

UNIVERSIDAD AUTÓNOMA DE SINALOA
FACULTAD DE INFORMÁTICA
FACULTAD DE CIENCIAS DE LA TIERRA Y DEL ESPACIO
DOCTORADO EN CIENCIAS DE LA INFORMACIÓN



DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA DE EVALUACIÓN ERGONÓMICA EN LÍNEA

T E S I S

QUE COMO REQUISITO PARA OBTENER EL GRADO DE:
DOCTORA EN CIENCIAS DE LA INFORMACIÓN

PRESENTA:

M.C. GRACIELA RODRÍGUEZ VEGA

DIRECTORES:

DRA. XIOMARA P. ZALDÍVAR COLADO
DR. ULISES ZALDÍVAR COLADO

CULIACÁN, SINALOA, MÉXICO, 15 DE SEPTIEMBRE DE 2021



Restricción de uso

UAS-Dirección General de Bibliotecas

Repositorio Institucional

Restricciones de uso

Todo el material contenido en la presente tesis está protegido por la Ley Federal de Derechos de Autor (LFDA) de los Estados Unidos Mexicanos (México).

Queda prohibido la reproducción parcial o total de esta tesis. El uso de imágenes, tablas, gráficas, texto y demás material que sea objeto de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente correctamente mencionando al o los autores del presente estudio empírico. Cualquier uso distinto, como el lucro, reproducción, edición o modificación sin autorización expresa de quienes gozan de la propiedad intelectual, será perseguido y sancionado por el Instituto Nacional de Derechos de Autor.

Esta obra está bajo una Licencia Creative Commons Atribución-No Comercial Compartir Igual, 4.0 Internacional.



Declaración de autenticidad

Por la presente declaro que, salvo cuando se haga referencia específica al trabajo de otras personas, el contenido de esta tesis es original y no se ha presentado total o parcialmente para su consideración para cualquier otro título o grado en esta o cualquier otra Universidad. Esta tesis es resultado de mi propio trabajo y no incluye nada que sea el resultado de algún trabajo realizado en colaboración, salvo que se indique específicamente en el texto.

M.C. Graciela Rodríguez Vega. Culiacán, Sinaloa, México, 15 de septiembre de 2021

Resumen

Las lesiones músculo-esqueléticas debidas al trabajo, además de disminuir la calidad de vida de quienes las padecen generan un alto costo a las empresas. Con la finalidad de identificar los puestos de trabajo que representan un riesgo de ocurrencia de este tipo de lesiones, los ergonomistas disponen de una serie de metodologías para el diagnóstico situacional. La literatura reporta que un porcentaje considerable de los resultados obtenidos en estos diagnósticos no corresponden a los resultados obtenidos por analistas expertos, generando una baja reproducibilidad de los mismos. Con objetivo de disminuir el porcentaje de diagnósticos erróneos reportado en la literatura, el presente trabajo de tesis tiene como propuesta de solución la determinación del nivel de riesgo ergonómico mediante un sistema de evaluación ergonómica en línea, que emplee técnicas de clasificación de variables adquiridas a través de un sistema de captura de movimiento.

Para llevar a cabo dicha propuesta, se establecieron tres objetivos principales: *diseñar e implementar un sistema de captura de movimiento para la parte distal de la extremidad superior*, conformado por sensores inerciales de nueve grados de libertad y sensores resistivos de fuerza; *implementar modelos de clasificación clásicos para el reconocimiento del tipo de agarre*, empleando la metodología de la cadena de reconocimiento de actividades y considerando 17 tipos de agarres descritos en la taxonomía GRASP, así como la realización de análisis exploratorio para identificar los patrones naturales presentes en cuatro dimensiones antropométricas que describen las características de la mano de los usuarios que permita *identificar el somatotipo al que pertenecen*. Finalmente, el nivel de riesgo ergonómico fue predicho mediante modelos de clasificación entrenados a partir de variables que describen a la tarea y al individuo.

Los resultados obtenidos mediante la predicción del nivel de riesgo ergonómico, indican que el porcentaje de error es menor al reportado en la literatura para la mayoría de los tipos de agarres predichos por el sistema.

Índice general

Índice de figuras	XI
Índice de tablas	XIII
1. Introducción	1
1.1. Motivación	2
1.1.1. Costo de las enfermedades de trabajo	2
1.1.2. Métodos subjetivos para la evaluación ergonómica de puestos de trabajo	3
1.2. Planteamiento del problema	3
1.3. Hipótesis	5
1.4. Objetivos	6
1.4.1. Objetivo general	6
1.4.2. Objetivos específicos	6
1.5. Estructura de la tesis	6
2. Marco teórico	7
2.1. Ergonomía y Salud Ocupacional	7
2.1.1. Desórdenes músculo-esqueléticos	10
2.1.2. Riesgo y factores de riesgo ergonómico	10
2.1.3. Costos de las lesiones músculo-esqueléticas	11
2.1.4. Ergonomía en la era de la Industria 4.0	12
2.1.5. Métodos de evaluación ergonómica	12
2.2. Antropometría y modelos representacionales	13
2.2.1. Diseño multivariado basado en casos extremos	16
2.2.2. Diseño multivariado basado en casos distribuidos	17
2.3. Técnicas de captura de movimiento para la evaluación ergonómica en línea	18
2.3.1. Sistemas Captura de Movimiento (MoCap) basados en sensores ópticos	18

2.3.2.	Sistemas de MoCap basados en sensores inerciales	21
2.3.3.	Sistemas Captura de Movimiento (MoCap) basados en electromiografía (Electromiografía (EMG))	22
2.3.4.	Sistemas MoCap basados en sensores mecánicos	22
2.3.5.	Sistemas MoCap basados en sensores magnéticos	22
2.3.6.	Sistemas MoCap basados en sensores acústicos	23
2.4.	Reconocimiento de los movimientos de la mano	25
2.5.	Metodología para el Reconocimiento de las Actividades Humanas	28
2.6.	Manipulación manual de objetos: agarre	32
3.	Metodología	35
3.1.	Diseño e implementación del sistema MoCap: guante de datos	36
3.1.1.	Arquitectura de hardware	36
3.1.2.	Arquitectura de software	42
3.1.3.	Pre-procesamiento de los datos	42
3.1.3.1.	Calibración de sensores inerciales	42
3.1.3.2.	Calibración de los sensores resistivos de fuerza	45
3.1.3.3.	Interfaz para la lectura del sistema MoCap	48
3.2.	Reconocimiento del tipo de agarre	50
3.3.	Identificación del somatotipo	53
3.3.1.	Recolección de datos antropométricos	55
3.3.2.	Análisis multivariado de datos: Agrupamiento	56
3.4.	Evaluación ergonómica	58
3.4.1.	Métodos de evaluación ergonómica	58
3.4.1.1.	Job Strain Index (JSI)	58
3.4.1.2.	Método Rodgers para la evaluación de la fatiga muscular	60
3.4.2.	Determinación del nivel de riesgo ergonómico	61
3.4.2.1.	Evaluación ergonómica por expertos	62
3.4.3.	Evaluación ergonómicas obtenidas mediante el sistema	62
3.5.	Análisis estadístico de los resultados	63
4.	Resultados	65
4.1.	Reconocimiento del tipo de agarre	65
4.1.1.	Selección de características: aceleración y FSR	65
4.1.2.	Selección de características: aceleración, velocidad angular y FSR	68
4.1.3.	Selección de características: aceleración, velocidad angular, campos magnéticos y FSR	71
4.1.4.	Selección del modelo de clasificación: Reconocimiento de agarre	74

4.2. Identificación del somatotipo	75
4.2.1. Análisis multivariado: Casos extremos	75
4.2.1.1. ACP	75
4.2.1.2. Análisis de arquetipos	76
4.2.2. Análisis multivariado: Casos distribuidos	76
4.2.3. Selección del agrupamiento	77
4.2.4. Modelos de clasificación para el somatotipo	78
4.3. Modelo para la predicción del nivel de riesgo ergonómico	81
4.4. Análisis estadístico de la predicción del nivel de riesgo ergonómico	82
4.4.1. Evaluación automática	82
4.4.2. Predicción de la evaluación	83
4.5. Discusión	84
4.5.1. Reconocimiento del tipo de agarre	84
4.5.2. Identificación del somatotipo	85
4.5.3. Evaluación ergonómica	86
5. Conclusiones	87
5.1. Observaciones finales	87
5.2. Principales hallazgos y contribuciones	88
5.3. Recomendaciones y trabajo futuro	89
A. Contribuciones científicas	91
B. Técnicas de análisis multivariado basado en extremos	93
B.1. Análisis de Componentes Principales (ACP)	93
B.2. Análisis de Arquetipos (AA)	94
C. Técnicas de aprendizaje de máquina	97
C.1. Aprendizaje de máquina	97
C.1.1. Técnicas de clasificación	98
C.1.1.1. Estrategias multiclase	98
C.1.1.2. Máquinas de vectores de soporte	99
C.1.1.3. k vecinos más cercanos	101
C.1.1.4. Gaussian Naïve Bayes	102
C.1.1.5. Análisis discriminante lineal y cuadrático	103
C.1.1.6. Árboles de decisión	103
C.1.1.7. Ensamblés	106
C.1.1.8. Evaluación de los modelos de clasificación entrenados	109

C.1.1.9. Métricas para el desempeño del clasificador	110
C.1.2. Análisis de conglomerados (clústers)	113
C.1.2.1. <i>k</i> -means clustering	115
C.1.2.2. Algoritmo aglomerativo de clusterización jerárquica	116
C.1.2.3. Análisis de Componentes Principales	117
C.1.2.4. Evaluación del agrupamiento	117
C.1.3. Técnicas de reducción de la dimensionalidad	119
D. Dimensiones antropométricas de los somatotipos	123
D.1. Casos extremos: ACP	123
D.2. Casos extremos: AA	124
D.3. Casos distribuidos: k-means	126
D.4. Casos distribuidos: Ward	128
Bibliografía	131

Índice de figuras

1.1. Ámbitos de aplicación de la biomecánica	1
1.2. Costos de las enfermedades	3
1.3. Procedimiento para la evaluación ergonómica	4
1.4. Relación de variables de la hipótesis	5
2.1. Modelo de lugar de trabajo saludable de la OMS	8
2.2. Factores considerados en Ergonomía	9
2.3. Métodos de evaluación ergonómica	14
2.4. Metodología para el RAH- CRA	28
2.5. Ventana Móvil	29
2.6. Tipos de agarre identificados por Napier	32
3.1. Metodología empleada para abordar el problema de investigación	35
3.2. Arquitectura de hardware del guante de datos	37
3.3. Sparkfun IMU Breakout – MPU-9250	37
3.4. Efectos magnéticos de los magnetómetros	39
3.5. FSR 402	39
3.6. Divisor de voltaje FSR	40
3.7. Elementos del sistema qwiic	41
3.8. Ubicación de los sensores en el guante de datos	41
3.9. Sistema MoCap - guante de datos	41
3.10. Calibración del sensor inercial	42
3.11. Calibración del acelerómetro	44
3.12. Calibración del giroscopio	44
3.13. Calibración del magnetómetro	45
3.14. Calibración del magnetómetro vista 3D	45
3.15. Lecturas obtenidas del FSR	46

