numérico, este análisis demuestra un concepto fundamental, la frecuencia de muestreo redefine el conjunto de características que resultan informativas. Lo que es una característica crucial a 25 Hz (e.g., una banda espectral específica) puede ser indistinguible del ruido a 0.5 Hz. A su vez, una correlación estática que es la única señal discernible a 0.1 Hz es prácticamente irrelevante a frecuencias más altas. Por lo tanto, este estudio demuestra que la 'importancia' de una característica no es una propiedad inherente, sino que está directamente condicionada por la resolución temporal de los datos.

**Impacto de la Granularidad de los Datos (Segmentos vs. Curvas/Recorridos):** Utilizar segmentos aumenta significativamente el número de muestras (410) en comparación con los análisis basados en recorridos completos (e.g., 36-60 recorridos en los Análisis #1 y #2). Esto puede llevar a modelos más robustos y estimaciones de rendimiento más fiables, aunque también introduce la complejidad de que un segmento individual podría no representar siempre el estilo global del recorrido si este es mixto.

El rendimiento obtenido en este análisis sobre segmentos es muy alto, superando a menudo el rendimiento del Análisis #1 (Vaitkus-Inspired) que probablemente usaba una granularidad diferente y un conjunto de características de menor dimensionalidad.

**Identificación de un Rango de Frecuencia recomendado:** Los resultados identifican una clara relación entre la frecuencia de muestreo y la efectividad de la clasificación, permitiendo definir un rango de operación recomendado. Se establece un umbral de viabilidad a partir de 1.0 Hz, por debajo del cual el rendimiento se degrada significativamente. Dentro de las frecuencias viables, se distinguen dos regímenes de alta efectividad:

- **Rango de Equilibrio (5.0 Hz a 10.0 Hz):** Ofrece un balance sobresaliente entre un alto rendimiento de clasificación y la eficiencia de los recursos.
- **Rango de Máxima Precisión (10.0 Hz a 25.0 Hz):** Proporciona el rendimiento más robusto y consistentemente alto (con Test AUC superando el 0.95 en muchos casos), siendo la elección preferente cuando la precisión es el factor crítico.
- **Robustez de Clasificadores y Características:** Random Forest generalmente se muestra como el clasificador más robusto y con mejor rendimiento general, especialmente en Test AUC.

La variabilidad en las características seleccionadas y su importancia a través de las frecuencias subraya la necesidad de un enfoque adaptativo. No existe un único subconjunto de características que sea óptimo para todas las frecuencias. Las características espectrales tienden a ser más útiles cuando hay suficiente resolución frecuencial, mientras que las estadísticas más básicas o temporales (como jerk o cuantiles amplios) pueden ganar relativa importancia a medida que la frecuencia disminuye.

En conclusión, el Análisis #3 demuestra que el uso de un conjunto completo de 78 características "Zylius-Inspired" aplicadas a segmentos de datos, combinado con SFFS por frecuencia, permite una clasificación robusta y de alto rendimiento de los estilos de manejo. Se identifica un rango de alta efectividad de frecuencias (1.0Hz - 25.0Hz) y se evidencia la importancia de adaptar la selección de características a la información disponible en cada nivel de frecuencia. Los resultados son prometedores para el desarrollo de sistemas de detección de estilos de manejo eficientes y precisos.

#### **Análisis #4: Evaluación con Características del "Conjunto Extendido"**

Este cuarto análisis computacional representa la exploración más exhaustiva en términos de la riqueza del conjunto de características. Se evalúa un "Conjunto Extendido" de aproximadamente 240 características aplicadas a segmentos de conducción de 30 segundos (DB\_Segmentos). Similar al Análisis #3, se utiliza un proceso de Selección Secuencial de Características (SFFS) para cada frecuencia de muestreo, pero operando sobre este espacio de características significativamente más amplio. Los objetivos principales de este análisis #4 son:

- Determinar si un conjunto de características mucho más diverso y numeroso puede mejorar el rendimiento de clasificación en comparación con los conjuntos más compactos de los análisis anteriores.
- Identificar cómo la disponibilidad de este conjunto de descriptores interactúa con la variación de la frecuencia de muestreo.
- Evaluar la robustez y el comportamiento de los clasificadores KNN y Random Forest bajo estas condiciones.
- Comparar los resultados con los análisis previos, especialmente el Análisis #3, que utiliza un conjunto de 78 características sobre la misma partición de segmentos.

#### 3.5.3.2 Metodología específica del análisis #4

Se utilizaron los datos del acelerómetro Accel1 (LSM6DS) provenientes de la DB\_Segmentos, que consiste en segmentos de 30 segundos. Esto resultó en un total de 410 muestras. Para la clasificación binaria, las etiquetas originales de los recorridos ('Reconocimiento', 'Normal', 'Cauteloso', 'Agresivo') se agruparon de la misma manera que en el Análisis #3: Clase "No Agresivo" (etiqueta 0): compuesta por segmentos de recorridos originalmente etiquetados como 'Reconocimiento', 'Normal' y 'No Agresivo' (total 314 segmentos). Clase "Agresivo" (etiqueta 1): compuesta por segmentos de recorridos originalmente etiquetados como 'Agresivo' (total 96 segmentos). Esta partición resulta en un desbalance de clases, que se maneja parcialmente mediante el uso de RepeatedStratifiedKFold en la validación y métricas como F1-score ponderado y AUC.

**Preprocesamiento de Señales y Extracción de Características:** Se utilizó cada una de las frecuencias de muestreo objetivo ([50.0, 25.0, 10.0, 5.0, 1.0, 0.5, 0.25, 0.1] Hz), diezmados a la frecuencia correspondiente utilizando el método descrito en la Sección 2.4 (Ecuación 4).

Posteriormente, se aplicó un filtro Savitzky-Golay (ventana de 0.22s, orden polinomial 2) a las señales de aceleración de cada segmento ya diezmado. Se extrajo el Conjunto Extendido de aproximadamente 240 características, cubriendo dominios temporales, frecuenciales Transformada Rápida de Fourier (FFT, por sus siglas en inglés) y Densidad Espectral de Potencia (PSD, por sus siglas en inglés), de vector magnitud y

de correlación inter-ejes. La característica DTV se calculó utilizando referencias específicas por piloto y frecuencia. Se extraen ~240 características del “Conjunto Extendido” como se describe en Anexo D.

**Reducción de Dimensionalidad y Selección de Características:** Se realizó PCA sobre las características escaladas para cada frecuencia. El objetivo principal fue exploratorio: determinar el número de componentes que explican el 95% de la varianza y visualizar la estructura de los datos. Los componentes PCA resultantes no se utilizaron directamente para la clasificación en este análisis, pero informaron sobre la dimensionalidad intrínseca.

También se aplicó SFFS (con k-NN, k=5, como estimador base y validación cruzada interna de 5 pliegues) para seleccionar un subconjunto de características. El parámetro *n\_caracteristicas\_to\_select* se estableció en 'auto' (aproximadamente  $\sqrt{N}$  características, con un tope de *MAX\_SFFS\_CHARACTERISTICAS* = 20). Esto permitió una selección adaptativa del número de características por frecuencia, a partir del conjunto completo de ~240 disponibles (después de la limpieza de NaNs/constantes).

**Modelos de clasificación y optimización de hiperparámetros:** Se evaluaron los mismos dos algoritmos de clasificación:

- K-Nearest Neighbors (KNN): *n\_neighbors*=5.
- Random Forest (RF): *n\_estimators*=100, *max\_depth*=None, *random\_state*=42.

En este análisis, los hiperparámetros de los clasificadores se mantuvieron fijos y no se optimizaron por frecuencia, para centrar la evaluación en el impacto del conjunto de características y la frecuencia de muestreo.

**Validación y métricas de evaluación:**

- **Validación Cruzada Repetida Estratificada:** Se utilizaron 3 repeticiones de StratifiedKFold con 5 pliegues (`RepeatedStratifiedKFold(n_splits=5, n_repeats=3, random_state=42)`). Se reportaron la media y desviación estándar de la Exactitud (Accuracy CV) y F1-Score ponderado (F1w CV).

- **División Train/Test:** Se realizó una única división estratificada (70% entrenamiento, 30% test, `random_state=42`) para evaluar el rendimiento final en datos no vistos. Se reportaron Exactitud, F1-Score ponderado y Área Bajo la Curva ROC (Test AUC).
- **Prueba T Pareada:** Se utilizó para comparar estadísticamente los scores de Accuracy de CV Repetida entre KNN y RF para cada frecuencia.
- **Importancia de Características (RF):** Se calcularon y reportaron las características más importantes según el modelo Random Forest para el conjunto de características seleccionadas por SFFS en cada frecuencia.

### 3.5.3.3 Resultados detallados del análisis #4

Esta sección presenta los resultados del Análisis #4, la exploración computacional más exhaustiva de este estudio. En este análisis, se evalúa el "Conjunto Extendido" de aproximadamente 240 características, cubriendo un espectro mucho más amplio de dominios (temporales, frecuenciales, de magnitud vectorial, etc.) que en los análisis previos. La pregunta fundamental que este análisis busca responder es si un repertorio de características significativamente más amplio y diverso puede desbloquear un nivel de rendimiento superior al ya notablemente alto alcanzado en el Análisis #3, o si, por el contrario, el conjunto de 78 características ya capturaba la mayor parte de la información útil.

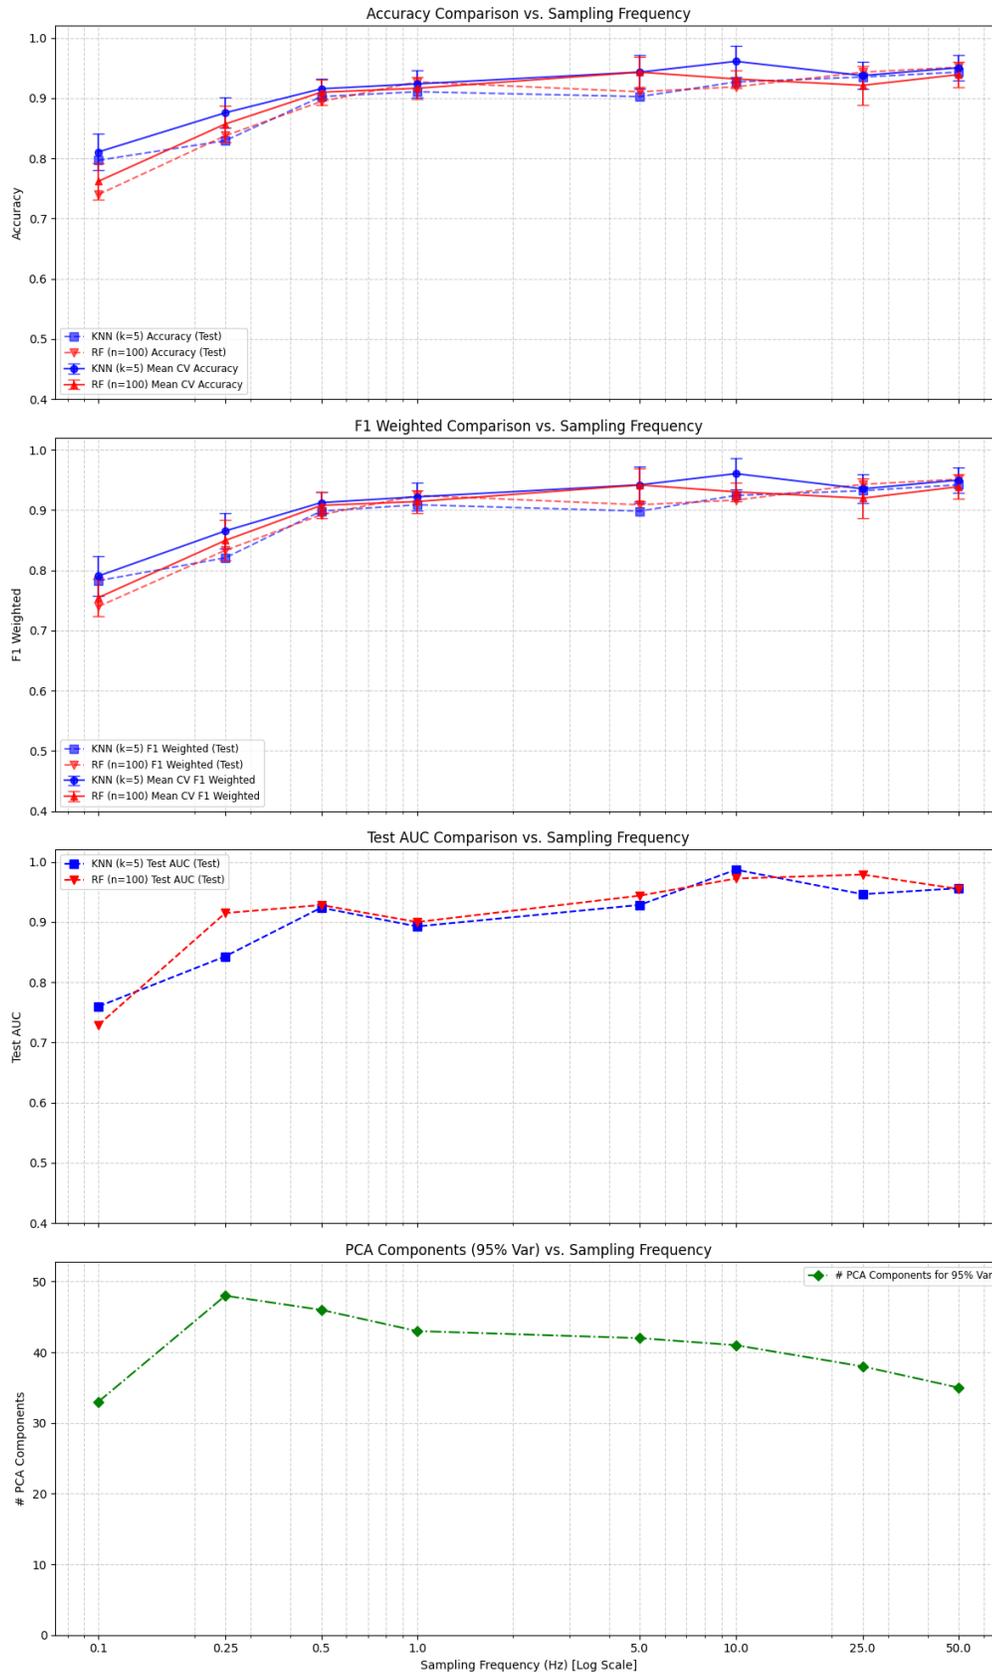
Los resultados consolidados de esta investigación se presentan en la Tabla 12. Dicha tabla no solo resume las métricas de rendimiento clave (Accuracy CV, F1-Weighted CV, Test AUC) para los clasificadores KNN y RF, sino que también ofrece una visión profunda de la dimensionalidad de los datos en cada frecuencia y de la naturaleza de las características seleccionadas. Se invita al lector a analizar no solo el rendimiento absoluto, sino también la dinámica entre la frecuencia de muestreo, el número de características que el SFFS considera óptimas y la identidad de las más relevantes (Top 3 Caract.). Esta visión integral es crucial para entender cómo la disponibilidad de información (modulada por la frecuencia) interactúa con la riqueza del espacio de características.