3.16. Barras de acero utilizadas para la calibración de los FSR	47
3.17. Modelos de regresión ajustados para la predicción del peso en función de las lecturas del FSR	47
3.18. Aplicación desarrollada en Matlab 2019a [©]	49
3.19. Metodología para el RAH utilizada en la investigación	50
3.20. Tipos de agarre considerados en la investigación	50
3.21. Altura recomendada del plano de trabajo	51
3.22. Alcances en el plano de trabajo	51
3.23. Metodología empleada para la identificación del somatotipo	54
3.24. Dimensiones de la mano	56
4.1. Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape $\geq 50\%$	67
4.2. Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape 50 %	68
4.3. Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape $\geq 50\%$	70
4.4. Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape 50 %	71
4.5. Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape 50 %	73
4.6. Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape $\geq 50\%$	74
4.7. RSS del AA para diferentes valores de k	76
4.8. Índices para diferentes valores de k, población masculina	77
4.9. Índices para diferentes valores de k, población femenina	77
4.10. Matrices de confusión para los modelos de clasificación de la población masculina	79
4.11. Matrices de confusión para los modelos de clasificación de la población femenina	80
B.1. Solución Análisis de Componentes Principales 2-Dimensiones	94
B.2. Centroide, intersecciones y puntos medios de los octantes de la elipsoide ajustada	95
C.1. Geometría de la separación del hiperplano en 2D ¹	100
C.2. Margen de separación del hiperplano	101
C.3. Matriz de confusión clasificación binaria	114

Índice de tablas

2.1. Factores de exposición analizados en métodos observacionales (7)	14
2.2. Estado del arte de sistemas de captura de movimiento (MoCap)	24
2.3. Estado del arte de sistemas de captura de movimiento (MoCap), continuación	25
2.4. Características en los diferentes dominios	31
3.1. Especificaciones del acelerómetro MPU-6500	37
3.2. Especificaciones del giroscopio MPU-6500	38
3.3. Especificaciones del magnetómetro AK8963	38
3.4. Especificaciones FSR 402	39
3.5. Niveles de esfuerzo	47
3.6. Combinaciones tamaño de ventana-paso consideradas en el análisis	52
3.7. Dimensiones antropométricas de la mano	55
3.8. Componentes principales, varianza y eigenvalores para la población masculina	57
3.9. Componentes principales, varianza y eigenvalores para la población femenina	57
3.10. Índices empleados para la selección del valor k	58
3.11. Valores de las seis variables consideradas en JSI	59
3.12. Tabla de multiplicadores	60
3.13. Criterios de evaluación la duración y frecuencia del esfuerzo en la metodología Suzanne Rodgers	60
3.14. Criterios de evaluación del nivel de esfuerzo en la metodología Suzanne Rodgers	61
3.15. Puntajes JSI y Rodgers para los difentes tipos de agarre	62
4.1. Exactitud de los modelos de clasificación entrenados para aceleración+FSR, traslape $\geq 50\%$	66
4.2. Exactitud de los modelos de clasificación entrenados para aceleración+FSR, 50% traslape	66

4.3. Exactitud de los modelos de clasificación entrenados para aceleración + velocidad angular + FSR, traslape $\geq 50\%$	69
4.4. Exactitud de los modelos de clasificación entrenados para aceleración + velocidad angular +FSR, 50% traslape	69
4.5. Exactitud de los modelos de clasificación entrenados para aceleración + velocidad angular + campos magnéticos + FSR, traslape $\geq 50\%$	72
4.6. Exactitud de los modelos de clasificación entrenados para aceleración + velocidad angular + campos magnéticos + FSR, 50% traslape	72
4.7. Exactitud y valores F1 de los modelos de clasificación entrenados	75
4.8. Porcentaje de acomodo de los modelos para las poblaciones masculina y femenina . .	78
4.9. Exactitud de los modelos de clasificación para la población masculina	78
4.10. Exactitud de los modelos de clasificación para la población femenina	78
4.11. Exactitud y F1-Score para los modelos de predicción del nivel de riesgo ergonómico, método JSI	81
4.12. Exactitud y F1-Score para los modelos de predicción del nivel de riesgo ergonómico, método Rodgers	82
4.13. Prueba de hipótesis para proporciones, evaluación automática W75 S10	83
4.14. Prueba de hipótesis para proporciones, predicción de la evaluación W75 S10	84
D.1. Casos obtenidos mediante APC	123
D.2. Casos obtenidos mediante AA para la población masculina	124
D.3. Casos obtenidos mediante AA para la población femenina	125
D.4. Casos obtenidos mediante el algoritmo k-means para la población masculino	126
D.5. Casos obtenidos mediante el algoritmo k-means para la población femenina	127
D.6. Casos obtenidos mediante el algoritmo Ward para la población masculina	128
D.7. Casos obtenidos mediante el algoritmo Ward para la población femenina	129

Índice de algoritmos

1.	Algoritmo de k -vecinos más cercanos	102
2.	Algoritmo árboles de decisión	105
3.	Algoritmo <i>bagging</i>	107
4.	Algoritmo <i>bagging - random forests</i>	107
5.	Algoritmo <i>boosting</i> para el ensamble de clasificadores binarios con conjuntos de datos de entrenamiento re-ponderados	108
6.	Algoritmo de validación cruzada k-folds	109
7.	Algoritmo de re-muestreo bootstrap	110
8.	Algoritmo k-means	115
9.	Algoritmo aglomerativo jerárquico	116
10.	Algoritmo ACP	121

Siglas

- AA** Análisis de Arquetipos
- ACP** Análisis de Principales Componentes
- AP** Ancho de la palma
- CRA** Cadena de Reconocimiento de Actividades
- DAM** Diámetro de agarre de la mano
- Discr** Discriminante
- DT** Árboles de Decisión
- EMG** Electromiografía
- Ens** Ensamblados
- GDL** Grados de Libertad
- IEA** Asociación Internacional de Ergonomía
- IMU** Unidad de Medición Inercial
- JSI** Job Strain Index
- kNN** k-Vecinos más cercanos
- LM** Longitud de la mano
- LP** Longitud de la palma
- MoCap** Captura de Movimiento
- MSD** Desórdenes Músculo-esqueléticos

NB Naïve Bayes

OIT Organización Internacional del Trabajo

PCs Principales Componentes

RAH Reconocimiento de las Actividades Humanas

RHM Modelos Humanos Representativos

RMO Reconocimiento en la Manipulación de Objetos

sEMG Electromiografía de superficie

SO Salud Ocupacional

SVM Máquina de Vectores de Soporte

SyST Seguridad y Salud en el Trabajo

WRMD Desórdenes de Trauma Acumulado relacionados con el Trabajo

Introducción

El estudio del movimiento del cuerpo humano ha sido de gran interés en disciplinas relacionadas con la medicina, la rehabilitación y la salud ocupacional, así como en el análisis biomecánico de actividades artísticas, como la danza (Fig. 1.1).

En el área de salud ocupacional, el conocimiento de los movimientos que se llevan a cabo como parte de las actividades laborales, es de suma importancia. La combinación de posturas estresantes, esfuerzos excesivos y altas tasas de repetición es la causa principal de la ocurrencia de enfermedades laborales, tales como los desórdenes de trauma acumulado, mismas que representan pérdidas significativas a través de días de incapacidad, incremento de primas de seguro, así como disminución de la productividad.



Figura 1.1: Ámbitos de aplicación de la biomecánica

Para determinar el nivel de riesgo ergonómico que conlleva una actividad, se emplean diversas metodologías que se basan en la percepción del trabajador, en la observación o bien que emplean la medición directa de variables físicas y fisiológicas (10).

La principal desventaja del primer grupo de métodos es el sesgo de los resultados debido a que se obtienen directamente de la opinión del trabajador, ocasionando baja confiabilidad relacionada con la ambigüedad de la interpretación. En el segundo caso, la medición se realiza tomando en cuenta

la experiencia del analista, la determinación de la duración del movimiento y del ciclo, así como la obtención de las características del movimiento (ángulos de rotación de las articulaciones) a partir de imágenes (medición estática) obtenidas por medio de la filmación de un ciclo de trabajo, lo que dificulta la medición del movimiento con precisión. Por otra parte, los métodos de medición directa consisten en obtener información a través de sensores colocados en el cuerpo del trabajador. Su principal desventaja, es su difícil aplicación en situaciones reales de trabajo (11).

En el presente trabajo, se propone una metodología para la determinación del nivel de riesgo ergonómico en función de variables relacionadas con la tarea y con el trabajador, de tal manera que se evite la aplicación directa de los diferentes métodos de evaluación en cada una de las actividades a analizar.

1.1. Motivación

Existen dos enfoques que permiten considerar que los resultados obtenidos mediante la presente investigación son de gran utilidad para el sector laboral: los costos absorbidos por las empresas debidos a las altas incidencias de lesiones musculoesqueléticas, enfermedades y accidentes de trabajo y, el alto margen de error que generan las evaluaciones basadas en la observación.

1.1.1. Costo de las enfermedades de trabajo

De acuerdo con el boletín emitido por la Organización Internacional del Trabajo (OIT) en el día de Mundial de la Seguridad y la Salud en el trabajo de 2013, los costos generales de los accidentes y los problemas de salud son a menudo mayores de los que se perciben inmediatamente. Por el contrario, invertir en la Seguridad y Salud en el Trabajo (SyST) reduce los costos directos, los costos indirectos y las primas de los seguros, además de incrementar el rendimiento y la productividad, logrando un impacto positivo en el ausentismo y el estado de ánimo del trabajador (Fig. 1.2)(12).

En México, los Desórdenes de Trauma Acumulado relacionados con el Trabajo (WRMD) se han incrementado en un 6.25 %, lo que representa un aumento en la tasa de incidencia del 5.15 % en los últimos cinco años(12). En 2001, el National Research Council y el Institute of Medicine indicaron que, en Estados Unidos, los WRMD representaron el 40 % de la compensación por lesiones, mientras que, en la Unión Europea, 40 millones de trabajadores sufren de WRMD (12).

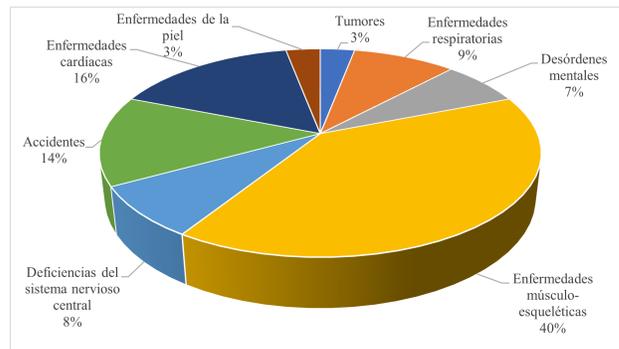


Figura 1.2: Costos de las enfermedades

1.1.2. Métodos subjetivos para la evaluación ergonómica de puestos de trabajo

Diego-Mas et. al.(13) analizaron los errores cometidos al realizar evaluaciones ergonómicas mediante los métodos observacionales tradicionales y concluyeron que, aproximadamente 30 % de las evaluaciones presentaban algún tipo de error, en las que:

1. El 13 % de las evaluaciones los errores fueron severos al grado de invalidar los resultados.
2. En el 15 % de los casos se obtuvo una estimación de la evaluación del riesgo superior o inferior.
3. El 2 % de los casos presentó errores mínimos.

1.2. Planteamiento del problema

La metodología actualmente empleada en la determinación del nivel de riesgo ergonómico de puestos de trabajo conlleva un alto margen de error, debido a que se basa principalmente en la apreciación y experiencia del analista (14).

Se han realizado estudios en los que se emplean sistemas de visión, mediante el sensor Kinect™, para obtener la cinemática de los movimientos requeridos por los diferentes metodologías para la determinación del riesgo ergonómico (15),(16), (17) , sin embargo, estos pueden presentar autooclusión y son sensibles a las condiciones ambientales del espacio de trabajo (principalmente iluminación) (10), (18). Aunado a lo anterior, en los ambientes reales de trabajo se dispone de áreas reducidas y en ocasiones sobresaturadas, lo que dificulta la colocación idónea del sensor. La versión 2 del sensor Kinect™, permite obtener la cinemática de 25 articulaciones, sin embargo, estas no son suficientes para determinar las características requeridas para la evaluación ergonómica de

1. INTRODUCCIÓN

actividades específicas del sector industrial, en las que los movimientos de las manos y dedos son preponderantes.

En años recientes también se han desarrollado sistemas de sensores inerciales para la evaluación ergonómica en línea (19), (20),(21), sin embargo, requieren de la experiencia del analista para la colocación correcta de los sensores. Diversas investigaciones han demostrado que la precisión que ofrecen es adecuada para su aplicación en la determinación del riesgo ergonómico. En la mayoría de los casos, las técnicas mencionadas son empleadas para la caracterización de la actividad, es decir para la obtención de la cinemática del movimiento y el reconocimiento del mismo, principalmente. Lo anterior significa que las características antropométricas, el tipo de agarre y las variables de fuerza ejercidas para llevar a cabo la actividad es información proporcionada directamente por el analista o bien no son incluidas dentro de la determinación del nivel de riesgo.

En la literatura existen pocos estudios para realizar análisis ergonómicos de forma automática, mismos que se basan principalmente en la duración, la frecuencia y la cinemática de los movimientos, sin embargo estos no suelen considerar características importantes en las tareas de trabajo manual, como lo es el tipo de agarre efectuado, la elevación de hombro, el soporte en brazos, la antropometría del individuo así como la fuerza ejercida por las extremidades superiores (Fig. 1.3).

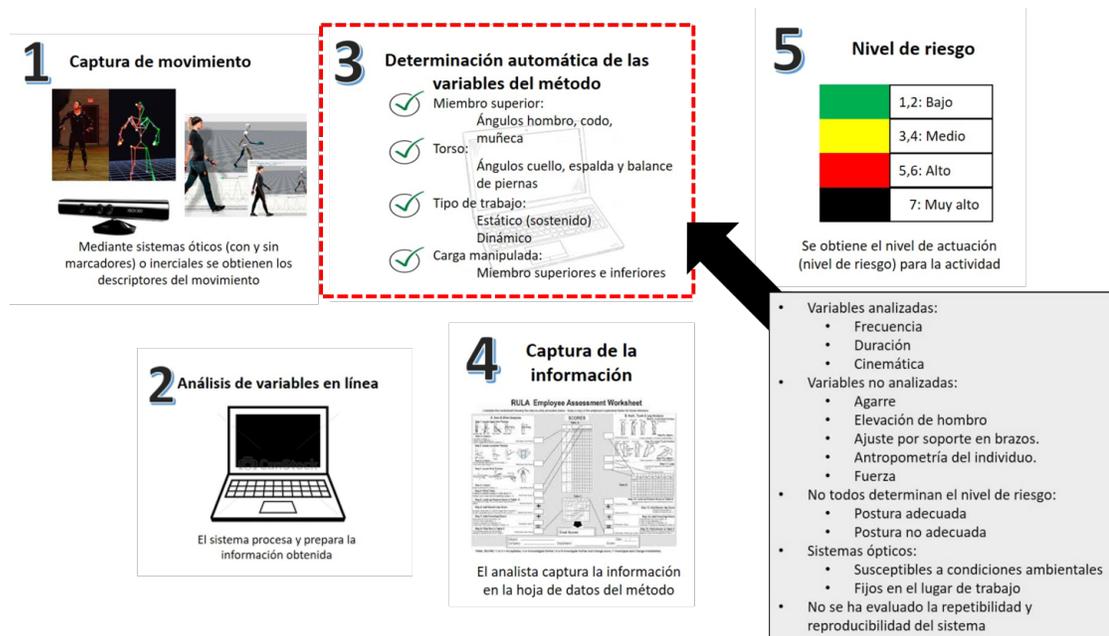


Figura 1.3: Procedimiento para la evaluación ergonómica

Lo anterior indica que la determinación del nivel de riesgo ergonómico depende en gran medida de la experiencia del analista y de la evaluación en sitio basada en la observación, así la información

de entrada proporcionada por el analista a los sistemas automáticos de evaluación, por lo que surge la siguiente pregunta de investigación:

¿Es posible realizar la evaluación ergonómica de un puesto de trabajo, en línea, que considere el tipo de agarre y las características antropométricas del individuo, sin llevar a cabo la aplicación directa de las diferentes metodologías observacionales para la determinación del nivel de riesgo ergonómico?

1.3. Hipótesis

Con base en la revisión de la literatura, es posible definir la siguiente hipótesis de investigación:

Un sistema de captura de movimientos que, mediante técnicas de clasificación, identifique el somatotipo y el tipo de agarre, disminuye el error actual en la determinación del nivel de riesgo ergonómico del 13 % indicado por Diego Mas et. al. (13).

En la figura 1.4, se puede apreciar las variables de entrada y de salida implícitas en la hipótesis planteada.

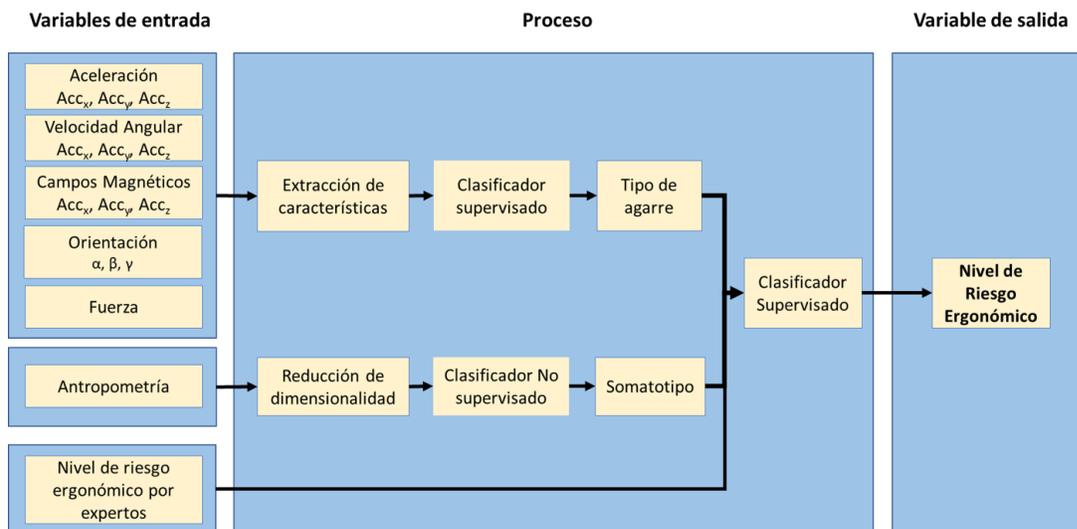


Figura 1.4: Relación de variables de la hipótesis

1.4. Objetivos

1.4.1. Objetivo general

Este trabajo tiene por objetivo general el diseñar e implementar un sistema de evaluación ergonómica en línea, que permita determinar el nivel de riesgo ergonómico mediante técnicas de clasificación.

1.4.2. Objetivos específicos

Los objetivos específicos de la investigación son los siguientes:

1. Diseñar e implementar un sistema de Captura de Movimiento (MoCap) a través de cual se obtengan las variables que describan a la tarea.
2. Implementar algoritmos para la clasificación de las características antropométricas y de la tarea.
3. Implementar un algoritmo de clasificación para la determinación del nivel de riesgo por carga postural.

1.5. Estructura de la tesis

El resto del presente trabajo se encuentra organizado en 4 capítulos. En el Capítulo II se presentan los antecedentes que permiten comprender el contexto de la presente investigación, así como el marco teórico en el que se basa la solución propuesta.

En el capítulo III se detalla la metodología empleada para llevar a cabo la solución propuesta: diseño e implementación del sistema de captura de movimiento, identificación del somatotipo, reconocimiento del tipo de agarre, y evaluación ergonómica . En el Capítulo IV se presentan los resultados, así como una breve discusión en cada una de las etapas descritas en la metodología.

Finalmente, en el capítulo V se incluyen las conclusiones con respecto a los objetivos de la investigación y la hipótesis planteada.

Marco teórico

En este capítulo se presentan los fundamentos teóricos necesarios para el desarrollo de la presente investigación. Conceptos relacionados con salud ocupacional y las metodologías empleadas para la determinación del nivel de riesgo ergonómico son descritos, al igual que las estrategias de análisis multivariado más utilizadas en el diseño antropométrico y las empleadas en el reconocimiento de actividades humanas.

2.1. Ergonomía y Salud Ocupacional

La conceptualización internacional y el desarrollo de la Salud Ocupacional (SO) ocurrió durante el siglo XX, gracias a la creación de la Comisión Internacional para la Salud Ocupacional en 1906 y al establecimiento de la OIT después de la segunda guerra mundial. Sin embargo, la definición mundialmente aceptada en la actualidad, está fuertemente influenciada por el concepto de salud provisto por la Organización Mundial de la Salud, en el que se describe a la salud como una “afirmación positiva del bienestar físico, mental y social, no solamente como la ausencia de enfermedades” (1).

El modelo de lugar de trabajo saludable desarrollado por la Organización Mundial de la Salud lo define como “aquel lugar en el que los trabajadores y administradores trabajan en conjunto en la mejora continua de los procesos, con la finalidad de proteger y promover la salud, seguridad y bienestar de todos los trabajadores y la sustentabilidad del lugar de trabajo” (1). Para lograr un lugar de trabajo saludable, el modelo de la Organización Mundial de la Salud considera cuatro áreas (Fig. 2.1):

1. Asuntos relacionados con la salud y seguridad relacionados con el ambiente de trabajo físico
2. Salud, seguridad y bienestar relacionados con el ambiente de trabajo psicosocial, incluyendo la organización y cultura del trabajo

2. MARCO TEÓRICO

3. Recursos en el trabajo para la salud personal (soporte y motivación provistos por el empleador para mantener estilos de vida saludables)
4. Participación en la comunidad para mejorar la salud de los trabajadores, sus familias y los miembros de la comunidad

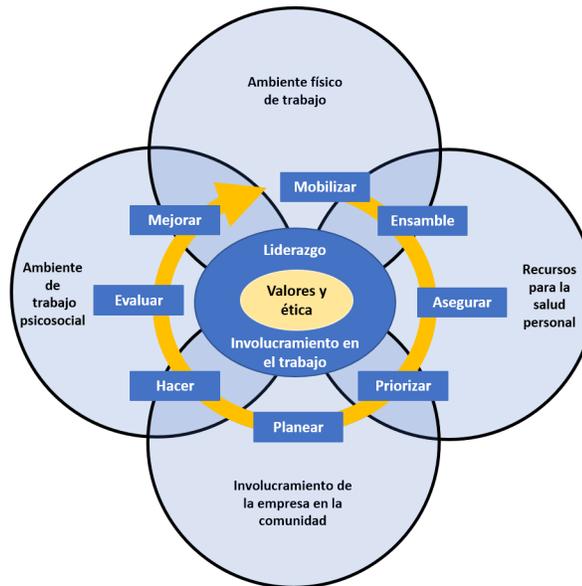


Figura 2.1: Modelo de lugar de trabajo saludable de la OMS (1)

Para cumplir con los puntos 1 y 2, la salud ocupacional se apoya en diferentes disciplinas, como la Ergonomía. La palabra ergonomía proviene de los vocablos griegos *ergon*, que significa trabajo, y *nomos*, que significa leyes. La Asociación Internacional de Ergonomía (IEA), define a la Ergonomía como:

“la disciplina científica enfocada al entendimiento de la interacción entre los humanos y el resto de los elementos que conforman un sistema, así como la profesión que aplica la teoría, principios, datos y métodos para diseñar, optimizando el bienestar del ser humano y el desempeño del sistema en general” (22).