Para facilitar la visualización de estas complejas interdependencias, la Figura 25 ilustra gráficamente las tendencias de las métricas de rendimiento y la dimensionalidad intrínseca de los datos (componentes PCA) en función de la frecuencia de muestreo.

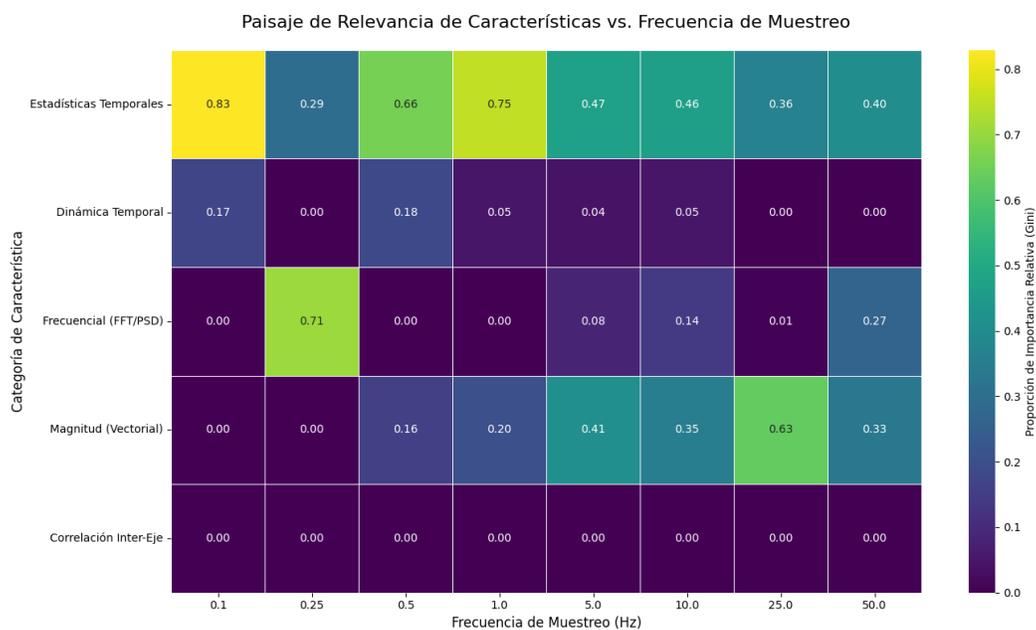
**Tabla 12.** Resultados Comparativos por Frecuencia de Muestreo para el Análisis #4

| Freq | Muestras | # Feat Escaladas | KNN CV Acc      | RF CV Acc       | KNN CV F1w      | RF CV F1w       | KNN Test AUC | RF Test AUC | KNN vs RF (p-val Acc CV) | # PCA 95% | # Feat Sel (SFFS) | Top 3 Caract.                              |
|------|----------|------------------|-----------------|-----------------|-----------------|-----------------|--------------|-------------|--------------------------|-----------|-------------------|--|
| 0.1  | 410      | 96               | 0.811±<br>0.030 | 0.762±<br>0.030 | 0.790±<br>0.033 | 0.755±<br>0.031 | 0.760        | 0.729       | 0.000 *                  | 33        | 9                 | X range, Y dtv, X dtv                      |
| 0.25 | 410      | 216              | 0.876±<br>0.025 | 0.857±<br>0.030 | 0.865±<br>0.030 | 0.849±<br>0.034 | 0.843        | 0.915       | 0.043 *                  | 48        | 14                | X fft mag mean, X fft mag media, X sum abs |
| 0.5  | 410      | 224              | 0.915±<br>0.016 | 0.910±<br>0.021 | 0.912±<br>0.017 | 0.908±<br>0.022 | 0.924        | 0.928       | 0.235                    | 46        | 14                | X rms, Y pctl 90, Z std                    |
| 1.0  | 410      | 236              | 0.924±<br>0.023 | 0.916±<br>0.018 | 0.922±<br>0.023 | 0.914±<br>0.019 | 0.893        | 0.900       | 0.167                    | 43        | 15                | X rms, Y var, Mag mAbsCh                   |
| 5.0  | 410      | 240              | 0.943±<br>0.028 | 0.943±<br>0.025 | 0.942±<br>0.030 | 0.942±<br>0.027 | 0.928        | 0.944       | 1.000                    | 42        | 15                | Mag pctl 90, X mad, Mag var                |
| 10.0 | 410      | 240              | 0.961±<br>0.026 | 0.932±<br>0.015 | 0.961±<br>0.026 | 0.930±<br>0.016 | 0.987        | 0.972       | 0.000 *                  | 41        | 15                | X rms, Mag fftLo mean, Mag energy band     |
| 25.0 | 410      | 240              | 0.937±<br>0.022 | 0.921±<br>0.032 | 0.935±<br>0.024 | 0.920±<br>0.033 | 0.946        | 0.979       | 0.023 *                  | 38        | 15                | Mag pctl 90, Mag coeff var, Y min          |
| 50.0 | 410      | 240              | 0.950±<br>0.022 | 0.939±<br>0.020 | 0.950±<br>0.021 | 0.939±<br>0.020 | 0.956        | 0.955       | 0.008 *                  | 35        | 15                | Mag pctl 90, X iqr, X fftLo std            |

\* Indica que la diferencia es estadísticamente significativa ( $p < 0.05$ ), El número de características de entrada varía ligeramente ya que algunas características no son computables a todas las frecuencias o son eliminadas durante el preprocesamiento por ser constantes o contener valores NaN.



**Figura 25.** Métricas de rendimiento (a) Accuracy CV, b) F1-Weighted CV, c) Test AUC para KNN y RF) y d) número de componentes PCA (95% varianza) en función de la frecuencia de muestreo para el Análisis #4.



**Figura 26.** Paisaje de Relevancia de Categorías de Características. Los valores representan la proporción de la importancia de Gini total que aporta cada categoría de características, normalizada por frecuencia. Este análisis se basa en los resultados del clasificador Random Forest sobre el "Conjunto Extendido".

El Paisaje de Relevancia de Características presentado en la Figura 26 ofrece una visualización del poder discriminatorio de los descriptores a medida que varía la frecuencia de muestreo. Para interpretar adecuadamente esta figura, es fundamental comprender la métrica subyacente y el proceso de agregación que la genera. El análisis se fundamenta en la Importancia de Gini, una métrica intrínseca al clasificador Random Forest que cuantifica la contribución de cada característica a la reducción de la impureza en los nodos de decisión. En este contexto, una mayor importancia de Gini es indicativa de un mayor poder discriminatorio de la característica para diferenciar entre los estilos de manejo "Agresivo" y "No Agresivo".

El valor de cada celda no representa la importancia de una característica individual, sino la proporción de la importancia relativa que aporta una categoría completa de características. Este valor se calculó para cada frecuencia de muestreo (cada columna de la figura) mediante un proceso de tres pasos. Primero, se obtuvieron las puntuaciones de importancia de Gini para cada una de las ~240 características del "Conjunto Extendido". Segundo, estas características fueron agrupadas en cinco categorías lógicas (ej. 'Estadísticas Temporales', 'Frecuencial (FFT/PSD)') según su naturaleza física o matemática. Finalmente, se sumaron las importancias de todas las características dentro de cada categoría y se normalizó este valor dividiéndolo por la suma total de las importancias de todas las características en esa frecuencia específica.

Este proceso de normalización y agregación, crucial para permitir una comparación equitativa entre frecuencias, puede formalizarse mediante la siguiente ecuación:

$$P_C = \frac{\sum_{i \in C} I(f_i)}{\sum_{j \in F_{\text{total}}} I(f_j)} \quad (6)$$

Donde  $PC$  es la proporción de importancia para una categoría  $C$  (el valor en la celda),  $I(fi)$  es la Importancia de Gini de una característica individual  $fi$ ,  $C$  es el conjunto de todas las características que pertenecen a una categoría, y  $F_{\text{total}}$  es el conjunto de todas las características disponibles en esa frecuencia.

A una frecuencia de 0.1 Hz, en un régimen de información escasa, el sistema depende casi exclusivamente de las "Estadísticas Temporales" (83%), reflejando la incapacidad de capturar la dinámica de las maniobras. Un cambio de paradigma ocurre a 0.25 Hz, donde las características "Frecuenciales" se vuelven abrumadoramente dominantes (71%), demostrando que tan pronto como la resolución es mínimamente suficiente, la firma espectral emerge como la información más relevante.

Interesantemente, en el rango de 0.5 Hz a 1.0 Hz, el modelo vuelve a apoyarse en la robustez de las "Estadísticas Temporales" y la "Magnitud (Vectorial)", sugiriendo que la información temporal agregada se consolida como más fiable antes de que el espectro, potencialmente afectado por aliasing, se vuelva suficientemente discriminativo. Finalmente, en el rango de rendimiento óptimo (5.0 Hz a 50.0 Hz), el sistema aprovecha un repertorio equilibrado y sofisticado de descriptores, con contribuciones sinérgicas de los dominios estadístico, de magnitud y frecuencial. Esta visualización confirma de manera inequívoca que la frecuencia de muestreo no solo afecta la precisión, sino que redefine qué aspectos de la física de la conducción son observables, haciendo de la selección de características un proceso fundamentalmente dinámico.

Para profundizar en qué características impulsan estos resultados, la Tabla 13 compara directamente las características más importantes identificadas por la importancia Gini de Random Forest con aquellas seleccionadas por el algoritmo SFFS en las frecuencias más relevantes.

**Tabla 13.** Resultados Comparativos por Frecuencia (características Extendidas)

| Frecuencia | Top 5 Features (RF Gini Importance)   | Top 10 Features (Selección SFFS)   |
|------------|---|--|
| 1.0 Hz     | X_rms<br>Y_var<br>Mag_mean_abs_change<br>Z_range<br>Z_dtv                                   | Mag_dominant_freq,<br>Mag_energy_band_2,<br>Mag_energy_band_3,<br>Mag_energy_band_4,<br>Mag_energy_ratio_band_1,<br>Mag_energy_ratio_band_2,<br>Mag_energy_ratio_band_3,<br>Mag_energy_ratio_band_4,<br>Mag_mean_abs_change,<br>Mag_psd_kurt |
| 5.0 Hz     | Mag_pctl_90<br>X_mad (Median Abs Dev)<br>Mag_var<br>Y_std<br>Y_pctl_90                      | Mag_energy_band_3,<br>Mag_energy_band_4,<br>Mag_energy_ratio_band_3,<br>Mag_energy_ratio_band_4,<br>Mag_pctl_90, Mag_var,<br>Mag_zero_crossings, X_coeff_var,<br>X_dtv, X_energy_band_3  |
| 10.0 Hz    | X_rms<br>Mag_fft_low10_mag_mean<br>Mag_energy_band_1<br>Y_pctl_90<br>X_median               | Mag_energy_band_1,<br>Mag_energy_band_3,<br>Mag_energy_band_4,<br>Mag_energy_ratio_band_3,<br>Mag_energy_ratio_band_4,<br>Mag_fft_low10_mag_mean,<br>Mag_zero_crossings, X_dtv,<br>X_energy_band_3, X_fft_mag_max                            |
| 25.0 Hz    | Mag_pctl_90<br>Mag_coeff_var<br>Y_min<br>Mag_psd_median<br>Z_median                         | Mag_coeff_var, Mag_pctl_90,<br>Mag_psd_median, Mag_psd_min,<br>Mag_zero_crossings,<br>X_dominant_freq, X_psd_min,<br>Y_coeff_var, Y_dominant_freq,<br>Y_min  |
| 50.0 Hz    | Mag_pctl_90<br>X_iqr (Interquartile Range)<br>X_fft_low10_mag_std<br>X_median<br>X_psd_kurt | Mag_fft_mag_min, Mag_pctl_90,<br>Mag_psd_min,<br>Mag_zero_crossings,<br>X_fft_low10_mag_std, X_iqr,<br>X_kurt, X_median, X_psd_kurt,<br>X_psd_min  |

**Observaciones Clave del Análisis #4: Rendimiento, Frecuencia y Características:** El análisis del "Conjunto Extendido" de características, cuyos resultados se detallan en las tablas y figuras anteriores, revela una profunda interdependencia entre la frecuencia de muestreo, el rendimiento de la clasificación y la naturaleza de las características más informativas. Las tendencias se pueden desglosar por regímenes de frecuencia:

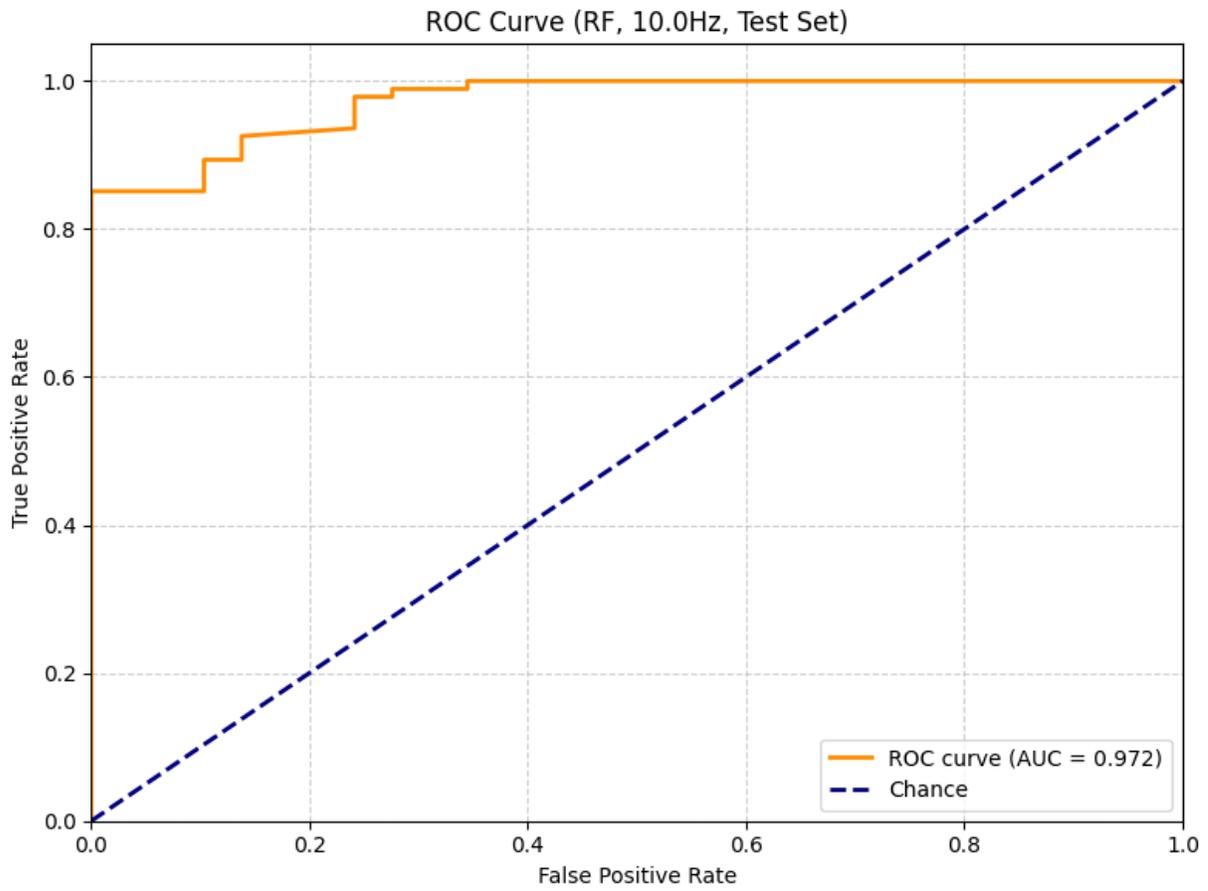
**Frecuencias Muy Bajas (0.1 Hz): información insuficiente** A esta frecuencia, el rendimiento es notablemente bajo (Test AUC  $\sim 0.76$  para KNN y  $\sim 0.73$  para RF), a pesar del vasto conjunto de características disponibles. SFFS solo seleccionó 9 características, dominadas por descriptores del dominio del tiempo y DTV ( $X_{\text{range}}$ ,  $Y_{\text{dtv}}$ ,  $X_{\text{dtv}}$ ). Esto indica que la resolución temporal es insuficiente para capturar la dinámica de las maniobras, forzando a los modelos a depender de métricas agregadas y estáticas. La baja dimensionalidad intrínseca (solo 33 componentes PCA para 95% de varianza) confirma esta drástica pérdida de información.

**Frecuencias Bajas (0.25 Hz - 0.5 Hz): Umbral de viabilidad**, se observa una mejora sustancial y crítica en el rendimiento. A 0.25 Hz, la prueba AUC de RF alcanza un notable 0.915, y a 0.5 Hz, el de KNN llega a 0.924. En este rango, SFFS selecciona 14 características, y el análisis de importancia de RF muestra la aparición de características frecuenciales ( $X_{\text{fft\_mag\_mean}}$ ) y estadísticas más robustas del dominio del tiempo ( $X_{\text{rms}}$ ). Esto demuestra que, a partir de 0.5 Hz, la señal contiene suficiente densidad de puntos para empezar a trazar un perfil dinámico reconocible.

**Frecuencias Medias (1.0 Hz - 10.0 Hz): Meseta de rendimiento recomendado**, el rendimiento se estabiliza en niveles excelentes y robustos. Las pruebas AUC superan consistentemente el 0.90, alcanzando un pico para KNN con una prueba AUC de 0.987 a 10.0 Hz. Las métricas de validación cruzada (Accuracy y F1w) también son excelentes, superando 0.96 para KNN a 10 Hz. Como se observa en la Tabla 13, SFFS selecciona consistentemente 15 características, que son una mezcla equilibrada y rica de dominios de tiempo, magnitud y frecuencia. Este es el rango donde la riqueza de la señal es máxima.

**Frecuencias Altas (25.0 Hz, 50.0 Hz): Rendimientos sostenidos y concentración de información**, el rendimiento se mantiene consistentemente alto. La prueba AUC para RF es notablemente elevado (0.979 a 25Hz). Las características de Magnitud ( $\text{Mag\_pctl}_{90}$ ,  $\text{Mag\_coeff\_var}$ ) y del dominio del tiempo que capturan la distribución de la señal ( $X_{\text{iqr}}$ ) son prominentes. Curiosamente, el número de componentes PCA necesarios para explicar el 95% de la varianza comienza a disminuir (de 41 a 10 Hz hasta 35 a 50 Hz), sugiriendo una mayor correlación o redundancia en las características extraídas.

El alto poder discriminatorio de *RF* en las frecuencias óptimas queda visualmente demostrado en la Figura 27, que muestra una curva ROC con un AUC de 0.972 para datos a 10 Hz.



**Figura 27.** Ejemplo de Curva ROC para RF usando datos muestreados a 10 Hz. El AUC de 0.972 indica un alto poder discriminatorio.

**Comparación entre KNN y RF con Características Extendidas:** La comparación estadística (prueba T pareada sobre los scores de CV Accuracy) revela una dinámica interesante. KNN tiende a mostrar un rendimiento superior y estadísticamente significativo ( $p < 0.05$ ) en las métricas de validación cruzada en la mayoría de las frecuencias (0.1, 0.25, 10.0, 25.0 y 50.0 Hz).

Sin embargo, Random Forest (RF) a menudo muestra un Test AUC igual o superior. Esto sugiere que, si bien KNN, con su naturaleza basada en la distancia, puede ajustarse de manera muy precisa a la estructura local del conjunto de entrenamiento/validación, Random Forest, al promediar las predicciones de múltiples árboles de decisión, construye un límite de decisión más robusto y menos propenso al sobreajuste, lo que resulta en una mejor capacidad de generalización para discriminar clases en datos completamente nuevos. La elección del clasificador no es absoluta; su efectividad relativa está modulada por la frecuencia de muestreo.

**Efectividad de la selección de características y dimensionalidad:** La estrategia de combinar un vasto conjunto de ~240 características con Sequential Forward Feature Selection (SFFS) demostró ser excepcionalmente efectiva. Algunas consideraciones relevantes encontradas son:

- **Reducción de Dimensionalidad:** SFFS redujo consistentemente el espacio de características a un subconjunto informativo y manejable de 9 a 15.
- **Selección Adaptativa:** Como se detalla en la Tabla 13, no existe un único conjunto de características óptimo. SFFS adapta su selección a la información disponible en cada frecuencia: prioriza descriptores agregados a 0.1 Hz, introduce características espectrales a 0.5 y crece a una amplia selección de características en las frecuencias más altas.

La divergencia parcial entre los conjuntos de características seleccionados por SFFS/KNN y los identificados como importantes por RF es, en sí misma, un hallazgo. Indica que la 'importancia' de una característica también está modulada por el algoritmo clasificador, que explota diferentes propiedades de los datos. Sin embargo, el solapamiento constante en características clave (e.g., Mag\_pctl\_90, X\_rms) confirma que estas representan la información discriminativa más fundamental, independientemente del modelo.

**Dimensionalidad intrínseca (PCA):** El número de componentes PCA de la **Tabla 12** revela que, aunque se disponga de 240 características, la dimensionalidad intrínseca de los datos no es excesivamente alta, alcanzando un pico de 48 componentes.

#### 3.5.3.4 Discusión parcial del análisis #4 y comparación con análisis anteriores

Este análisis confirma y refuerza los resultados del Análisis #3, que utilizaba el conjunto más limitado de 78 características "Zylius-Inspired" dentro del cual se destacan los siguientes dos puntos:

- **Rendimiento Comparativo:** El rendimiento del Análisis #4 es, en general, comparable al del Análisis #3 y, en algunos casos, representa una mejora notable, especialmente en el caso del clasificador KNN. Por ejemplo, a 10 Hz, la prueba AUC de KNN mejoró de 0.938 a 0.987. Para RF, los resultados en las frecuencias óptimas son muy similares. Esto sugiere que, si bien el conjunto de 78 características ya era muy potente, el enfoque de "Conjunto Extendido" con SFFS ofrece un potencial adicional para encontrar combinaciones de características aún más efectivas.

- **Identificación del rango de frecuencia recomendado:** Este análisis refuerza la identificación de un rango de frecuencia óptimo entre 1.0 Hz y 25.0 Hz. Dentro de este espectro, se logra un equilibrio excepcional entre la riqueza de la información y la eficiencia. Frecuencias por debajo de 0.5 Hz muestran una degradación pronunciada, mientras que las ganancias por encima de 25.0 Hz son marginales.

En conclusión, el Análisis #4 demuestra que la estrategia de combinar un amplio conjunto de características (~240) con una selección adaptativa (SFFS) es excepcionalmente poderosa, logrando un rendimiento de clasificación sobresaliente y definiendo un rango operativo óptimo entre 1.0 Hz y 50 Hz. Al compararlo directamente con el Análisis #3, el "Conjunto Extendido" ofrece una mejora de rendimiento marginal pero consistente, como lo evidencia el aumento de la métrica AUC de prueba para KNN de 0.938 a 0.987 a 10 Hz. Este resultado es significativo porque, si bien confirma que un repertorio más amplio permite a SFFS descubrir combinaciones de características aún más efectivas, también ratifica que el conjunto original de 78 características ya era muy potente y capturaba la mayor parte de la información discriminativa relevante, explicando así por qué la mejora no fue drástica.

**Impacto de la granularidad de los datos (segmentos):** Este análisis, al igual que el #3, utiliza segmentos de 30 segundos, proporcionando un gran número de muestras (410), lo que contribuye a la robustez de los modelos y las estimaciones de rendimiento.

El alto rendimiento logrado confirma que los segmentos de 30 segundos contienen suficiente información contextual para una clasificación precisa del estilo de manejo cuando se utilizan conjuntos de características ricos y selección adaptativa.