De la definición anterior se deriva el que la Ergonomía emplea un enfoque de sistemas para aplicar la teoría, los principios y la información proveniente de disciplinas relacionadas al diseño y evaluación de las tareas, trabajos, productos, ambientes y sistemas (22). También es posible identificar los dos objetivos principales de la Ergonomía, el primero de ellos con una motivación social: *el bienestar del ser humano*, y el segundo con un punto de vista económico: *el desempeño del sistema en general* (23). Para lograr dichos objetivos, la Ergonomía considera factores físicos,

cognitivos, socio-técnicos, organizacionales, ambientales, así como las interacciones entre humanos y otros humanos, el ambiente, las herramientas, productos, equipos y la tecnología (Fig. 2.2) (22).

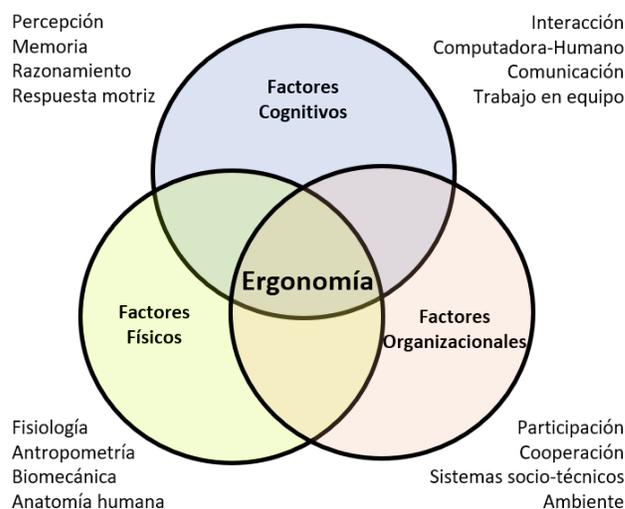


Figura 2.2: Factores considerados en Ergonomía

La Ergonomía emplea diferentes metodologías que permiten determinar el nivel de riesgo de lesión músculo-esquelética en el trabajo, a través del análisis de diferentes variables como la postura, la frecuencia o tasa de repetición del movimiento, el tiempo de ciclo de la operación, la duración de la jornada de trabajo, el tiempo de exposición a la actividad analizada, así como la fuerza ejercida durante los movimientos estudiados (13), (11).

La exposición a condiciones de trabajo ergonómicamente adversas puede ocasionar perturbaciones visuales, musculares y psicológicas, tales como (11):

- Tensión ocular
- Dolor de cabeza
- Fatiga
- Desórdenes musculoesqueléticos: dolor crónico de espalda, cuello y hombros
- Desórdenes de trauma acumulado
- Lesiones de esfuerzo repetitivo
- Lesiones de movimientos repetitivos
- Tensión psicológica

- Ansiedad
- Depresión

2.1.1. Desórdenes músculo-esqueléticos

Los Desórdenes Músculo-esqueléticos (MSD) incluyen un gran rango de condiciones inflamatorias y degenerativas que afectan a los músculos, los tendones, los ligamentos, las articulaciones, los nervios periféricos y los vasos sanguíneos de soporte (24). Los MSD se caracterizan por no ser resultado de un evento instantáneo específico como caídas y resbalones (25), sino por actividades repetitivas y prolongadas. Las regiones anatómicas más afectadas por la ocurrencia de WRMD, comprenden la espalda baja, el cuello, los hombros, los brazos y las manos, sin embargo estudios recientes han prestado mayor atención a las extremidades inferiores (24).

2.1.2. Riesgo y factores de riesgo ergonómico

Los riesgos ergonómicos se definen como la probabilidad de desarrollar un WMSD debido al tipo e intensidad de la actividad física que se realiza en el trabajo. Diversos estudios han identificado factores de riesgo físicos, psicosociales-organizacionales y debidos al individuo que coadyuvan en el desarrollo de los WRMD generados en ambientes laborales (7). Las características físicas del trabajo que comúnmente han sido asociadas como factores de riesgo para la ocurrencia de WRMD (factores de riesgo ergonómico) son las siguientes (24):

- Ritmos de trabajo rápidos y patrones de movimiento repetitivos
- Tiempos de recuperación insuficientes
- Manipulación de objetos pesados y esfuerzos manuales
- Posturas corporales no-neutras (dinámicas o estáticas)
- Concentración de la presión mecánica
- Exposición a vibraciones locales o de cuerpo entero
- Exposición local o de cuerpo entero a temperaturas abatidas

El riesgo de ocurrencia de WRMD se incrementa considerablemente con la exposición a la combinación de dos o más de los factores mencionados, así como la exposición prolongada o de alta intensidad. Existe evidencia de que la exposición ocasional o de un 25 % o menos de la jornada de trabajo a un factor de riesgo ocupacional, puede ocasionar un WRMD (11).

La exposición prolongada a la combinación de los factores mencionados con características no deseadas del ambiente de trabajo psicosocial, tales como altas demandas psicológicas y bajo nivel de control del propio trabajo, pueden afectar también la salud del trabajador (11).

2.1.3. Costos de las lesiones músculo-esqueléticas

La OIT estima que cada año alrededor de 2.3 millones de trabajadores perecen a causa de accidentes ocupacionales y enfermedades relacionadas con el trabajo. En el mundo, ocurren 337 millones de accidentes y 160 millones de enfermedades ocupacionales cada año, mientras que las enfermedades mortales ocasionadas por el trabajo cuestan alrededor de 1.95 millones al año, aproximadamente (26). Los costos de los problemas de salud y seguridad ocupacional representan un alto costo a las empresas, afectando directamente su productividad y competitividad. La OIT estima que las pérdidas anuales por enfermedades y lesiones debidas al trabajo (incluyendo compensaciones, disminución de la productividad, gastos médicos y de aseguranza, entre otros) promedian más del 4% del producto interno bruto (PIB) total en todos los países del mundo (27).

La incapacidad para reconocer la relación de los MSD con el trabajo, la preocupación por la seguridad en el trabajo, los incentivos laborales que desmotivan a los supervisores a realizar el reporte, la decisión de los empleadores para evitar el sistema de compensaciones a los empleados y la adquisición de coberturas médicas a través de aseguranzas privadas, la anticipación al rechazo del reclamo, la auto-negación de la lesión debido a la necesidad de proveer soporte financiero y económico a la familia, entre otros factores, han ocasionado que los empleadores no reporten los WRMD en su totalidad (11). Lo anterior significa que la magnitud real de los WRMD es desconocida, ocasionando que la estimación de la OIT se hace con base en una pequeña porción de los WRMD, por lo que las pérdidas financieras pudieran incrementarse en más del 10-15% del PIB nacional si se considerarían todos los factores de riesgo(11).

Los principales costos específicos de no considerar principios ergonómicos básicos en el diseño de puestos de trabajo son los siguientes (11):

- Para los empleadores:
 - Incremento del ausentismo y tiempo de trabajo perdido
 - Efectos adversos en las relaciones laborales
 - Costos de compensación y aseguranza elevados
 - Incremento de la probabilidad de accidentes y errores
 - Restricciones, transferencia del trabajo y rotaciones de turno de personal
 - Desperdicios y disminución de la producción y productividad
 - Asuntos legales
 - Capacidad reducida para manejar las emergencias
 - Altos costos administrativos y de personal
- Para los empleados:

- Dolor y sufrimiento debidos a las lesiones y enfermedades ocupacionales
- Costos de cuidado médico
- Tiempo de trabajo perdido
- Disminución de ganancias futuras y margen de beneficios
- Efectos adversos en las relaciones familiares
- Pérdida de la auto-estima e identidad
- Costos de cuidados en casa proporcionados por familiares
- Efectos adversos en las relaciones sociales y comunitarias
- Efectos adversos en las actividades recreativas

2.1.4. Ergonomía en la era de la Industria 4.0

El Industria 4.0 se refiere a la convergencia de la manufactura con la revolución digital, la inteligencia artificial, el internet de las cosas y los dispositivos inteligentes. Su objetivo es permitir a la industria manufacturera cumplir con los cambios constantes en la demana de manera más eficiente empleando sistemas adaptativos, integrándolos en los ecosistemas digitales a través de la cadena de suministro. La automatización inteligente así como la integración de nuevas tecnologías en la cadena de valor de los negocios no pueden ser logradas sin la introducción de nuevas restricciones organizacionales, en los que los problemas de producción se ven agravados por la inclusión de trabajadores con experiencia insuficiente, prolongando las curvas de aprendizaje. En esta transición hacia las fábricas inteligentes, es donde se presenta una gran variedad de riesgos ocupacionales (28).

2.1.5. Métodos de evaluación ergonómica

En la actualidad, existe una gran variedad de metodologías para la identificación y cuantificación del nivel de riesgo ergonómico en los puestos de trabajo que pueden ser aplicados en diferentes entornos laborales. La exposición al trabajo físico es comúnmente descrita mediante tres variables principales (7):

1. Nivel: intensidad de la fuerza
2. Tasa de repetición: frecuencia de cambio en los niveles de esfuerzo, y
3. Duración: tiempo que la actividad física es desarrollada

Variables como los cambios de postura, las tasas de movimiento y vibración, así como la medición de los factores psico-sociales y organizacionales también deben ser incluidas en la determinación del riesgo ocupacional(7). Mengoni et al. (23) señalan que la exposición directa del trabajador a los

riesgos ergonómicos es directamente proporcional a un conjunto de movimientos erróneos que éste realiza de manera inconsciente durante la ejecución de sus tareas (23).

Los métodos de evaluación ergonómica se clasifican en tres grandes grupos (7): a) percepción de los trabajadores, b) medición directa y c) métodos observacionales. El primer grupo de métodos consiste en la consulta directa de la opinión del trabajador respecto a sus actividades laborales (29). Su principal desventaja es la ambigüedad de sus resultados, debido a que la percepción del trabajador debe ser interpretada por un analista, lo que ocasiona baja confiabilidad en el resultado (30). En el segundo grupo, la medición se realiza tomando en cuenta la experiencia del analista, así como la obtención de las características del movimiento (ángulos de rotación de las articulaciones) a partir de imágenes (medición estática) obtenidas por medio de la filmación de un ciclo de trabajo, siendo la dificultad de medición su principal desventaja (10). Por otra parte, los métodos de medición directa consisten en obtener información a través de sensores colocados en el cuerpo del trabajador. Su principal desventaja es su difícil aplicación en situaciones reales de trabajo(7).

Una segunda clasificación de las metodologías para la determinación del riesgo ergonómico, permite agruparlos de acuerdo a las variables empleadas en el análisis, por lo que es posible definir cuatro grupos de métodos: 1) aquellos empleados para determinar el nivel de riesgo de ocurrencia de un WRMD, 2) los utilizados para determinar el nivel de riesgo en actividades de Manipulación Manual de Cargas, 3) los métodos que permiten determinar el nivel de fatiga y prioridad de cambio, y 4) aquellos que evalúan las condiciones ambientales que rodean al trabajador en su espacio laboral. La figura 2.3 y la tabla 2.1 muestran los principales métodos de evaluación ergonómica y las variables analizadas en cada uno de ellos, respectivamente.

2.2. Antropometría y modelos representacionales

En el proceso de adaptar el entorno al trabajador es importante considerar el acomodo físico, es decir, el diseño de productos y entornos laborales debe tener en cuenta la forma y tamaño físicos de los usuarios objetivo (31), tratando de acomodar a la mayor cantidad posible de usuarios actuales y potenciales. Lo anterior es conocido como *diseño centrado en el usuario* y es comúnmente acotado al 90-95 % de la población objetivo (32). En este contexto, la antropometría es un elemento clave, ya que proporciona información sobre las dimensiones del cuerpo, en particular las mediciones del tamaño, la forma, la fuerza, la movilidad y la flexibilidad y capacidad de trabajo (33).