**Identificación de un rango de frecuencia recomendado:** Los resultados de este análisis refuerzan la existencia de un rango de frecuencias de alta efectividad. Se confirma que frecuencias por debajo de 0.5 Hz muestran una degradación pronunciada. A partir de 1.0 Hz, el rendimiento se vuelve consistentemente alto y robusto. El rango entre 10.0 Hz y 25.0 Hz destaca por ofrecer la máxima precisión (Test AUC > 0.95 para ambos clasificadores en muchos casos). Si bien extender la frecuencia hasta 50 Hz mantiene este excelente rendimiento, las ganancias son marginales, lo que posiciona al rango de 10.0 a 25.0 Hz como la zona de mayor efectividad práctica.

Frecuencias por debajo de 0.5 Hz muestran una degradación más pronunciada, y 0.1 Hz es claramente insuficiente con el flujo de trabajo actual, incluso con el conjunto extendido.

La mejora marginal al pasar de, por ejemplo, 10 Hz a 50 Hz podría no justificar el aumento en el volumen de datos y coste computacional en todas las aplicaciones, haciendo de las frecuencias intermedias (5-25 Hz) opciones muy atractivas.

**Robustez de clasificadores y relevancia de características:** La elección de la frecuencia de muestreo demuestra ser un factor crucial que modula tanto la robustez de los clasificadores como la relevancia de las características extraídas. Si bien Random Forest se perfila como el modelo más estable en un amplio espectro de frecuencias, especialmente en la métrica Test AUC, el análisis revela que la superioridad no es absoluta. La competitividad de KNN, e incluso su mejor desempeño en métricas de validación cruzada en frecuencias específicas como 10 Hz, subraya que la efectividad relativa de un clasificador está ligada a la resolución temporal de los datos. Esto indica que no hay un único clasificador superior en todas las condiciones; su rendimiento depende de cómo sus mecanismos internos interactúan con la información disponible a una frecuencia dada.

De manera aún más contundente, el análisis demuestra que la frecuencia de muestreo dicta qué características son más informativas. La variabilidad observada en las características seleccionadas por SFFS y su importancia (Top 3 en RF) no es aleatoria, sino una consecuencia directa de la información preservada en cada nivel de muestreo. A frecuencias bajas (p. ej., 0.1 Hz), donde los detalles temporales finos se pierden, el modelo se ve forzado a depender de descriptores más generales como las características de tiempo y DTV. En contraste, a medida que la frecuencia aumenta, se habilita la explotación de características más ricas y detalladas, como las espectrales (bandas de energía, FFT) y las de magnitud. Esto confirma que no existe un conjunto de características universalmente ideal; la selección debe ser adaptativa a la frecuencia para lograr el máximo rendimiento, ya que la naturaleza de la señal discriminativa cambia con la resolución.

En conclusión, el Análisis #4 demuestra que la combinación de un conjunto de aproximadamente 240 características ("Conjunto Extendido") con una estrategia de selección adaptativa como SFFS permite alcanzar un rendimiento de clasificación sobresaliente. El resultado más relevante es la identificación de un rango de frecuencias de muestreo óptimo, entre 1.0 Hz y 50 Hz, donde este enfoque es altamente efectivo. Dentro de este rango, los modelos pueden aprovechar una mezcla equilibrada de descriptores temporales, frecuenciales y de magnitud, cruciales para una discriminación robusta de los estilos de manejo.

Los resultados, comparables y en ocasiones superiores a los del Análisis #3, indican que, aunque un conjunto más compacto de 78 características ya es muy informativo, la disponibilidad de un repertorio de ~240 características en lugar de 78 ofrecen a SFFS la flexibilidad para encontrar combinaciones aún más potentes y específicas para cada nivel de frecuencia. Esto refuerza la idea de que la clave del éxito no reside solo en la cantidad de características, sino en la capacidad de adaptar la selección de estas a la información disponible, un proceso que es fundamentalmente gobernado por la frecuencia de muestreo.

Este resultado es de suma importancia: demuestra que, si bien un espacio de características de mayor dimensionalidad permite mejoras marginales, no modifica el rango de operación de alta efectividad, que parece estar fundamentalmente determinado por la física del fenómeno de la conducción. Esto sugiere que el conjunto de 78 características ya era suficientemente rico para capturar la información esencial dentro de ese rango.

### 3.6 Similitud de rendimiento entre sensores (Accel1 vs. Accel2)

Un objetivo secundario de esta investigación fue comparar directamente el rendimiento de las dos IMUs empleadas, Accel1 (LSM6DS) y Accel2 (LSM9DS1). Para ello, se replicó la metodología del Análisis #3 (78 características "Zylius-Inspired" sobre segmentos de 30s) para ambos sensores a través de todas las frecuencias de muestreo.

Los resultados demostraron una equivalencia de rendimiento muy alta y consistente. Si bien existieron diferencias marginales en algunas métricas específicas, estas diferencias rara vez fueron estadísticamente significativas y no mostraron una ventaja clara y sostenida para ninguno de los dos sensores.

Para ejemplificar, se tiene en el rango de frecuencias óptimas lo siguiente:

- **A 5.0 Hz**, el rendimiento fue prácticamente idéntico. Con el modelo RF, Accel1 obtuvo una prueba *AUC* de 0.949, mientras que Accel2 alcanzó 0.948.
- **A 25.0 Hz**, Accel1 mostró una ligera ventaja con una prueba *AUC* de 0.965 frente al 0.954 de Accel2, aunque las métricas de validación cruzada (*CV Accuracy*) no mostraron diferencias estadísticamente significativas ( $p$ -valor > 0.05).

La equivalencia entre ambos sensores fue corroborada más allá de las métricas de clasificación. El número de componentes PCA necesarios para explicar el 95% de la varianza también resultó ser casi idéntico para ambos en todas las frecuencias, lo que sugiere una complejidad intrínseca de la señal muy similar. Dada esta alta consistencia en los resultados, se concluyó que ambos sensores son igualmente competentes para esta tarea. Por consiguiente, con el fin de evitar redundancia y centrar la narrativa en el hallazgo principal del estudio —el impacto de la frecuencia de muestreo—, se tomó la decisión metodológica de presentar los resultados detallados de los análisis subsiguientes (Análisis #3 y #4) utilizando exclusivamente los datos del sensor Accel1 como representante.

## Capítulo 4. Discusión

---

Este capítulo tiene como objetivo interpretar los resultados presentados en el Capítulo 3, contextualizándolos dentro de los objetivos e hipótesis planteados en la Sección 1.4 y 1.5, y en relación con la metodología descrita en el Capítulo 2. Se discutirán las implicaciones de los hallazgos sobre el impacto de la frecuencia de muestreo, la efectividad de los conjuntos de características y la comparativa entre las IMUs en la clasificación de estilos de manejo.

### 4.1 Validación de la estrategia de etiquetado y relevancia para la clasificación

Las conclusiones de este estudio se fundamentan en una premisa que fue rigurosamente validada en las fases iniciales de la investigación: las etiquetas de estilo de manejo autorreportadas por los conductores son un reflejo fiable de comportamientos cinemáticos diferenciables y medibles.

Como se demostró en las Secciones 3.1 y 3.2, las percepciones subjetivas ("Agresivo" y "Cauteloso") se manifiestan consistentemente en métricas objetivas como el Índice de Aceleración Lateral (IAL) y las distribuciones de riesgo modeladas por KDE. El establecimiento de esta correlación inequívoca fue un paso metodológico crítico, pues confirió a las etiquetas el estatus de *referencia válida*. Esta validación es el pilar que otorga significado a los resultados de clasificación y permite interpretar con confianza el impacto de variables como la frecuencia de muestreo y la selección de características.

### 4.2 Impacto de la frecuencia de muestreo en la precisión de la clasificación

La hipótesis central del estudio, que postulaba un impacto significativo de la frecuencia de muestreo, se confirma. Además, los resultados revelan una relación profunda y no lineal. La frecuencia de muestreo no es un simple parámetro de ajuste; es el factor fundamental que gobierna el paradigma de la clasificación, dictando qué características son físicamente representables en la señal y, por ende, qué nivel de abstracción puede alcanzar el modelo. Este impacto se puede segmentar en cuatro regímenes operativos distintos.

#### 4.2.1 Baja tasa de muestreo (Frecuencias por debajo de 0.5 Hz)

En este régimen, la clasificación fracasa no por una debilidad del modelo, sino porque una frecuencia de muestreo de menos de 1 muestra por segundo no captura la dinámica del fenómeno estudiado, lo que implica información insuficiente en la propia señal. A frecuencias como 0.1 Hz, la resolución temporal es pobre para capturar la dinámica del fenómeno, por ejemplo, una maniobra (como un giro o una frenada) que puede durar 1 o 2 segundos puede perderse en un periodo de muestreo de 10 segundos. El sistema, al no tener referencia de la secuencia y forma de los eventos, se ve forzado a depender de características estáticas y agregadas, como las correlaciones inter-eje. Estas métricas no describen la maniobra, sino una tendencia general del vehículo, perdiendo todo el poder discriminatorio. La baja dimensionalidad intrínseca de los datos en este rango (explicada por solo 3 componentes PCA), es la prueba definitiva de esta baja densidad de información, hace inviable cualquier clasificación fiable de la dinámica de conducción.

#### 4.2.2 El Umbral de viabilidad (0.5 Hz - 1.0 Hz)

Este rango marca un punto de inflexión crítico. A partir de 0.5 Hz, y consolidándose en 1.0 Hz, la densidad de puntos comienza a ser suficiente para que la señal deje de ser una colección de muestras aisladas y empiece a trazar un perfil temporal reconocible. El sistema ya no está ciego; ahora puede "ver" las características básicas de las maniobras. Este cambio fundamental se refleja directamente en la selección de características: el modelo abandona las métricas puramente estáticas y comienza a seleccionar descriptores más sofisticados que capturan la distribución de la aceleración (cuantiles) y la variación temporal (como la desviación estándar del jerk). Se establece así un umbral mínimo de viabilidad: por debajo de esta frecuencia, la caracterización de estilos de manejo con los métodos empleados es simplemente imposible; por encima, se vuelve factible.

#### 4.2.3 La Meseta de rendimiento recomendado (1.0 Hz - 25.0 Hz)

Dentro de este rango se encuentra el equilibrio ideal entre la riqueza de la información y la eficiencia de los recursos. El rendimiento de la clasificación alcanza una meseta alta y estable (Test AUC consistentemente superiores a 0.90-0.95), demostrando que estas frecuencias capturan la dinámica relevante de la conducción con una fidelidad excepcional. La resolución temporal es lo suficientemente

alta para desbloquear un conjunto de características informativas de diferentes dominios (temporales, espectrales y de magnitud). El sistema de selección de características (SFFS) permite una elección adaptativa entre las alternativas que se describen a continuación:

- **Características espectrales (PSD bins):** La señal ahora tiene la resolución necesaria para analizar su contenido en frecuencia.
- **Características temporales detalladas (jerk, cuantiles):** Ahora capturan matices más finos en lugar de solo tendencias generales.
- **Características de magnitud:** Describen la intensidad del movimiento con gran precisión.

La capacidad de los modelos para aprovechar esta rica mezcla de dominios demuestra que, en este rango, la señal es dimensionalmente rica y altamente informativa, permitiendo una clasificación robusta y precisa.

#### 4.2.4 La Zona de mejores en rendimientos marginales y redundancia (25.0 Hz - 50.0 Hz)

Si bien las frecuencias más altas mantienen un rendimiento excelente y estable, con métricas clave como la prueba AUC que se sitúan consistentemente por encima de 0.95 (alcanzando picos de hasta 0.979 según el Análisis #4), las ganancias en precisión se vuelven marginales. Por ejemplo, la mejora de una prueba AUC de 0.951 a 5 Hz a uno de 0.976 a 50 Hz, aunque positiva, puede no justificar el aumento exponencial en el volumen de datos y el coste computacional para muchas aplicaciones prácticas. Curiosamente, el ligero descenso en el número de componentes PCA necesarios para explicar el 95% de la varianza — pasando de 41 componentes a 10 Hz a solo 35 componentes a 50 Hz, según los datos del Análisis #4— sugiere que la información adicional se vuelve cada vez más correlacionada o redundante. Para la tarea específica de clasificar el estilo general de una maniobra, que ocurre en escalas de tiempo de segundos o décimas de segundo, muestrear a 50 Hz no añade necesariamente más información discriminativa que muestrear a 25 Hz.

En resumen, la frecuencia de muestreo es la variable maestra que dicta el paradigma de la clasificación. Este estudio establece con contundencia que para aplicaciones de monitoreo de conducción con IMUs de

bajo costo, la estrategia más ventajosa es operar dentro del rango de 5.0 Hz a 10.0 Hz. Esta gama de frecuencias garantiza una clasificación robusta y precisa al equilibrar de manera efectiva la captura de información dinámica con la eficiencia de los recursos, evitando tanto la pérdida de datos críticos a bajas frecuencias como la redundancia de datos a frecuencias muy altas.

### 4.3 Eficacia de los conjuntos de características y estrategias de selección

Los diferentes análisis exploraron la utilidad de varios conjuntos de características:

- **"Vaitkus-Inspired" (13 características, Análisis #1):** Demostró un potencial discriminatorio razonable (F1-Score RF  $\sim 0.823$  en DB\_Curvas\_BIN), validando su aplicabilidad como línea base.
- **"Zylius-OPTIM" (6 características, Análisis #2):** Sorprendentemente, este conjunto compacto superó al anterior (F1-Score RF  $\sim 0.962$  en DB\_Curvas\_BIN), destacando la eficacia de características bien seleccionadas como la desviación estándar del jerk y cuantiles específicos. Esto refuerza la idea de que no siempre más características equivalen a mejor rendimiento.
- **"Zylius-Inspired" Completo (78 características con SFFS, Análisis #3):** La combinación de un conjunto diverso y una selección adaptativa por SFFS (seleccionando típicamente 7 características) demostró ser muy robusta, alcanzando rendimientos superiores a 0.95.
- **Conjunto Extendido (240 características con SFFS, Análisis #4):** Este enfoque exhaustivo logró rendimientos superiores, especialmente con KNN a 10Hz. La SFFS fue crucial para manejar la alta dimensionalidad, seleccionando consistentemente un subconjunto pequeño (9-15 características) de descriptores informativos.

La variabilidad en las características seleccionadas por SFFS a través de diferentes frecuencias (Secciones 3.5.3 y 3.5.4) subraya la importancia de un enfoque adaptativo. Características espectrales ganaron relevancia con suficiente resolución frecuencial, mientras que estadísticas temporales o de magnitud fueron cruciales en general.

## 4.4 Implicaciones prácticas y alineación con objetivos

Los resultados de este estudio tienen implicaciones directas para el diseño y la implementación de sistemas de monitoreo de estilos de manejo basados en IMUs de bajo costo. A continuación, se detalla cómo los resultados abordan sistemáticamente cada uno de los objetivos de investigación planteados, validando las hipótesis y sentando bases concretas para aplicaciones futuras.

El primer objetivo era evaluar y validar la estrategia de clasificación basada en la autoevaluación del conductor. Este pilar fundamental se alcanzó con éxito, estableciendo una base empírica sólida para todos los análisis posteriores. Los resultados de las Secciones 3.1 y 3.2 demostraron de manera concluyente que las etiquetas subjetivas ("Agresivo", "Normal", "Cauteloso") no son arbitrarias, sino que se correlacionan fuertemente con métricas cinemáticas objetivas. Por ejemplo, los recorridos etiquetados como "Agresivo" mostraron consistentemente valores más altos del Índice de Aceleración Lateral (IAL) y distribuciones de densidad (KDE) con mayor dispersión y valores esperados más elevados. Esta validación rigurosa nos permitió utilizar las etiquetas autorreportadas como una referencia fiable para el entrenamiento y la evaluación de los modelos de clasificación.

El segundo y tercer objetivo particular, que consistían en determinar el impacto de la frecuencia de muestreo y establecer un umbral mínimo, así como un rango de operación recomendado, fueron los ejes centrales de la investigación. Los análisis cuantitativos confirmaron de manera contundente la hipótesis de que la frecuencia de muestreo tiene un impacto significativo y no lineal en la precisión de la clasificación. Se identificó un umbral crítico de viabilidad entre 0.5 Hz y 1.0 Hz, por debajo del cual el rendimiento se degrada drásticamente. A 0.1 Hz, por ejemplo, la prueba AUC se desplomó a valores de  $\sim 0.70-0.80$ , y el sistema solo podía recurrir a características estáticas como las correlaciones inter-eje, perdiendo toda la información dinámica.

En contraste, se estableció un rango de operación de alta efectividad entre 1.0 Hz y 25.0 Hz. Dentro de este, se observó que los modelos (tanto KNN como RF) lograron rendimientos consistentemente altos, con Test AUCs que frecuentemente superaban el 0.95. Se precisó además que el rango de 5.0 a 10.0 Hz ofrece un excelente equilibrio entre rendimiento y eficiencia, mientras que el rango de 10.0 a 25.0 Hz permite alcanzar la máxima precisión. Si bien extender la frecuencia hasta 50 Hz mantenía este alto rendimiento, las ganancias marginales sugieren que, para muchas aplicaciones, este aumento en la densidad de datos podría no justificar el coste computacional adicional.

Finalmente, el cuarto objetivo particular buscaba desarrollar una guía preliminar para el uso de IMUs de bajo costo, abordando la selección de características y de sensores. Este estudio proporciona directrices claras, especialmente en lo que respecta a las características, donde se plantean dos enfoques. Primero, se demostró que un conjunto pre-optimizado y extremadamente compacto, como el "Zylius-OPTIM" de 6 características, puede ser sorprendentemente efectivo, alcanzando F1-Scores de 0.962 en particiones por curva (Análisis #2). Esto valida el enfoque de "calidad sobre cantidad".

Sin embargo, para una mayor robustez y adaptabilidad a través de diferentes frecuencias, el estudio demostró que la estrategia superior es combinar un repertorio de características más amplio con una selección dinámica como SFFS, la cual eligió consistentemente conjuntos informativos de entre 7 y 15 características (Análisis #3 y #4). Consistentemente, descriptores de magnitud de la aceleración, así como características temporales (jerk, cuantiles) y espectrales (PSD bins), demostraron ser los más relevantes en estos conjuntos adaptativos.

En cuanto a la selección del sensor, el análisis comparativo entre el LSM6DS (Accel1) y el LSM9DS1 (Accel2) reveló una similitud de rendimiento notable. Aunque Accel1 mostró una ventaja marginal en algunas configuraciones, ambos sensores probaron ser igualmente competentes. Esto implica que la elección del sensor puede basarse en factores prácticos como el costo o la disponibilidad, siempre y cuando se opere dentro del rango de frecuencias de alta efectividad ( $\geq 1.0$  Hz) y se utilice un conjunto de características adecuado. En resumen, este estudio no solo cuantifica el "qué" y el "cuánto" del impacto de la frecuencia, sino que también proporciona una orientación práctica para el diseño de sistemas eficientes y precisos.

#### **4.5 Conclusión general en respuesta a la hipótesis**

La hipótesis de que "El impacto de la frecuencia de muestreo en la calidad y representatividad de los datos de IMUs de bajo costo ( $\pm 2g$ ) para el análisis del estilo de manejo (agresivo vs. no agresivo) es significativo" se confirma plenamente. Se ha demostrado que la relevancia y el poder discriminativo de las características extraídas dependen directamente de la frecuencia de muestreo. En otras palabras, la utilidad de una característica para diferenciar estilos de manejo no es absoluta, sino que varía según la resolución temporal de la señal, ya que esta determina qué dinámicas de la conducción (rápidas o lentas) son capturadas. Específicamente, se identificó un umbral mínimo de frecuencia de muestreo (entre 0.5 Hz y 1.0 Hz) por debajo del cual la clasificación se degrada significativamente.

Asimismo, se estableció un rango óptimo de frecuencias, aproximadamente de 1.0 Hz a 25.0 Hz, con extensiones hasta 50 Hz, que permite la extracción de características robustas y fiables, equilibrando la precisión de la clasificación con la eficiencia de recursos. Las variaciones en el rendimiento de los algoritmos de clasificación al utilizar datos muestreados a distintas frecuencias cuantificaron la magnitud de este impacto, validando la importancia de este parámetro en el diseño de sistemas de monitoreo de conducción.

## Capítulo 5. Conclusiones

---

Este capítulo final resume las conclusiones sobre los resultados clave de la investigación, evalúa el cumplimiento de los objetivos propuestos y la validación de la hipótesis central. Además, se discuten las implicaciones generales de los resultados, las limitaciones del estudio y se proponen líneas de investigación para futuros trabajos en el campo de la monitorización de estilos de manejo mediante IMUs de bajo costo.

### 5.1 Resumen general del estudio

La presente investigación propuso evaluar de manera sistemática el impacto de la frecuencia de muestreo y la selección de características sobre el desempeño de las IMUs de bajo costo (específicamente el LSM6DS y LSM9DS1 con un rango de  $\pm 2g$ ) para clasificar estilos de manejo "Agresivo" vs. "No Agresivo". Ante la ausencia de un consenso claro en la literatura sobre los parámetros de operación más efectivos para estos sensores en aplicaciones automotrices, este estudio buscó proporcionar evidencia empírica para guiar el diseño de sistemas de monitoreo más eficientes y accesibles, contribuyendo a la mejora de la seguridad vial y la eficiencia en la movilidad.

### 5.2 Conclusiones respecto a los objetivos del estudio

Se evaluó el cumplimiento de cada objetivo específico planteado:

**Evaluar y validar objetivamente la clasificación de estilos de manejo basada en la autoevaluación del conductor utilizando métricas de (IAL) y GPS:** Este objetivo fue alcanzado exitosamente. Los análisis detallados en las Secciones 3.1 y 3.2, utilizando el Índice de Aceleración Lateral (IAL) y la Estimación de Densidad Kernel (KDE), demostraron una correlación robusta y consistente entre las etiquetas de estilo de manejo autorreportadas y las métricas cinemáticas objetivas. Esto validó la estrategia de etiquetado como una referencia fiable para los análisis de clasificación.

**Determinar el impacto de la frecuencia de muestreo en la clasificación del estilo de manejo con IMUs de bajo costo:** Este objetivo, eje central del estudio, fue alcanzado plenamente. Como se discutió en detalle

en la Sección 4.2, se demostró una relación no lineal y significativa entre la frecuencia de muestreo y el rendimiento de la clasificación, identificándose una degradación considerable del rendimiento a frecuencias inferiores a 0.5 Hz y una estabilización del alto rendimiento a partir de 1.0 Hz.

**Determinar el umbral mínimo de frecuencia de muestreo y el rango de frecuencias más efectivo para lograr una clasificación precisa:** Este objetivo fue alcanzado con claridad. Se identificó un umbral mínimo de viabilidad entre 0.5 Hz y 1.0 Hz, por debajo del cual la clasificación efectiva se ve comprometida. Se determinó un rango de operación preferente entre 1.0 Hz y 25.0 Hz, donde se logra un rendimiento alto y estable. Para aplicaciones prácticas, se recomienda un rango de 5.0 a 10.0 Hz por su equilibrio entre precisión y eficiencia, mientras que el rango de 10.0 a 25.0 Hz es el más adecuado para maximizar la precisión. Las extensiones hasta 50 Hz mantienen la alta precisión, pero con ganancias marginales.

**Desarrollar una guía de recomendaciones preliminares para la selección y uso de IMUs de bajo costo en sistemas de detección de eventos y estilos de manejo, incluyendo características mínimas, rangos más efectivos y consideraciones de frecuencia de muestreo:** Este objetivo fue alcanzado, sentando bases sólidas. Se ofrecen las siguientes recomendaciones:

**Frecuencia de Muestreo:** Para un equilibrio entre rendimiento y eficiencia, frecuencias entre 5 Hz y 10 Hz son recomendables. Para maximizar la precisión, operar entre 10 Hz y 25 Hz es viable. Se debe evitar operar por debajo de 1.0 Hz.

**Selección de Características:** Conjuntos compactos y bien seleccionados (como el de 6 características "Zylius-OPTIM") pueden ser altamente efectivos. Sin embargo, para una mayor robustez, una estrategia que combina un conjunto amplio de características con una selección adaptativa (SFFS) es superior. Descriptores de magnitud de la aceleración, jerk, cuantiles y densidad espectral de potencia (PSD) demostraron ser consistentemente los más informativos.

**Unidad de medición inercial:** Los sensores LSM6DS (Accel1) y LSM9DS1 (Accel2) demostraron ser igualmente competentes. La elección entre ellos puede basarse en factores prácticos como el costo o la disponibilidad, siempre que se operen a frecuencias apropiadas.

### 5.3 Conclusión respecto a la hipótesis del estudio

La hipótesis central de esta investigación fue: "El impacto de la frecuencia de muestreo en la calidad y representatividad de los datos de las IMUs de bajo costo ( $\pm 2g$ ) para el análisis del estilo de manejo (agresivo vs. no agresivo) es significativo. Se propone que las características extraídas de señales muestreadas a diferentes frecuencias poseerán diferente poder discriminativo. Específicamente, se espera identificar un umbral mínimo y un rango de frecuencias de alta efectividad que permitan la extracción de características robustas y fiables."

Esta hipótesis se confirma contundentemente. Los resultados demostraron de manera inequívoca que la frecuencia de muestreo no es un simple parámetro técnico, sino el factor determinante que modula la información cinemática disponible, dictando tanto la capacidad de clasificación del sistema como, la naturaleza misma de las características relevantes.