Uno de los desafíos del diseño ergonómico centrado en el usuario, es lograr el mayor acomodo físico posible, debido a la baja o nula correlación de las variables físicas o antropométricas que caracterizan a los individuos: individuos que no se ajustan en una dimensión pueden ser diferentes a los que no se ajustan en otras dimensiones (34).

El problema del acomodo antropométrico ha sido abordado mediante diferentes técnicas estadísticas de análisis univariado: *percentiles*, *plantillas*, *modelos de regresión*, y técnicas multivaria-

2. MARCO TEÓRICO

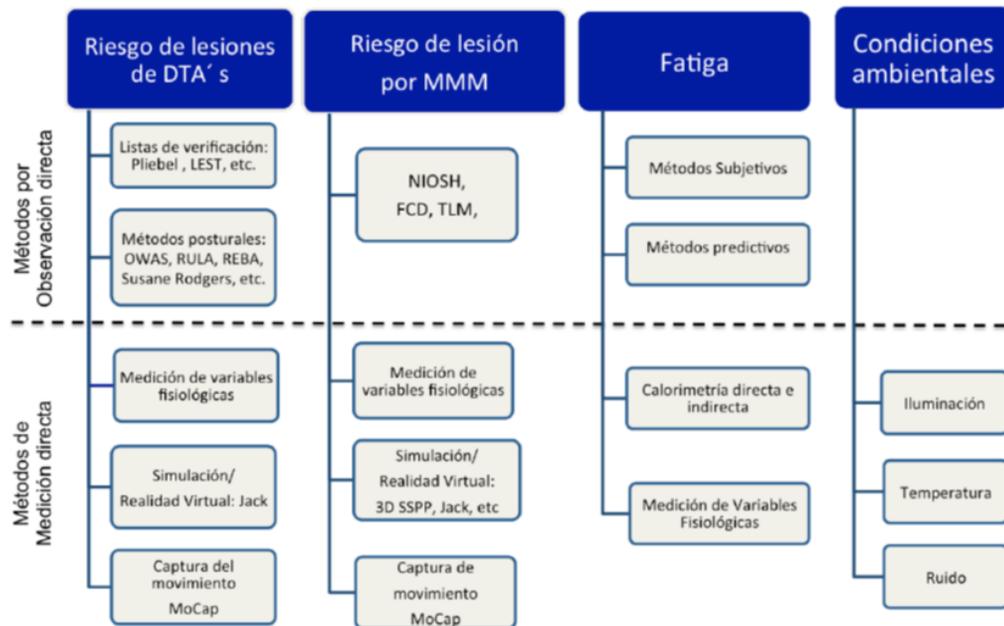


Figura 2.3: Métodos de evaluación ergonómica

Método	Postura	Carga o Fuerza	Frecuencia del movimiento	Duración	Recuperación	Vibración
OWAS	X	X				
Listas de verificación	X					
RULA	X	X	X			
Ecuación de levantamiento NIOSH	X	X	X	X	X	
PLIBEL	X	X				
Strain Index	X	X	X	X		
OCRA	X	X	X	X	X	X
QEC	X	X	X	X		X
Guía para la Manipulación Manual	X	X	X	X	X	
REBA	X	X	X			
FIOH	X	X	X	X		
ACGIH TLVs	X	X	X	X		
LUBA	X					
Guía para los desórdenes de extremidades superiores	X	X	X	X		X
HSG60						
MAC	X	X	X			

Tabla 2.1: Factores de exposición analizados en métodos observacionales (7)

das: *modelos de regresión, diseño basado en extremos y diseño basado en casos distribuidos.*

En el análisis univariado, los percentiles han sido los más utilizados conformando la base del diseño para los extremos, en los que se comúnmente se seleccionan los percentiles 5-95 y 1-99 para acomodar al 90% y 98% de la población, respectivamente. A pesar de su popularidad, el uso de percentiles antropométricos presenta dos desventajas principales en comparación con las técnicas multivariadas:

1. La suposición incorrecta de que todas las dimensiones antropométricas de un individuo en el n^{th} percentil corresponden al n^{th} percentil (32),(34)
2. A excepción del 50 percentil, los percentiles no son aditivos(32),(4)

Tanto las plantillas como las constantes de proporción son por lo general inadecuados debido a que personas con la misma estatura o dimensión, pueden tener proporciones diferentes (33), (35).

Por otra parte, las técnicas multivariadas permiten modelar, desde la etapa de diseño, el acomodo de una persona en un espacio dado, representando al individuo mediante representaciones gráficas, por ejemplo Modelos Humanos Representativos (RHM) y Modelos Humanos Digitales (36). Los RHM consisten en un grupo pequeño de modelos humanos digitales que representan estadísticamente a un porcentaje específico de la población objetivo, comúnmente el 90%, y que son empleados en el diseño y evaluación en ambientes virtuales (37). Los *casos* se definen como modelos RHM que consideran la combinación de las dimensiones antropométricas más relevantes para un problema de diseño particular. En la literatura existen tres técnicas de generación de RHM: métodos basados para casos centrales, para casos extremos y para casos distribuidos. La selección de la técnica multivariada para la generación de RHM, está en función del objetivo del diseño (38),(39),(37):

- Casos centrales: este tipo de casos/modelos son de utilidad en el diseño de productos para múltiples tamaños (n tamaños acomodan a n grupos porcentaje de la población objetivo), por ejemplo las tallas de ropa.
- Casos extremos: si el diseño del producto o lugar de trabajo tiene como finalidad acomodar a un porcentaje específico de la población objetivo y los modelos humanos pueden ser aplicados en el diseño y evaluación de productos de un solo tamaño (un tamaño acomoda a todos) como en el caso de diseño de estaciones de trabajo, interior de automóviles y cabinas, es recomendable emplear las técnicas de casos extremos.
- Casos distribuidos: si la finalidad del diseño es desarrollar una familia de modelos centrales y extremos que acomoden un determinado porcentaje de la población y que puedan ser utilizados en el diseño y evaluación de productos multi-talla, como los textiles, es preferible emplear las técnicas de casos distribuidos.

2.2.1. Diseño multivariado basado en casos extremos

Una de las ventajas de emplear los métodos basados en casos extremos con respecto a los métodos basados en casos distribuidos, es que estos proporcionan un mayor porcentaje de acomodo con un menor número de casos (40).

En la literatura existe evidencia de la implementación de dos técnicas de análisis multivariado en la determinación de los casos extremos que representan a una población: Análisis de Principales Componentes (ACP) B.1 y Análisis de Arquetipos (AA) B.2.

Bittner et al. (40) desarrollaron CADRE, una familia de *maniqués* para el diseño de estaciones para trabajo sentado, empleando ACP. Los modelos que conforman CADRE fueron mejorados en 2000 por Bittner Jr et al.(41).

Zehner et al. (4) desarrollaron una versión simplificada de la metodología multivariada empleada por Bittner et al. (40) y Bittner Jr. et al. (41) y la implementaron en el diseño de cabinas de aviones de la Fuerza Aérea de Estados Unidos. La propuesta consideraba el ajuste de una elipse al conjunto de datos multivariado, la cuál permite cubrir un porcentaje deseado de la población representada por dos Principales Componentes (PCs). Los individuos extremos eran identificados como los individuos más cercanos a las intersecciones de los ejes de la elipse y a los puntos medios en cada uno de los cuadrantes. Con esta metodología se pretendía asegurar un nivel deseado de acomodo a través de uso de la familia de modelos comprendida por los individuos extremos.

Por otra parte, Gordon, et al. (120), aplicaron ACP a 12 dimensiones antropométricas de la base de datos ANSUR I con la finalidad de definir el tamaño y forma del torso de los individuos considerados como extremos requeridos en el diseño de sistemas de blindaje corporal integrado y de soporte de cargas. Young et al. (36) desarrollaron 26 modelos representativos y realistas para la base de datos HSIR considerando tres PCs, obteniendo mejores resultados para todas las dimensiones consideradas en los modelos multivariados que en los modelos obtenidos mediante percentiles. En estudios más recientes, Guan et al.(5) encontraron que al implementar el ACP en el acomodo antropométrico obtenido a través de modelos extremos para el diseño de cabinas, los percentiles 5 y 95 se encontraban dentro de la elipsoide ajustada, lo que significa que el nivel de acomodo es mayor en el análisis multivariado. Essdai et al. (42) compararon los resultados obtenidos mediante percentiles con los obtenidos mediante ACP para un nivel de confianza del 95 % y concluyeron que los modelos obtenidos mediante ACP generaban un mayor nivel de acomodo antropométrico. En 2013, Biswal & Dahiya identificaron 26 individuos extremos para seis parámetros críticos de diseño de cabinas, aplicando ACP a la base de datos antropométricos de la IAF (43). A pesar de los diversos estudios internacionales para el análisis del acomodo antropométrico de los modelos multivariados, no se ha encontrado evidencia de estudios similares para la población mexicana.

En el caso del modelado de la mano, pocos estudios se han realizado en el mundo, principalmente en el análisis de las características de trabajadores agrícolas(44), (45), industriales(46),(47) y una

mezcla entre individuos que desempeñan labores de oficina y del sector industrial(48). Las diferencias entre los sujetos de estudio ha sido reportada también en la literatura(49). Jee y Yun (48), analizaron los factores que influyen en la forma de la mano (por ejemplo: ancho de la mano, largo de la palma y la longitud de los dedos) e identificaron cuatro modelos que describen la forma de la mano mediante análisis multivariado. Al igual que en el análisis multivariado de las características antropométricas del cuerpo, tampoco se ha encontrado evidencia del análisis multivariado de las características físicas de la mano para la población mexicana. En el anexo B se encuentra la base teórica de los métodos multivariados basados en extremos más comunes.

2.2.2. Diseño multivariado basado en casos distribuidos

A pesar de que los métodos distribuidos (veáse C.1.2) no buscan cubrir la distribución total de la población objetivo mediante un determinado número de grupos, estos han sido implementados en la identificación de las características de los diferentes tipos de formas físicas del cuerpo humano (38). El diseño multivariado basado en casos distribuidos es también conocido como diseño para el ajuste de grupos, el cual busca identificar los grupos naturales en la población objetivo (38), dividiéndola en un número determinado de grupos con una variación mínima en el tamaño de cada uno de ellos (50). En este caso el problema de diseño es dividido en sub-problemas que consisten en un diseño colectivo para la población que conforma a cada uno de los grupos en donde la media, mediana y valores extremos son de interés (50). En este contexto, Brolin et al. (38), obtuvieron modelos que representan el tamaño o la talla del cuerpo humano empleando técnicas comunes de agrupamiento – k -means, análisis jerárquico y mezcla de modelos gaussianos – y concluyeron que implementar ACP con la finalidad de reducir la dimensionalidad del conjunto de datos antropométricos puede ser de utilidad al identificar los grupos en la población objetivo, si se considera la mayor cantidad de variabilidad explicada en el modelo. Con la finalidad de obtener modelos representativos basados en extremos mediante métodos distribuidos, los autores recomiendan seleccionar al individuo más lejano a la media o centroide de cada grupo como el individuo considerado como modelo representativo del grupo.

En algunos estudios se ha aplicado k -means para el agrupamiento de datos antropométricos (51), (52) y después de reducir la dimensionalidad del conjunto de datos mediante ACP (11), (53), (54), (55).

Abdali et al. (56) presentan una revisión de la literatura sobre la aplicación de las técnicas de agrupamiento en el análisis de la diversidad del tamaño del cuerpo humano. En el anexo C.1.2 se presenta la base teórica de las principales técnicas de clusterización.