La frecuencia de muestreo tuvo un efecto determinante en la configuración del espacio de características discriminativas, modificando la representación informativa de los datos relevantes para la clasificación. A medida que la frecuencia de muestreo se reducía, no solo disminuía el rendimiento, sino que cambiaba drásticamente qué información era útil, por ejemplo:

- **A frecuencias muy bajas (0.1 Hz)**, la señal perdía su estructura temporal, provocando un colapso informativo. El modelo, incapaz de discernir la dinámica de una maniobra, se veía forzado a recurrir a descriptores de muy bajo nivel, como las correlaciones estáticas inter-eje, perdiendo todo poder discriminatorio.
- **Al alcanzar el umbral de viabilidad (0.5 - 1.0 Hz)**, la señal adquiría la resolución suficiente para que emergieran características temporales básicas. La desviación estándar del jerk y los cuantiles se volvieron repentinamente relevantes, indicando que el modelo ahora podía "ver" la variabilidad y la distribución de las aceleraciones dentro de una maniobra.
- **En el rango recomendado (1.0 Hz a 25.0 Hz)**, la riqueza de la señal permitió la explotación de un conjunto de características sofisticado y diverso. El poder discriminativo se distribuyó entre descriptores temporales, de magnitud y, crucialmente, características espectrales (como la densidad espectral de potencia o PSD), cuya utilidad es una consecuencia directa de la alta resolución temporal.

En definitiva, la investigación demostró que la importancia de una característica está directamente condicionada por la frecuencia de muestreo. El cambio en las características seleccionadas a través de las diferentes frecuencias corroboró que la frecuencia gobierna qué aspectos de la dinámica de conducción son observables y, en consecuencia, explotables para la clasificación.

## 5.4 Implicaciones generales y contribuciones del estudio

Este estudio trasciende la mera presentación de resultados para ofrecer contribuciones significativas y aplicables en los ámbitos práctico, metodológico y científico. Los hallazgos validan empíricamente cómo una comprensión profunda de los parámetros de adquisición de datos, específicamente la frecuencia de muestreo es fundamental para el diseño de sistemas de monitoreo de conducción eficientes y precisos.

### 5.4.1 Contribuciones prácticas: optimización de recursos y viabilidad comercial

La contribución práctica más relevante es la validación empírica de que no es necesario operar los sensores a su máxima frecuencia para alcanzar un rendimiento de clasificación óptimo. Esta conclusión se opone a la intuición común de "más datos es mejor" y tiene profundas implicaciones económicas y técnicas. Para ilustrar este punto, los resultados del Análisis #4 (Tabla 12) son contundentes:

- **Rendimiento recomendado a Frecuencia reducida:** Un sistema operando a 10 Hz alcanza un Test AUC de 0.987 con el clasificador KNN. Este rendimiento es excepcional y, de hecho, superior al obtenido a la máxima frecuencia de 50 Hz (Test AUC de 0.956). Este hallazgo demuestra que existe un punto de rendimiento decreciente y que la optimización de la frecuencia es más efectiva que el simple incremento de la densidad de datos.
- **Implicaciones directas de la optimización de frecuencia:** La decisión de operar a 10 Hz en lugar de 50 Hz, sin sacrificar la precisión, genera beneficios cuantificables:
- **Reducción de datos y costos:** Se logra una reducción del 80% en el volumen de datos generados. Esta disminución impacta directamente en los costos operativos al reducir las necesidades de almacenamiento en la nube, el ancho de banda para transmisión (crítico en aplicaciones IOT con planes de datos 4G/5G) y la carga computacional en el dispositivo.

- **Eficiencia energética:** La reducción del 80% en la tasa de datos implica una reducción proporcional estimada en el consumo de potencia asociado a las tareas de muestreo, procesamiento y transmisión. Este es un factor crítico para dispositivos telemáticos alimentados por batería, donde la extensión de la vida útil es un objetivo primordial de diseño.
- **Viabilidad comercial y accesibilidad:** La viabilidad comercial de cualquier sistema de monitoreo depende de su capacidad para ofrecer un alto rendimiento a un bajo costo. Este estudio demuestra que es posible:
  - Utilizar IMUs de bajo costo, cuyo precio unitario se encuentra en el rango de \$1-5 USD, en lugar de alternativas de grado industrial que pueden costar cientos de dólares.
  - Lograr una clasificación de élite (>98% AUC) con este hardware económico y, crucialmente, con un 80% menos de recursos de datos. Esto hace que la tecnología sea altamente escalable, competitiva y accesible para una implementación masiva en flotillas de cualquier tamaño, democratizando el acceso a sistemas avanzados de seguridad vial.

#### 5.4.2 Contribuciones metodológicas

Este trabajo ofrece un marco robusto y sistemático para evaluar el impacto de los parámetros de los sensores en tareas de clasificación complejas. La metodología, que abarca desde la validación de etiquetas subjetivas con métricas cinemáticas objetivas (Secciones 3.1 y 3.2) hasta el análisis multifrecuencia con selección adaptativa de características (SFFS), establece un precedente metodológico para futuras investigaciones. Demuestra un camino riguroso para pasar de datos brutos a conclusiones aplicables, asegurando que las decisiones de diseño se basen en evidencia empírica.

#### 5.4.3 Contribuciones científicas

En el plano científico, la investigación profundiza en la comprensión de la relación fundamental entre la resolución temporal de los datos y la naturaleza de la información discriminativa. El hallazgo clave es que la "importancia" de una característica no es una propiedad estática, sino que es gobernada directamente por la frecuencia de muestreo.

Como se ilustra en el Paisaje de Relevancia de Características (Figura 24), el estudio mapea esta dinámica: a frecuencias muy bajas ( $<0.5$  Hz), el sistema se ve forzado a depender de métricas estáticas y agregadas. Al cruzar el umbral de viabilidad (0.5 - 1.0 Hz), emergen descriptores temporales básicos. Finalmente, en el rango óptimo (a partir de 5.0 Hz), el sistema puede explotar un repertorio rico y equilibrado de características de los dominios temporal, espectral y de magnitud, que son cruciales para una discriminación robusta de los estilos de manejo. Esto confirma que la frecuencia de muestreo no solo afecta la precisión, sino que redefine qué aspectos de la física de la conducción son observables y, por tanto, explotables.

## **5.5 Reflexión final: la importancia de la capa física en la era del aprendizaje automático**

En la era actual del aprendizaje automático, es posible abordar problemas complejos adoptando un enfoque de "caja negra". Sin embargo, esta investigación subraya una lección fundamental que a menudo se pasa por alto: la optimización más significativa no reside únicamente en la arquitectura del modelo, sino en la comprensión profunda de la capa física de la que emanan los datos.

Confiar ciegamente en que "más datos es mejor" nos habría llevado a la conclusión trivial de muestrear siempre a la frecuencia más alta posible (50 Hz). En cambio, al analizar la naturaleza física de las maniobras de conducción —eventos que se desarrollan en escalas de segundos y décimas de segundo—, este estudio demostró que existe un claro punto de rendimiento decreciente.

Se identificó un rango de operación de alta efectividad (entre 1.0 Hz y 10.0 Hz) que captura toda la información discriminativa esencial. Operar a 10 Hz, por ejemplo, ofrece un rendimiento casi idéntico al de 50 Hz, pero con una reducción del 80% en el volumen de datos y en el coste computacional asociado. Este es un ejemplo tangible de cómo una decisión informada en la capa física, previa a la ingesta de datos, conduce a sistemas drásticamente más eficientes sin sacrificar la fiabilidad.

Por lo tanto, este trabajo no solo proporciona lineamientos prácticos para el diseño experimental, sino que también enfatiza un principio fundamental, el aprovechamiento del conocimiento del dominio es clave para optimizar las estrategias de adquisición de datos y maximizar la relevancia de la información capturada. El objetivo no debe ser simplemente alimentar a los modelos con "big data", sino con "smart

data", datos cuya estructura y resolución han sido deliberadamente alineadas con las características del fenómeno que se pretende analizar.

## 5.6 Limitaciones del estudio

Es importante reconocer las siguientes limitaciones:

- **Tamaño de la muestra de conductores:** El estudio se basó en 6 conductores voluntarios. Una muestra más grande y diversa podría revelar variabilidades interindividuales adicionales.
- **Entorno controlado:** Los experimentos se realizaron en un circuito cerrado (PIIT). Los resultados podrían no generalizarse directamente a la conducción en entornos naturalistas con mayor variabilidad.
- **Simulación de frecuencias de muestreo:** El diezmado simple se utilizó para aislar el efecto de la densidad de puntos. Esta aproximación conlleva un riesgo residual de *aliasing* que difiere de un sistema con filtros anti-aliasing ideales.
- **Clasificación Binaria:** El estudio se centró en una clasificación binaria (agresivo vs. no agresivo). La discriminación de estilos más granulares podría requerir diferentes enfoques.

## 5.7 Recomendaciones para trabajos futuros

Basándose en los resultados y limitaciones, se sugieren las siguientes líneas de investigación:

- **Ampliación de la base de datos:** Replicar el estudio con un mayor número de conductores y una mayor diversidad demográfica.
- **Estudios en entornos naturalistas:** Validar los resultados utilizando datos de conducción recopilados en diferentes condiciones de tráfico y carretera.

- **Análisis de filtros anti-aliasing:** Investigar comparativamente el efecto de aplicar filtros anti-aliasing explícitos antes del diezmado.
- **Clasificación multiclase:** Extender el análisis a un espectro más amplio de estilos de manejo (e.g., distraído, somnoliento).
- **Implementación en tiempo real:** Explorar la viabilidad de implementar los modelos y frecuencias recomendadas en sistemas embebidos, considerando el consumo energético.

## Literatura citada

- Ahmad, N., Ghazilla, R. A. R., Khairi, N. M., & Kasi, V. (2013). Reviews on various inertial measurement unit (IMU) sensor applications. *International Journal of Signal Processing Systems*, 1(2), 256-262. <https://doi.org/10.12720/ijsps.1.2.256-262>
- Andria, G., Attivissimo, F., Di Nisio, A., Lanzolla, A., & Pellegrino, A. (2016). Development of an automotive data acquisition platform for analysis of driving behavior. *Measurement*, 93, 278-287. <https://doi.org/10.1016/j.measurement.2016.07.035>
- Balla, E. (2025, enero 3). F1 G-Force: How Many G's Can A F1 Car Pull? - F1 Explained. <https://f1chronicle.com/f1-g-force-how-many-gs-can-a-f1-car-pull/>
- Banco Mundial. (2018, enero 9). Las muertes y lesiones causadas por accidentes de tránsito frenan el crecimiento económico de los países en desarrollo. <https://www.bancomundial.org/es/news/press-release/2018/01/09/road-deaths-and-injuries-hold-back-economic-growth-in-developing-countries>
- Bouhsissin, S., Sael, N., & Benabbou, F. (2023). Driver behavior classification: A systematic literature review. *IEEE Access*, 11, 14128-14153. <https://doi.org/10.1109/ACCESS.2023.3243865>
- Broughall, Matt. (2020, noviembre 5). What is g-force and how is it related to harsh driving? | Geotab. <https://www.geotab.com/blog/what-is-g-force>
- Chen, Y., Wang, K., & Lu, J. J. (2023). Feature selection for driving style and skill clustering using naturalistic driving data and driving behavior questionnaire. *Accident Analysis & Prevention*, 185, 107022. <https://doi.org/10.1016/j.aap.2023.107022>
- Davis, G. A., & Aul, N. (2007). Safety Effects of Left-Turn Phasing Schemes at High-Speed Intersections (Final Report, Minnesota Local Road Research Board No. 200703). Minnesota Department of Transportation, Research Services Section. <https://www.lrrb.org/pdf/200703.pdf>
- de Oliveira, R. H., Loprencipe, G., de Almeida Filho, F. G. V., & de Sousa Pissardini, R. (2022). Experimental investigation on the use of multiple very low-cost inertial-based devices for comfort assessment and rail track monitoring. *Measurement*, 199, 111549. <https://doi.org/10.1016/j.measurement.2022.111549>
- Dettù, F., Formentin, S., & Savaresi, S. M. (2022). Driving Style Assessment System for Agricultural Tractors: Design and Experimental Validation. *Agronomy*, 12(3), 590. <https://doi.org/10.3390/agronomy12030590>
- Deubel, C., Ernst, S., & Prokop, G. (2023). Objective evaluation methods of vehicle ride comfort— A literature review. *Journal of Sound and Vibration*, 548, 117515. <https://doi.org/10.1016/j.jsv.2022.117515>