2.3. Técnicas de captura de movimiento para la evaluación ergonómica en línea

Golabchi et al. (57) señalan que la confiabilidad de los resultados de las evaluaciones ergonómicas depende de la precisión de las variables de entrada empleadas en el análisis, mismas que puede ser afectada por los instrumentos de medición y dispositivos de sensado, así como por la percepción de éstas por parte del analista en el caso de los métodos observacionales. Por lo anterior, en años recientes las técnicas de modelado digital del movimiento del cuerpo han sido empleadas en el análisis biomecánico y la determinación del riesgo ergonómico. La observación de las posturas con fines de evaluación ergonómica de forma automática es de gran utilidad debido a su facilidad de implementación, flexibilidad y bajo costo, además de no ser invasivos (o ser minimamente invasivos) y no interrumpir la actividad laboral (29), (58). Por otra parte, Vignais et al. (59), señalan que la retroalimentación ergonómica en tiempo real, basada en captura de movimiento, disminuye los índices de riesgo de lesión, al informar continuamente al trabajador de las posturas estresantes adoptadas.

El modelado digital del movimiento del cuerpo ha sido posible gracias a la MoCap, que se define como el proceso de grabación de movimientos del cuerpo humano y su conversión en información matemática utilizable (29). En MoCap, los datos son representados comúnmente, mediante modelos de esqueletos de manos y de cuerpo entero que describen el movimiento a través de los cambios en el tiempo de las coordenadas cartesianas de las articulaciones y los ángulos entre los segmentos corporales (29).

En la literatura se han encontrado diferentes tecnologías para la implementación de la MoCap: sistemas ópticos, inerciales, y teléfonos inteligentes que integran sensores ambientales e inerciales (29). Yahya et al. (60) presentan una revisión del estado del arte de la MoCap para extremidades superiores, en la que clasifican a las tecnologías de captura de movimiento en cuatro grupos principales: sistemas ópticos, sistemas inerciales y sistemas basados en Electromiografía (EMG), mientras que Field et al. (61) incluyen también los sistemas conformados por sensores mecánicos y sensores acústicos. En las siguientes secciones se describen cada una de las categorías mencionadas.

2.3.1. Sistemas MoCap basados en sensores ópticos

Los sistemas ópticos están conformados por una cámara o una red multi-cámaras – por lo general infrarrojas, RGB y de profundidad – y, en algunos casos marcadores, que convierten la información en datos digitales para su uso posterior en entornos virtuales. Los sistemas pueden ser estacionarios o portables. Una clasificación básica de los sistemas MoCap basados en sensores ópticos comprende los siguientes tipos de sistemas(61):

- Sistemas basados en marcadores.

- Sistemas ópticos con marcadores pasivos.

Este tipo de sistemas emplea múltiples cámaras de alta velocidad (por lo general RGB) que permanecen fijas alrededor del área de medición con la finalidad de triangular la posición del marcador con precisión. Vicon® Nexus® y Optitrack® son sistemas comerciales conformados por marcadores pasivos ampliamente utilizados en la MoCap (60). Para disminuir los problemas de oclusión, requieren de sensores redundantes, lo que incrementa el proceso de latencia. Algunas de las ventajas de implementar este tipo de tecnologías radican en la alta precisión en la posición registrada ($error < 1mm$) además de que no son invasivos y no requieren que el sujeto bajo análisis porte alguna fuente de energía y un sistema de cableado para el funcionamiento del sistema, que pueden limitar el movimiento del usuario. Dentro de sus principales desventajas se pueden mencionar los espacios de trabajo fijos y reducidos, que se limitan al área de visión del sistemas de cámaras.

- Sistemas ópticos con marcadores activos.

Los marcadores activos actúan como una fuente de luz en lugar de un reflector – como en el caso de los marcadores pasivos– y son comúnmente empleados como diodos emisores de infrarrojos (61). Requieren de menor post-procesamiento que los sistemas con marcadores pasivos, ya que los marcadores individuales pueden ser identificados. Al igual que los sistemas con marcadores pasivos, el espacio de trabajo se limita al área de visión de las cámaras, que es un poco mayor en los sistemas con marcadores activos, y también pueden presentar oclusiones. Debido a los marcadores activos, pueden requerir de fuentes de poder y pequeños sistemas de cableado portados por el usuario, por lo que pueden limitar o disminuir su movimiento en el espacio de trabajo.

- Sistemas ópticos sin marcadores.

Requieren de un solo conjunto de cámaras, ubicadas en el mismo ángulo, similar a la visión humana, sin requerir de algún tipo de marcadores (61). Por lo general emplean cámaras de profundidad (un cámara combinada con un emisor infrarrojo) y una cámara con espectro de visión estándar (60). Microsoft Kinect® y Leap Motion® controller son dos sistemas MoCap que no requieren marcadores y emplean modelos digitales del esqueleto humano para rastrear el movimiento 3-D (60). Al igual que los sistemas con marcadores, se ven afectados por oclusiones, requieren de un alto costo computacional para el post-procesamiento de los datos y son altamente sensibles a las condiciones de iluminación. Dentro de las ventajas de su uso se pueden mencionar que no requieren carga adicional para el usuario, son portátiles y flexibles, por lo que pueden ser instalados en diferentes lugares de trabajo (61). Una gran cantidad de estudios con diversas finalidades se han realizado empleando el sensor Microsoft Kinect® (tablas 2.2, 2.3) , principalmente para la aplicación automática del método observacional

OWAS (62), RULA (10), (57), (63), (64), (59) y la ecuación de levantamiento NIOSH (65). En la actualidad estos sensores están siendo utilizados en la optimización del diseño de puestos de trabajo (66).

En 2013, Colombo et al. (67), emplearon dos sistemas MoCap para desarrollar una plataforma computacional que analice las posturas y movimientos de los usuarios y valide ergonómicamente el diseño del dispositivo. Utilizaron un sistema basado en seis cámaras web Sony Eje y otro basado en dos sensores Microsoft Kinect®. Los datos fueron analizados en el software Jack y mediante el paquete de simulación LifeMod.

Manghisi et. al. (68), emplearon el sensor Kinect® v2 para la determinación del nivel de riesgo mediante RULA. Diego-Mas y Alcaide-Marzal (13), en 2014, desarrollaron la aplicación ergonautas-NUI, mediante Delphi XE, para el procesamiento de los datos provistos por el sensor Microsoft Kinect, y compararon los resultados con los obtenidos por el método OWAS.

En 2017 Plantard et. al. (69) desarrollaron un método de evaluación ergonómica empleando datos obtenidos a partir de un sensor Microsoft Kinect® en condiciones reales de trabajo. Los autores reportan que, debido a la saturación del ambiente de trabajo, no fue posible colocar el sensor en la posición recomendada para obtener los mejores resultados. Los autores también indican que no fue posible monitorear la posición de la región mano-muñeca durante las actividades de los trabajadores. Plantard et. al. (70), emplearon un sistema de captura de movimiento mediante Kinect®, para obtener el modelo dinámico inverso, y concluyeron que el sensor es apto para este tipo de situaciones, siempre que no se presenten oclusiones.

Diversos estudios revelan que el sensor Microsoft Kinect® presenta una mayor precisión que los sistemas basados en marcadores para actividades de captura de movimiento (65) y caracterización antropométrica (71) (en comparación a procedimientos manuales y mediante dispositivos estereofotogramétricos), mientras que otros reportan que a pesar de que la exactitud se ve afectada significativamente por la colocación del sensor en el entorno de trabajo, el sensor proporciona la confiabilidad suficiente para ser utilizado en evaluaciones ergonómicas (62), (72). Moon et. al. (73) señalan que para resolver los problemas ocasionados por la auto-oclusión del sensor kinect, se requiere emplear múltiples cámaras de manera simultánea, de tal forma que los datos que no se pueden leer a través de un sensor, sean proporcionados por otro.

A pesar de su gran popularidad en la MoCap, los sistemas ópticos presentan ciertas desventajas: invasión a la privacidad, ya que no todos los individuos está preparados para ser monitoreados constantemente mediante cámaras, rango de visión limitado y alta complejidad computacional (74).

2.3.2. Sistemas de MoCap basados en sensores inerciales

Las Unidad de Medición Inercial (IMU) han sido ampliamente utilizados en la MoCap por ser de bajo costo y alta efectividad, principalmente en aquellos casos en los que el usuario no se puede desplazar a los espacios donde se encuentran instalados sistemas de medición ópticos (60). Los sensores inerciales proveen información sobre la aceleración y la velocidad angular a través de acelerómetros y giroscopios multi-ejes (61) que permiten obtener la posición y la orientación de los segmentos corporales (60). Algunos sensores inerciales comerciales integran magnetómetros multi-ejes, en los que la orientación del sensor puede conocerse, y por ende, su posición y orientación con respecto a un marco referencial global (60). La principal desventaja de los sensores inerciales es el *drift*, que es el cambio de las lecturas de salida con respecto al tiempo (60). Este error acumulado es consecuencia de la estimación de la posición por medio de la integración de la aceleración y/o la velocidad angular. Otra de las limitaciones de este tipo de tecnologías es la necesidad de post-procesamiento en ambientes inciertos (61). XSens® es uno de los sistemas MoCap conformado por sensores inerciales más utilizados (60).

Este tipo de sistemas de captura de movimiento ha sido de gran utilidad en diversas áreas desde actividades de rehabilitación y monitoreo por periodos largos en el sector salud, evaluación del desempeño en actividades deportivas hasta la captura de movimiento en películas y la industria de los videojuegos[29]. Algunas investigaciones relacionadas se detallan en (75), (76), (77), (78).

En el área de salud ocupacional, Battini, Persona y Sgarbossa (79), demostraron que la retro-alimentación ergonómica en tiempo real basada en la captura de movimiento mediante sensores inerciales disminuye los índices de riesgo de lesión. Además, Schall, et. al. (75) compararon la exactitud y repetibilidad de un sistema de captura de movimiento basado en sensores inerciales y concluyeron que el sistema puede ser un instrumento aceptable para la medición directa de las extremidades superiores y torso en la determinación de la exposición ocupacional del individuo.

Kim y Nussbaum (76) emplearon el sistema inercial de captura de movimiento XSens y el sistema de óptico ViconMX de 7 cámaras, para obtener la cinemática del cuerpo entero durante actividades de levantamientos. Se muestreó a 60Hz para determinar el nivel de riesgo por manipulación manual de cargas.

Vignais et. al.(80) , en 2017, realizaron el análisis ergonómico de actividades de manejo manual de materiales, tomando como referencia el método RULA, y empleando para ello técnicas de video análisis y captura de movimiento mediante sensores inerciales y electrogoniómetros. El sistema contaba de siete sensores Caption Motion (TEA, Nancy, France) de nueve grados de libertad (acelerómetro, giroscopio y magnetómetro), uno en cada brazo, antebrazo, cabeza, torso y uno más en la pelvis, (necesario para definir el movimiento del torso con respecto al segmento de la pelvis). Para monitorear los ángulos de las muñecas se emplearon dos electro-goniómetros bi-axiales (Biometrics, Ltd), sincronizados con el sistema de IMUs durante el post-procesamiento, mediante

CAPTIV software. Para realizar el análisis de la tarea y dividir la operación en elementos menores, se utilizaron cámaras RGB.

2.3.3. Sistemas MoCap basados en electromiografía (EMG)

La electromiografía (EMG) es la medición de la conductividad eléctrica generada por los músculos al realizar un movimiento. La principal desventaja de la EMG en la MoCap es su alta sensibilidad al ruido (*crossstalk*), que puede ser disminuida con la implementación de filtros pasa alta que remueven el movimiento del sensor (60). La colocación adecuada de los sensores es primordial en este tipo de sistemas, por lo que requieren de un experto para sujeción del sistema al usuario.

2.3.4. Sistemas MoCap basados en sensores mecánicos

El método más sencillo de MoCap es la medición directa empleando potenciómetros electromecánicos, que miden los cambios en la orientación de cada articulación (61). En estos sistemas, un encoder angular es colocado en cada una de las articulaciones que se desean monitorear. Los movimientos reales pueden ser determinados mediante las lecturas de cada uno de los encoders y la posición relativa de los mismos. Las principales ventajas de estos sistemas es que no se ven afectados por fuerzas externas y oclusiones, las mediciones pueden obtenerse de una forma rápida y el equipo es portable (sujetado al cuerpo mediante un exoesqueleto) y portátil (61). En los sistemas mecánicos el movimiento del usuario es comúnmente restringido por la rigidez del equipo portable ya que el exoesqueleto está conformado por redes de sensores conectados mediante cables, además de que las articulaciones humanas por lo general son más flexibles que las articulaciones mecánicas del exoesqueleto. Otro de los problemas a enfrentar cuando se implementa este tipo de tecnologías es la detección de la posición y orientación verdaderas del marco completo o global (61).

2.3.5. Sistemas MoCap basados en sensores magnéticos

Los sensores magnéticos proporcionan información de 6 Grados de Libertad (GDL) sobre la orientación y posición en un rango superior a 10 pies. Para determinar la posición, una perturbación es creada y transmitida a través de una antena, lo que permite conocer la orientación. Las ventajas de estos sensores incluyen la flexibilidad para posicionar los sensores en el cuerpo, además de no presentar problemas de oclusión. El área de medición es limitada al área de transmisión del sensor, sin embargo, presenta la ventaja de que el sensor puede ser transportado junto con el transmisor. Una de las ventajas de estos sensores es que los campos magnéticos pueden generar ruido en los datos (61).

2.3.6. Sistemas MoCap basados en sensores acústicos

La posición de un segmento corporal puede ser estimada mediante la intensidad de pulsos acústicos generados por transmisores acústicos y micrófonos: los micrófonos pueden medir la intensidad de los pulsos de cada transmisor para estimar las distancias relativas entre los sensores. Esta tecnología puede generar auto-oclusiones debidas al movimiento propio del cuerpo que puede bloquear una ruta directa de la señal a los micrófonos, además de sensibilidad al ruido, la temperatura y la humedad del ambiente, cuando se trata de ambientes cerrados, y al viento, cuando se trata de ambientes abiertos (61).

Tabla 2.2: Estado del arte de sistemas de captura de movimiento (MoCap)

Año	Autores	Objetivo	Tecnología	VARIABLES	Región anatómica	Frecuencia de muestreo
2013	Vignais, N. et al. (80)	Modelo biomecánico de las extremidades superiores mediante MoCap (IMU). Obtención de puntaje local y global RULA. Retroalimentación al usuario en tiempo-real sobre riesgo ergonómico	8 sensores inerciales Colibri [®] Tridso GmbH, Trier, Germany	No disponible	Cuerpo entero articulaciones principales	ND
2014	Diego M Alcázar M (83)	Aplicabilidad del sensor en evaluaciones ergonómicas	Kinect [®]	Posición: coordenadas cartesianas	Cuerpo entero articulaciones principales	ND
2016	Jarque-Bou N et al. (81)	Analizar el efecto del peso y el diámetro de cilindros en las posturas de agarre, empleando reducción cinemática	Sistema óptico Vicon [®] de 8 cámaras infrarrojas Bonita [®]	Posición 3D de 32 marcadores: 3 en el objeto, 29 en la mano	Mano	100Hz
2019	Peppoloni et al. (82)	Determinar el esfuerzo muscular (SI) y postural (RULA) de las extremidades superiores	Sensores inerciales Electromiografía	Ángulos de las articulaciones Máxima contracción voluntaria RMS de la intensidad del espectro de poder	Torso, brazo y mano Músculos flexores de la mano	ND 500Hz
2017	Vignais, N. et al. (80)	Análisis ergonómico mediante RULA para actividades de manipulación manual de cargas	Electrogoniómetros de dos ejes (Biometrics Ltd., Newport, UK) Sensores inerciales CAPTIV Motion IMUs Polar GRS00X	Orientación (flexión, extensión) Orientación Estrés fisiológico (ritmo cardíaco)	Mano Pelvis, torso, cabeza, brazo (2) y antebrazo(2) Pecho	32Hz 6Hz 120Hz
2019	Sedighi Z. et al. (85)	Estimar la fatiga física mediante sensores portables en ambientes de manufactura simulados	Sensores inerciales Shimmer3 (Shimmer, Dublin, Ireland)	Cambios en la postura (Aceleración y cambios en la inclinación) Disminución de la coordinación y control motoriz y temblores físicos (Variabilidad del movimiento) Cambios en la duración de la actividad (duración y repetición del movimiento)	Torso, cadera, muñeca y tobillo	51.2Hz
2017	Diego-Mas et al. (86)	Optimización del diseño de estaciones de trabajo mediante algoritmos evolutivos	Kinect [®]	Posición 3D	Extremidades superiores	30fps

Tabla 2.3: Estado del arte de sistemas de captura de movimiento (MoCap), continuación

Año	Autores	Objetivo	Tecnología	Variables	Región anatómica	Frecuencia de muestreo
2017	Golbachi, A. et al. (87)	Determinar el nivel de precisión asociado a las técnicas de adquisición de variables de entrada de los métodos de evaluación ergonómica: observacional vs MoCap óptico	Kinect®	Orientación 3D	Hombro, codo, muñeca, cuello y torso	ND
2018	Tammama, A. et al. (84)	Evaluar el uso de sensores inerciales en el análisis de actividades de levantamientos en ambientes exteriores no laborales	Sensores inerciales (APDM Wearable Technologies Inc.)	Velocidad angular	NA	128Hz
2018	Battini, D. et al. (79)	Evaluar el riesgo ergonómico en ambientes de almacén	17 Sensores inerciales (6GDM) IGS-180i	Orientación	Cuerpo entero Articulaciones principales	500Hz
2018	Föhrer, G.S. et al. (85)	Monitorizar de manera continua y ambulatoria la fuerza de la mano en actividades de manipulación manual de cargas	Sensores inerciales (Certus Optitrak OMC)	Variables de cinemática	Cuerpo entero	50Hz
			Plastillas de fuerza (6 Kistler FPs) Force alphas (FS, Xsens Technologies, Netherlands)	Variables de cinemática	Cuerpo entero	120Hz
2018	Choment, J. et al. (86)	Analizar la reproducibilidad del estado de trabajo de los miembros superiores y el efecto de los protocolos de adquisición, género y dominancia de la mano	6 Cámaras Optitrack V100 R2 Natural Point Inc.	Orientación	Extremidades superiores Articulaciones principales	100Hz
2019	Merino G. et al. (87)	Evaluar los riesgos de lesión músculo-esquelética	Sensores inerciales (XSens Technologies BV) Electromiografía	Ángulos de las articulaciones Frecuencia mediana error cuadrático medio	Brazo, codo y pierna Trápico superior biceps braquial, extensor y flexor codo	120Hz 60Hz
2019	Taboacou, K. et al. (88)	Analizar los patrones de postura de cirujanos con dos niveles de habilidad durante cirugía laparoscópica	6 Cámaras Optitrack Flex3 Natural Point Inc.	Tiempo total Orientación	Cabeza, torso, hombro, codo y muñeca	100Hz

2.4. Reconocimiento de los movimientos de la mano

El Reconocimiento de las Actividades Humanas (RAH) ha sido de gran utilidad en el análisis de la interacción hombre-máquina, del comportamiento en el hogar así como en el análisis de la marcha y el reconocimiento de gestos (89), (90). El RAH busca identificar actividades con base en

información obtenida mediante sensores, lo que es posible gracias a sistemas MoCap(74).

En el caso del Reconocimiento en la Manipulación de Objetos (RMO), éste resulta complejo debido a que los individuos pueden seleccionar la estrategia de agarre de manera independiente y aplicar diferentes niveles de fuerza, de acuerdo con las características de los objetos (91). Por lo anterior, se recomienda que los sistemas MoCap empleados en el RMO, incluyan sensores táctiles y de fuerza, además de sensores inerciales (91).

La clasificación principal de las tecnologías de sensado para el RMO se basa principalmente en el nivel de invasividad de los sensores utilizados en el usuario y en el área de trabajo (91),(92). Los sistemas de sensores para el movimiento de la mano que requieren contacto con el usuario se clasifican en: captura mediante guantes de datos, captura mediante sensores de fuerza y captura a través de Electromiografía de superficie (sEMG) (91). Los sistemas que no requieren de contacto directo con el usuario se clasifican en: captura mediante marcadores ópticos y captura basada en visión (91),(92).

Por lo general, los guantes de datos son guantes típicos adaptados con sensores (magnéticos o de fibra óptica) que registran la flexión de los dedos (91). El sistema de sensores se puede complementar mediante sensores de fuerza, que registran las características de la fuerza de contacto en tiempo real. El uso de guantes de datos en la captura de movimientos de la mano es recomendado a pesar de los problemas que se pueden presentar por las diferencias de talla y el ajuste, así como la calibración para la lectura real de los ángulos de las diferentes tamaños de mano. La desventaja principal de los guantes, es que pueden disminuir la flexibilidad de los movimientos de la mano, debido a la conexión física de los sensores.

Por otra parte, los sEMG son empleados en la evaluación de las respuesta biológica de los movimientos de los músculos específicos, principalmente para el control de prótesis (91). A pesar de que los sEMG son ampliamente utilizados, es necesario estudiar la manera de eliminar o disminuir los efectos del *crosstalk* debido al desplazamiento de los electrodos, así como la redundancia de la información y la selección y evaluación adecuada de las características de las señales puras (91). Koskimaki & Siirtola (93) encontraron que en el reconocimiento de actividades individuales, la captura de movimiento mediante acelerómetros brinda mejores resultados que la obtenida mediante sEMG, incluso mediante la combinación de ambos (acelerómetros y sEMG). Riek et al. (58), concluyeron que las señales sEMG afectan el desempeño del clasificador en tareas que implican el levantamiento de brazos y de objetos. Los autores señalan también que algunas herramientas de aprendizaje profundo tuvieron un desempeño menor al incluirse señales sEMG (58).

En el caso de los sistemas no invasivos, los marcadores ópticos se emplean para describir el movimiento de las manos en un espacio dimensional pequeño, por lo general se utilizan en conjunto con cámaras que permiten su detección en la imagen (91). Las principales desventajas de este tipo de tecnología es la oclusión que puede ser ocasionada por objetos del área de trabajo o bien por el mismo usuario, además del error ocasionado por la colocación incorrecta del marcador y a su

desplazamiento, derivado de los movimientos del cuerpo (91).

En la literatura existe evidencia de estudios que tienen como finalidad el RAH y RMO. Junker et al.(94) , emplearon un sistema de cuatro sensores inerciales, dos posicionados en la muñeca y otros dos colocados en el brazo y torso, para detectar los gestos de comer y beber en un primer grupo de estudio, así como el saludo de mano, contestar y colgar el teléfono en un segundo grupo. Se emplearon Modelos de Markov Ocultos (HMM), obteniendo un *recall* promedio del 79 % para el primer grupo, y de 93 % para el segundo. Moschetti et al. (95), analizaron nueve movimientos diferentes de la vida diaria, que implican el movimiento de la mano y la muñeca (comer con la mano, con un tenedor y con una cuchara, beber de un vaso y de una taza, contestar el teléfono, cepillarse los dientes y el cabello y utilizar una secadora de cabello). El análisis se realizó mediante Máquina de Vectores de Soporte (Máquina de Vectores de Soporte (SVM)) y árboles de decisión. De Vries et al. (96), investigaron la mejor combinación de sensores para la clasificación del movimiento alcanzar-tomar, con la finalidad de realizar la identificación de la intención del movimiento con solo sensores inerciales. La detección de la intención se busca sea antes de requerir información proveniente de sensores de fuerza.