- Dong, D., & Li, Z. (2021). Smartphone sensing of road surface condition and defect detection. *Sensors*, 21(16), 5433. <https://doi.org/10.3390/s21165433>
- Dorantes Argandar, G. (2018). Validación de un Inventario de Comportamientos Agresivos en el Tránsito. *Revista Internacional de Psicología*, 16(01), 1-57. <https://doi.org/10.33670/18181023.v16i01.256>
- Fernández, R. (2024, mayo 22). Industria logística: Tamaño mundial del mercado hasta 2028 | *Statista*. <https://es.statista.com/estadisticas/1406171/tamano-de-la-industria-logistica-a-nivel-mundial/>
- Ferreira, J., Carvalho, E., Ferreira, B. V., de Souza, C., Suhara, Y., Pentland, A., & Pessin, G. (2017). Driver behavior profiling: An investigation with different smartphone sensors and machine learning. *PLoS one*, 12(4), e0174959. <https://doi.org/10.1371/journal.pone.0174959>
- Géron, A. (2022). Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. (3a ed.) O'Reilly Media, Inc.
- Gillespie, T. (2021). Fundamentals of vehicle dynamics. (2a ed.) SAE international.
- Gonzalez, A. B. R., Wilby, M. R., Diaz, J. J. V., & Ávila, C. S. (2014). Modeling and detecting aggressiveness from driving signals. *IEEE Transactions on intelligent transportation systems*, 15(4), 1419-1428. <https://doi.org/10.1109/TITS.2013.2297057>
- International Energy Agency (IEA). (2021, mayo). Net Zero by 2050 – Analysis—IEA. <https://www.iea.org/reports/net-zero-by-2050>
- International Energy Agency (IEA). (2023, marzo). CO2 Emissions in 2022 – Analysis—IEA. <https://www.iea.org/reports/co2-emissions-in-2022>
- Jachimczyk, B., Dziak, D., Czapla, J., Damps, P., & Kulesza, W. J. (2018). IoT on-board system for driving style assessment. *Sensors*, 18(4), 1233. <https://doi.org/10.3390/s18041233>
- National Highway Traffic Safety Administration (NHTSA). (2024). Speeding: 2022 Data (No. DOT HS 813 582; Traffic Safety Facts). U.S. Department of Transportation, National Highway Traffic Safety Administration, National Center for Statistics and Analysis. <https://crashstats.nhtsa.dot.gov/Api/Public/ViewPublication/813582.pdf>
- Ojeda, L., & Borenstein, J. (2007). Non-GPS navigation for security personnel and first responders. *The Journal of Navigation*, 60(3), 391-407. <https://doi.org/10.1017/S0373463307004286>
- Organización Mundial de la Salud (OMS). (2023, diciembre 13). Traumatismos causados por el tránsito. <https://www.who.int/es/news-room/fact-sheets/detail/road-traffic-injuries>
- Parker, D., Reason, J. T., Manstead, A. S., & Stradling, S. G. (1995). Driving errors, driving violations and accident involvement. *Ergonomics*, 38(5), 1036-1048. <https://doi.org/10.1080/00140139508925170>

- Poo, F., Montes, S., & Ledesma, R. (2008). Conducción agresiva. Delimitación y definición conceptual del fenómeno. *XV Jornadas de Investigación y Cuarto Encuentro de Investigadores en Psicología del Mercosur*. <https://www.aacademica.org/000-032/190>
- Pretorius, L. (2022, mayo 15). Formula 1 vs. Jet Fighter—One Stop Racing. <https://onestopracing.com/formula-1-vs-jet-fighter/>
- Quintanilla, J. R. G., & Rivera, M. E. L. (2017). Factores psicosociales y comportamiento agresivo al conducir correlacionados con accidentes de tránsito en conductores salvadoreños. *Entorno*, 64, 9-19. <https://doi.org/10.5377/entorno.v0i64.6056>
- Reason, J., Manstead, A., Stradling, S., Baxter, J., & Campbell, K. (1990). Errors and violations on the roads: A real distinction? *Ergonomics*, 33(10-11), 1315-1332. <https://doi.org/10.1080/00140139008925335>
- Savitzky, A., & Golay, M. J. (1964). Smoothing and differentiation of data by simplified least squares procedures. *Analytical chemistry*, 36(8), 1627-1639. <https://doi.org/10.1021/ac60214a047>
- Siddiqui, A., Khan, M. R., Rashid, R. M., & Khan, M. A. (2024). Industry 4.0 Adoption in Transportation: Does Industry 4.0 Adoption Enhance Sustainability? A Systematic Literature Review. *International Journal of Supply and Operations Management*, 11(2), 231-249. <https://doi.org/10.22034/IJSOM.2024.110058.2852>
- Tewelde, G. S. (2012). Sensor and network technology for intelligent transportation systems. 2012 *IEEE International Conference on Electro/Information Technology*, 1-7. <https://doi.org/10.1109/EIT.2012.6220735>
- Tselentis, D. I., & Papadimitriou, E. (2023). Driver profile and driving pattern recognition for road safety assessment: Main challenges and future directions. *IEEE Open Journal of Intelligent Transportation Systems*, 4, 83-100. <https://doi.org/10.1109/OJITS.2023.3237177>
- Vaitkus, V., Lengvenis, P., & Žylius, G. (2014). Driving style classification using long-term accelerometer information. *2014 19th international conference on methods and models in automation and robotics (MMAR)*, 641-644. <https://doi.org/10.1109/MMAR.2014.6957429>
- Welch, G., & Bishop, G. (1995). An introduction to the Kalman filter (TR 95-041). *Department of Computer Science, University of North Carolina at Chapel Hill*. [https://www.cs.unc.edu/~welch/media/pdf/kalman\\_intro.pdf](https://www.cs.unc.edu/~welch/media/pdf/kalman_intro.pdf)
- Woodman, O. J. (2007). An introduction to inertial navigation. *University of Cambridge, Computer Laboratory*. <https://doi.org/10.48456/tr-696>
- Zylius, G. (2017). Investigation of route-independent aggressive and safe driving features obtained from accelerometer signals. *IEEE Intelligent Transportation Systems Magazine*, 9(2), 103-113. <https://doi.org/10.1109/MITS.2017.2666583>

## Anexo A Tabla de estudios completa

| Estudio           | Tipo sensor  | Datos  | Modelo sensor | Rango | Freq. Muestreo | Muestras  | Pre-procesamiento  | Eventos                                   | Características   | Selección Características   | Clasificación   | Clasificador  | Resultados   |
|-------------------|--|--|---------------|-------|----------------|---|--|---|---|---|---|---|--|
| Vaitkus (2014)    | Acelerómetro 3 ejes  | aceleración longitudinal, lateral y vertical   | N/A           | N/A   | N/A            | 110 Muestras ruta fija                          | Filtro deslizante  | N/A                                       | 117<br>Tendencia Central, Dispersión, Valores Extremos, etc.  | T de Student + SFFS   | Normal Agresivo   | KNN   | 100 % 7 características.<br><br>98 % valores medios y medianas de la aceleración longitudinal y vertical.  |
| Zylius (2017)     | Acelerómetro 3 ejes  | aceleración (longitudinal, lateral y vertical)   | N/A           | N/A   | 17 Hz.         | 1000 (1) minute signals labeled                 | Mediana móvil  | N/A                                       | Dominio del Tiempo: Histo. corr, DTV, Jerk<br><br>Dominio de la Frecuencia: Pot Espectral 10 Normalizada hamming  | SFFS + Random Forest  | Seguro Agresivo   | RF  | 95.5% 6 características SFFS.<br><br>Más importante desviación estándar del perfil de jerk del eje X.  |
| Ferreira (2017)   | Android Smartphone IMU   | acelerómetro, sensor de aceleración lineal, magnetómetro y giroscopio  | N/A           | N/A   | 50 Hz ~ 100Hz  | 69 Muestras                                     | Traducción del Sistema de Coordenadas<br><br>Ventana Deslizante 1 segundo (frames)   | breaking accel<br>left turn<br>right turn | Media<br>Mediana<br>Desviación Estándar<br>Tendencia  | Probaron todas las combinaciones de MLA   | Agresivo No Agresivo  | Red Neuronal Artificial, SVM, RF, Red Bayesiana (validación cruzada de 10 pliegues) | El RF superó a los otros algoritmos<br><br>tamaños de mejorar el rendimiento<br><br>datos del acelerómetro y el giroscopio mejores resultados  |
| Van Ly (2013)     | sensores inerciales acelerómetro Giroscopio Bus CAN              | aceleración y velocidad angular  | N/A           | N/A   | N/A            | 160 - 413 muestras x evento                     | Detección de Eventos Limpieza de Datos   | breaking accel<br>Turning                 | Histogramación, mínimo, máximo, media, varianza, Duración del Evento  | eventos individuales<br><br>Subconjuntos de Características   | Clusters  | SVM k-Means   | Los histogramas de los datos del sensor no mejoran la precisión de la clasificación en comparación con las características estadísticas por sí solas.<br><br>Vectores de características acortados comparables<br>vectores de características completos<br><br>Eventos de frenado y los eventos combinados de frenado/giro son las características más importantes para distinguir entre conductores |
| Jachimczyk (2018) | Acelerómetro 3 ejes<br><br>Módulo GPS NEO-7M-C. Adaptador OBD-II | Aceleración en ejes x, y, z. Posición GPS. Velocidad del vehículo, velocidad del motor (RPM), tiempo de conducción sin parar, y códigos de diagnóstico | ADXL345       | + 4g  | 12.5Hz         | 6 conductores viaje 16km<br>1 viaje largo 325km | Filtro pasa-bajos Butterworth de 4° orden para señales de aceleración en los ejes x y y, con una frecuencia de corte de 0.8 Hz.<br><br>Filtro pasa-banda Butterworth para la aceleración en el eje z con frecuencias de corte de 0.1 Hz a 0.8 Hz, para eliminar vibraciones y efectos del terreno. | N/A                                       | Relación de aceleración y desaceleración (ry).<br>Relación de baches (rz).<br>Relación de giros (ry).<br>Tiempo de conducción sin descanos (dt).<br>Relación de exceso de velocidad (spr).<br>Duración de exceso de velocidad (spdr).<br>Relación de velocidad de rotación excesiva del motor (rar).<br>Duración de la rotación excesiva del motor (rsdr).          | Seguridad<br>Economía<br>Confort  | Calma<br>Ordinario<br>agresivo/inusual                                    | diagramas tipo araña<br>puntuación normalizada                                      | conductores con un estilo "calmado"<br>puntuaciones cercanas experto<br>estilos "agresivos"<br>puntuaciones bajas en seguridad, economía y confort   |
| Chen (2023)       | IMU GPS Dos cámaras  | Aceleración longitudinal, aceleración lateral, velocidad angular, velocidad del vehículo   | N/A           | N/A   | 10 Hz          | 42 Loops entre 19 drivers                       | Filtro Savitzky-Golay<br><br>División de datos kilómetro de longitud   | DBQ                                       | 72 características<br><br>Estadísticas: Máximo, mínimo, media, varianza, desviación estándar, curtosis, asimetría, pico a pico, valor rectificado promedio, raíz cuadrada media, factor de forma, factor de cresta, factor de impulso, factor de margen, amplitud promedio.<br><br>Frecuencia: Centroides de frecuencia, varianza de frecuencia, entropía espectral | Agrupamiento jerárquico sobre las correlaciones de Spearman<br><br>clasificador XGBoost<br>38 características restantes | Novato<br><br>Experimentado y precavido<br><br>Experimentado e imprudente | Agrupamiento jerárquico   | Se analizaron las cinco características clave para cada clúster, mostrando diferencias significativas. Por ejemplo, el clúster imprudente tuvo una aceleración longitudinal máxima y desviación estándar de velocidad más alta.  |

Figura 28. Tabla de estudios completa

## Anexo B Protocolo Formal de Adquisición de Datos V1.0

**Objetivo del Protocolo:** Describir el procedimiento estandarizado para la recolección de datos inerciales (IMU) y de geolocalización (GPS) de un vehículo Honda Fit Fun 2017 en movimiento, conducido por diferentes pilotos bajo distintos estilos de manejo (normal, precavido, agresivo) en un circuito cerrado, para el posterior análisis y clasificación del estilo de manejo.

**Vehículo:** Honda Fit Fun 2017.

### Unidad de Medición Inercial (IMU):

- **IMU #1:** LSM6DS
- **IMU #2:** LSM9DS1

**Montaje:** Ambas IMUs alojadas en una base impresa en 3D, ubicada en la consola central del vehículo, lo más cerca posible del centro geométrico. La base cuenta con patas de goma para ajustarse a presión en la cavidad y minimizar vibraciones.

**Orientación:** Ejes alineados con el vehículo: Eje Y apuntando hacia adelante, Eje X laterales del coche (depende el modelo de IMU), Eje Z hacia abajo.

### Módulo GPS:

- **Modelo:** U-blox NEO-7M.
- **Montaje:** Antena/módulo ubicado sobre el techo del vehículo, en la parte central, para maximizar la visibilidad de satélites. Fijación mediante base magnética o adhesivo resistente.

### Sistema de Adquisición/Control:

- **Microcontrolador:** ESP32
- **Almacenamiento:** Tarjeta microSD

### Alimentación:

- **Fuente:** Power bank externa de 5V
- **Conexión:** Cable USB estándar conectado al puerto del ESP32.

### Calibración:

- No se aplicó un procedimiento de calibración específico (offset/escala) a las IMUs antes de la adquisición de datos para este conjunto experimental. Se capturaron los datos crudos ("raw data"). Se realizaron mediciones estáticas de referencia para posible calibración a posteriori si fuese necesario durante el análisis.

### Software y Formato de Datos:

- **Software:** Código personalizado desarrollado en el IDE de Arduino para la plataforma ESP32.
- **Frecuencia de Muestreo:** El ESP32 lee y registra datos de todos los sensores (ambas IMUs y GPS) a una frecuencia constante de 50 Hz.
- **Sincronización:** Se utiliza un único timestamp generado por el microcontrolador ESP32 (basado en interrupciones) para cada fila de datos registrada a 50 Hz. Se asume que este timestamp es la referencia temporal común. Nota: La tasa de actualización intrínseca del GPS NEO-7M es típicamente de 1-10 Hz; por lo tanto, los valores de GPS (latitud, longitud, velocidad) se repetirán en varias filas consecutivas del archivo CSV hasta que una nueva lectura esté disponible del módulo.
- **Columnas Registradas:** El archivo CSV contiene las siguientes 16 columnas: time\_(ms), latitude\_(deg), longitude\_(deg), GPS\_speed, Accel\_1\_X, Accel\_1\_Y, Accel\_1\_Z, Gyro\_1\_X, Gyro\_1\_Y, Gyro\_1\_Z, Accel\_2\_X, Accel\_2\_Y, Accel\_2\_Z, Gyro\_2\_X, Gyro\_2\_Y, Gyro\_2\_Z
- **Formato de Archivo:** Archivos .csv delimitados por comas. Se genera un nuevo archivo cada 30 segundos de grabación continua durante un recorrido.

**Entorno y Condiciones:**

- **Lugar:** Circuito cerrado PIIT.
- **Condiciones Ambientales:** Día seco, buena visibilidad, sin lluvia.
- **Condiciones de Tráfico:** Nulas (circuito cerrado).
- **Conductores:** Se contó con la participación de 6 conductores voluntarios (asegurar diversidad de género y rango de edad).
- **Escenarios de Conducción (Estilos por Recorrido):** Cada conductor realizó los siguientes tipos de recorridos:
  1. (1) Recorrido de familiarización con el vehículo y el circuito.
  2. (3) Recorridos bajo instrucción de "conducción normal".
  3. (3) Recorridos bajo instrucción de "conducción precavida" (equivalente a "No Agresivo").
  4. (3) Recorridos bajo instrucción de "conducción agresiva".

**Total:** 10 recorridos por conductor.

**Ejecución:**

1. Un supervisor (alumno) acompaña al conductor en el vehículo.
2. Antes de iniciar cada recorrido, el supervisor se asegura de que el sistema esté encendido y listo.
3. El inicio de la grabación del recorrido se activa mediante la presión de un botón conectado al ESP32.
4. El conductor realiza el recorrido siguiendo las instrucciones del estilo asignado.
5. Al finalizar el recorrido, el supervisor presiona un botón para detener la grabación.
6. Se registra en una bitácora el nombre del conductor, el tipo de recorrido y cualquier observación relevante.

**Etiquetado de Eventos:**

- El etiquetado principal se realiza a nivel de recorrido completo. Cada conjunto de archivos CSV generados durante un recorrido está asociado a uno de los tres estilos de manejo objetivo (Reconocimiento, Normal, Precavido, Agresivo) y al conductor correspondiente.
- No se implementó un sistema para marcar eventos discretos específicos (frenadas, giros individuales) en tiempo real durante la adquisición. El análisis se enfocará en caracterizar segmentos de 30 segundos o recorridos completos según la etiqueta del estilo general.

**Gestión de Desafíos (Soluciones Implementadas):**

- **Sincronización:** A pesar de la diferencia de frecuencias de los distintos sensores mediante el uso de un timestamp común de frecuencia (50 Hz) generado por el ESP32 se sincronizan todas las lecturas, aceptando la repetición de valores en las lecturas de GPS entre sus actualizaciones reales.
- **Ruido:** Se aborda principalmente mediante el montaje físico (base impresa 3D con goma) para minimizar vibraciones mecánicas. El filtrado digital de las señales se realiza en la etapa de post-procesamiento de datos.

**Seguridad:**

1. Se seguirán las normas de seguridad estándar para conducción en circuito cerrado.
2. El supervisor encargado del equipo no interferirá con la conducción.
3. Se establece un límite de velocidad máxima de 60 km/h, incluso durante los recorridos designados como "agresivos", para mantener un margen de seguridad.
4. Verificar la correcta sujeción de todo el equipo dentro del vehículo antes de cada recorrido.

## Anexo C Dispositivo de captura de datos

**Microcontrolador:** ESP32 con procesador Tensilica Xtensa 32-bit LX6 (hasta 240 MHz).

**Memoria:** 448 KB ROM, 520 KB SRAM, 16 MB Flash.

**Conectividad:** Wi-Fi y Bluetooth Low Energy (BLE).

**Bus Modular:** Facilita la integración de nuevas funcionalidades y sensores.

**Protocolo I2C:** Permite conectar múltiples adaptadores y sensores, garantizando escalabilidad.

### Sensores Integrados:

- **IMU de 6 DoF Adafruit LSM6DSOX + LIS3MDL:**
- **Acelerómetro:**
  - Rango:  $\pm 2/\pm 4/\pm 8/\pm 16$  g.
  - Frecuencia de actualización: 1.6 Hz a 6.7 kHz. \*
- **Giroscopio:**
  - Rango:  $125/\pm 250/\pm 500/\pm 1000/\pm 2000$  dps
  - Frecuencia de actualización: 12.5 Hz a 6.7 kHz. \*
- **IMU de 9 DoF Adafruit LSM9DS1:**
- **acelerómetro:**
  - Rango:  $\pm 2/\pm 4/\pm 8/\pm 16$  g.
  - Frecuencia de actualización: Hasta 952 Hz. \*
- **Giroscopio:**
  - Rango:  $\pm 245/\pm 500/\pm 2000$  dps
  - Frecuencia de actualización: Hasta 952 Hz. \*
- **Magnetómetro (NO utilizado):**
  - Rango:  $\pm 4/\pm 8/\pm 12/\pm 16$  gauss
  - Frecuencia de actualización: Hasta 952 Hz. \*
- **NOTA (\*):** Los sensores IMU operan con una frecuencia de actualización interna de hasta 6.7 KHz, pero los datos son muestreados y registrados para fines de generar la base de datos por el microcontrolador a una frecuencia constante de 50 Hz.
- **Módulo GPS NEO-7M:**
  - 56 canales, frecuencia L1 (1575.42 MHz), compatible con SBAS (WAAS/EGNOS/MSAS).
  - **Antena Externa:** Mejora la precisión en la recepción de señales.

### Almacenamiento y Registro:

- **Memoria MicroSD:** Almacenamiento de grandes volúmenes de datos (logs) recopilados por los sensores.
- **Interfaz de Usuario:**
  - **Indicadores:**
    - Visual: LED multicolor para estados del sistema.
    - Auditivo: Buzzer para alertas.
    - Display Numérico: Monitorea el seguimiento de archivos (versión final).
  - **Entradas:**
    - Botones: 1 botón en la versión final (originalmente 2) para interacción.
  - **Alimentación y Regulación:**
    - Entrada USB: Compatible con power banks y eliminadores de coche.
    - Regulador Lineal Externo de 3.3V: Garantiza estabilidad energética para sensores y módulos.

### Mejoras en la Versión Final:

- **Diseño Compacto y Robusto:** Optimizado para portabilidad y durabilidad.

- Integración Directa: Módulo ESP32 soldado a la PCB, reduciendo tamaño y mejorando fiabilidad.
- Conectores de Programación: Jack auxiliar para actualizaciones rápidas.
- **Protección Física:**
  - Soporte 3D: Protege las pistas de la PCB y soporta conectores.
  - Patas de Goma: Minimizar vibraciones y mejoran estabilidad.
- **Aplicaciones:**
  - Ideal para monitoreo en tiempo real de variables físicas (aceleración, orientación, ubicación), logística, IOT industrial, y proyectos que requieren alta modularidad y almacenamiento local.
- **Ventajas Clave:**
  - Escalabilidad gracias al bus I2C y diseño modular.
  - Autonomía con alimentación USB portátil.
  - Precisión reforzada por antena GPS externa y regulador de voltaje dedicado.
  - Robustez en entornos dinámicos (soporte 3D y patas anti vibratorias).

## Anexo D Conjunto Extendido

- **Características del Dominio del Tiempo (para cada eje X, Y, Z, y para Mag):** Este grupo incluye un total de 25 descriptores estadísticos y temporales básicos para cada una de las cuatro señales (X, Y, Z, Mag), aunque la característica DTV solo aplica a X, Y, Z.
  - **Estadísticas de Tendencia Central y Dispersión:**
    - **mean:** Media aritmética.
    - **median:** Mediana.
    - **std:** Desviación estándar.
    - **va:** Varianza.
    - **mad:** Desviación Absoluta Mediana (Median Absolute Deviation).
    - **rms:** Valor Eficaz (Root Mean Square).
    - **coeff\_var:** Coeficiente de Variación ( $\text{std} / |\text{mean}|$ ).
    - **trim\_mean\_10:** Media recortada al 10%.
  - **Estadísticas de Rango y Límites:**
    - **min:** Valor mínimo.
    - **max:** Valor máximo.
    - **range:** Rango ( $\text{max} - \text{min}$ ).
    - **iqr:** Rango Intercuartílico (percentil 75 - percentil 25).
    - **pctl\_10:** Percentil 10.
    - **pctl\_90:** Percentil 90.
  - **Estadísticas de Forma de la Distribución:**
    - **skew:** Asimetría (Skewness).
    - **kurt:** Curtosis.
  - **Características Basadas en Cambios y Dinámica:**
    - **sum\_abs:** Suma de los valores absolutos (proxy de energía de la señal).
    - **mean\_abs\_change:** Media de los cambios absolutos entre muestras consecutivas.
    - **mean\_change:** Media de los cambios entre muestras consecutivas.
    - **std\_change:** Desviación estándar de los cambios entre muestras consecutivas.
  - **Características de Cruces y Picos:**
    - **zero\_crossings:** Número de cruces por cero.
    - **mean\_crossings:** Número de cruces por la media de la señal.
    - **peak\_count:** Número de picos detectados (usando `find_peaks` con prominencia relativa a `std`).
  - **Autocorrelación:**
    - **autocorr\_lag1:** Autocorrelación con lag 1.
  - **Desviación del Comportamiento Típico (solo para X, Y, Z):**
    - **dtv:** Proporción de valores que caen fuera del rango "normal" (min/max) del piloto para ese eje y frecuencia.
- **Características del Dominio de la Frecuencia (para cada eje X, Y, Z, y para Mag):** Este grupo incluye un total de 33 descriptores espectrales para cada una de las cuatro señales (X, Y, Z, Mag).
  - **Basadas en la Transformada Rápida de Fourier (FFT):**
    - **Estadísticas del espectro de magnitud FFT (solo frecuencias positivas):** `fft_mag_mean`, `fft_mag_median`, `fft_mag_std`, `fft_mag_max`, `fft_mag_min`, `fft_mag_range`, `fft_mag_iqr`, `fft_mag_skew`, `fft_mag_kurt`. (9 características)

- **Estadísticas de los primeros N coeficientes de baja frecuencia de la FFT (excluyendo componente DC, N=10 por defecto):** `fft_low{N}_mag_mean`, `fft_low{N}_mag_std`, `fft_low{N}_mag_max`. (3 características)
- **Basadas en la Densidad Espectral de Potencia (PSD, método de Welch):**
  - **Estadísticas de la PSD:** `psd_mean`, `psd_median`, `psd_std`, `psd_max`, `psd_min`, `psd_range`, `psd_iqr`, `psd_skew`, `psd_kurt`. (9 características)
  - Descriptores espectrales derivados de la PSD:
  - **spectral\_centroid:** Centroide espectral.
  - **spectral\_spread:** Dispersión espectral.
  - **spectral\_entropy:** Entropía espectral.
  - **dominant\_freq:** Frecuencia con la máxima potencia en la PSD. (4 características)
- **Energía en Bandas de Frecuencia predefinidas (FREQ\_BANDS = [(0,1), (1,5), (5,10), (10,inf)] Hz):**
  - **energy\_band\_{i+1}:** Energía absoluta en cada una de las 4 bandas. (4 características)
  - **energy\_ratio\_band\_{i+1}:** Proporción de energía en cada banda respecto a la energía total en las bandas. (4 características)
- **Características Cruzadas entre Ejes (para los pares X-Y, X-Z, Y-Z):** Este grupo incluye 3 descriptores de relación para cada uno de los tres pares de ejes.
  - **Covarianza:**
    - **{Eje1}{Eje2}\_cov:** Covarianza entre las señales alineadas de los dos ejes.
  - **Correlación no Paramétrica:**
    - **{Eje1}{Eje2}\_kendall\_tau:** Coeficiente de correlación Tau de Kendall.
  - **Correlación Paramétrica:**
    - **{Eje1}{Eje2}\_corr\_pearson:** Coeficiente de correlación de Pearson.

**Resumen Numérico:**

- **Características del dominio del tiempo:**
  - X, Y, Z: 3 ejes \* 25 características/eje = 75, Mag: 1 \* (25 - 1 dtv) características = 24
- **Características del dominio de la frecuencia:**
  - X, Y, Z, Mag: 4 señales \* 33 características/señal = 132
- **Características cruzadas entre ejes:**
  - 3 pares \* 3 características/par = 9

**Total: 75 + 24 + 132 + 9 = 240 características.**