También se ha encontrado evidencia del desarrollo de guantes de captura de movimiento de bajo costo para uso en rehabilitación de pacientes con eventos cerebrovasculares ((97), (98), (99), (100)). La principal restricción de estos guantes, es que no consideran el movimiento de todos los dedos de la mano o bien no incluyen sensores que permitan registrar el esfuerzo realizado por cada dedo.

Diversos estudios han analizado el movimiento de la mano mediante sensores inerciales. Fang et al. (101), emplearon 18 sensores inerciales para la captura de movimiento de la mano con la finalidad de utilizar la información en la teleoperación de robots, mientras que Choi, et al. (102), propusieron un guante de 17 sensores inerciales. El uso de dicha cantidad de sensores representa un mayor costo computacional, además de que no considera las características del esfuerzo ejercido por la mano y los dedos en la manipulación de los objetos. Algunos trabajos relacionados con la identificación de riesgos ergonómicos emplearon el guante Cyberglove ((20), (19)), sin embargo, la principal limitante del uso de este sistema comercial es su elevado costo, además de que no consideran el esfuerzo de la mano.

Riek et al. (58), (103), analizaron la eficacia de la captura de movimiento mediante sensores portables en el reconocimiento de actividades motrices finas (manipulación de legos) y gruesas (representadas mediante actividades comunes de la industria automotriz).

La literatura muestra evidencia del análisis de los movimientos de la mano mediante sensores inerciales para la identificación de gestos de la vida diaria, sin embargo en la revisión de la literatura se encontraron pocos estudios cuya finalidad es la identificación del tipo de agarre, principalmente de los utilizados en actividades laborales del sector industrial, basados en la taxonomía GRASP (104).

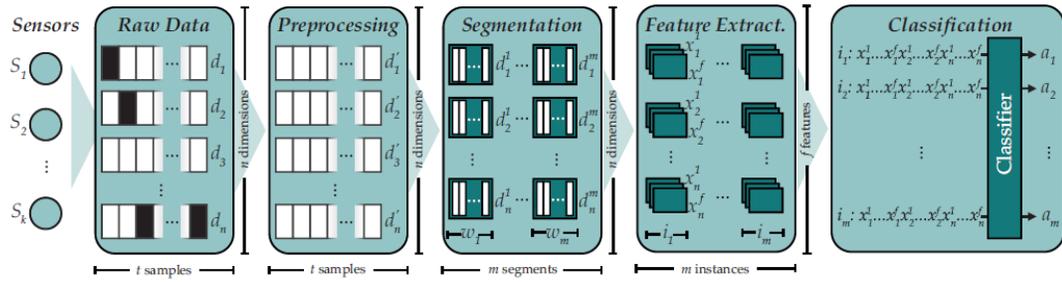


Figura 2.4: Metodología para el RAH- CRA (2)

2.5. Metodología para el Reconocimiento de las Actividades Humanas

El reconocimiento de actividades puede ser analizado como un problema de clasificación, tratado principalmente como un problema de aprendizaje supervisado (2). Bulling et al.(105), presentan el modelo típico de la Cadena de Reconocimiento de Actividades (CRA), en la que se describe la metodología recomendada para el reconocimiento de actividades mediante sistemas MoCap portables. La metodología propuesta involucra la adquisición y el pre-procesamiento de las señales, la segmentación de los datos, la selección y la extracción de características, así como el entrenamiento y clasificación de la información (Figura 2.4).

1. Adquisición de datos y pre-procesamiento Los datos crudos son adquiridos mediante sensores colocados en diferentes puntos del cuerpo. Debido a que algunos sensores pueden proporcionar múltiples variables o múltiples sensores son muestreados, la salida del sistema de sensores es descrita mediante notación vectorial:

$$s_i = (\mathbf{d}^1, \mathbf{d}^2, \mathbf{d}^3, \dots, \mathbf{d}^t), \text{ para } i = 1, \dots, k \quad (2.1)$$

donde k representa el número de sensores y d^i los múltiples valores obtenidos en el tiempo t . La segunda parte de la metodología, el pre-procesamiento, transforma las series de tiempo de datos crudos multivariados y asíncronos en series de tiempo preprocesadas \mathbf{D}' :

$$\mathbf{D}' = \begin{pmatrix} d_1^{\prime 1} & \dots & d_1^{\prime t} \\ \vdots & \dots & \vdots \\ d_n^{\prime 1} & \dots & d_n^{\prime t} \end{pmatrix} = (\mathbf{d}'_1, \dots, \mathbf{d}'_t)^T \quad (2.2)$$

El pre-procesamiento de las señales de acelerómetros y giroscopios involucra la calibración,

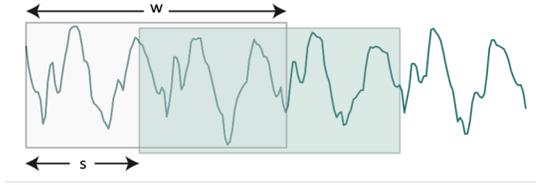


Figura 2.5: Ventana Móvil (2)

conversión de unidades, normalización, re-muestreo, sincronización o fusión a nivel de señales; mientras que las señales fisiológicas, requieren de algoritmos de pre-procesamiento para eliminar el ruido o remover el *drift* (105), (106).

2. Segmentación de los datos

En este paso los flujos de datos continuos obtenidos por los sistemas MoCap, son divididos en segmentos más pequeños para su procesamiento posterior (ventanas). Cada segmento de datos $\mathbf{w}_i = (t_1, t_2)$ es definido por el tiempo de inicio t_1 y el tiempo final t_2 en la serie de tiempo. Como resultado se tiene un segmento W que contiene una actividad potencial y :

$$W = \{\mathbf{w}_1, \dots, \mathbf{w}_m\} \quad (2.3)$$

Para contrarrestar el problema de definición de a actividad en la segmentación de series de tiempo de datos continuos, se han implementado tres estrategias:

- a) *Ventana móvil.* La ventana se mueve a través de la serie de datos para extraer un segmento de datos que es empleado en los siguientes pasos de la CRA 2.5. El tamaño de la ventana impacta directamente la demora del sistema de reconocimiento. A mayor paso, menor cantidad de datos se tendrán después de la extracción de características, mientras que pasos pequeños pueden resultar en volúmenes in-manipulables de información. La segmentación basada en ventanas de tiempo puede ser manejada de dos maneras: sin-traslape y con-traslape. La primera de ellas implica segmentos en los cuales los valores de una ventana no se intersectan con valores de otras ventanas ($w_1 \cap w_2 = \emptyset$), mientras que las ventanas con traslape son segmentos representados por un porcentaje que define cuantas muestras de la ventana previa se intersectan con la ventana siguiente ($w_1 \cap w_2 \neq \emptyset$). En el caso de sensores inerciales, el tamaño de las ventanas es definido en función del intervalo de tiempo y la frecuencia de muestreo. Estudios indican que el tamaño recomendado para ventanas fijas varía de 2 a 5 segundos para frecuencias de muestreo de 20Hz a 50Hz (107).
- b) *Segmentación basada en energía.* Este tipo de segmentación se basa en el hecho de que diferentes actividades se realizan con diferentes intensidades, lo que permite identificar

los segmentos en función de un umbral de energía.

- c) Sensores adicionales y fuentes contextuales. Un ejemplo de este tipo de segmentación, es la utilizada en el registro de datos de aceleración por tiempos prolongados que pueden ser segmentados en función de la información obtenida mediante un GPS.

3. Selección y extracción de características

Una característica puede ser definida como un elemento dotado de información útil acerca de los datos que representa. En el RAH, una característica representa los diferentes patrones de movimiento de las actividades físicas del usuario (107). En esta etapa el conjunto de datos es reducido en características con poder discriminatorio para el reconocimiento de actividades. Las características son extraídas como vectores de características \mathbf{X}_i en el conjunto de segmentos W :

$$\mathbf{X}_i = F(\mathbf{D}', \mathbf{w}_i) \quad (2.4)$$

donde F es la función de extracción de características. El número total de características extraídas se denomina *espacio de características*. A mayor dimensionalidad del espacio de características, más datos de entrenamientos son requeridos, así como mayor es la complejidad computacional de la clasificación. En este contexto la literatura clasifica las características en diferentes dominios de representación: dominio del tiempo, dominio de la frecuencia y dominio discreto (Tabla 2.4).

a) Dominio del tiempo:

Son métricas estadísticas y matemáticas simples ampliamente utilizadas en el contexto de sensores inerciales para extraer información básica de la señal a partir de datos crudos. Estas métricas pueden ser divididas en dos tipos principales de funciones: estadísticas y no estadísticas. Las funciones estadísticas involucran cálculos como valores mínimo, máximo, media, desviación estándar, entre otros. Las métricas no estadísticas involucran cálculos más demandantes como determinación de áreas y distribuciones.

b) Dominio de la frecuencia:

Estas técnicas han sido ampliamente utilizadas para capturar la naturaleza repetitiva de las señales de los sensores, que por lo general correlaciona la naturaleza periódica de una actividad específica. Por lo general, las características extraídas en este dominio son calculadas con base en la transformada de Fourier de bajo nivel o en las características Wavelet. Ambas transformaciones son herramientas matemáticas que permiten el cambio de las variables en el tiempo por variables en el dominio de la frecuencia, esto es, la señal es descompuesta en un conjunto de valores reales e imaginario que representan las ondas llamadas frecuencias.

- Transformada de Fourier: En la representación espectral (dominio de la frecuencia)

de las características de señales en el dominio del tiempo, los principales periodos o intervalos de repetición de la señal son representados por valores diferentes de cero o coeficientes en el correspondiente valor del eje de la frecuencia. Una señal en el tiempo con patrones periódicos centrada alrededor de un intervalo de repetición de 0.5-s presentará un coeficiente Fourier notablemente centrado en 2Hz de eje de frecuencia. Para realizar la transformación de Fourier, generalmente se emplea un algoritmo eficiente que obtiene la transformación discreta de Fourier (llamada transformación rápida de Fourier (TRP)), que emplea la ecuación 2.5:

$$FFT(X) = \sum_{k=0}^{n-1} x_k \exp^{-2\pi i j \frac{k}{n}} \quad (2.5)$$

donde x_k es una secuencia de tamaño n que representa una señal continua, y $\exp^{-2\pi i j \frac{k}{n}}$ representa la n^{th} raíz primitiva de cada unidad de x_k .

- Transformada Wavelet: esta transformación es similar a los cálculos de la transformación de Fourier, la diferencia principal consiste en que los valores de los rangos son representados en términos de bases ortogonales.

c) Dominio discreto:

En este dominio, se busca transformar las señales continuas en *strings* de símbolos discretos. Un aspecto importante de la transformación es el proceso de discretización, en el que la limitación de los símbolos incluidos en el alfabeto pueden generar una compresión sustancial en la representación de la señal.

Dominio	Características
Frecuencia	mínimo, máximo, amplitud, picos de amplitud, suma, suma absoluta, norma euclídeana, media, media absoluta, media cuadrada, desviación media absoluta, suma de errores al cuadrado, varianza, desviación estándar, coeficiente Pearson, correlación, correlación cruzada
Tiempo	energía, energía normalizada, poder, centroide, entropía, componente DC, picos, suma de coeficientes

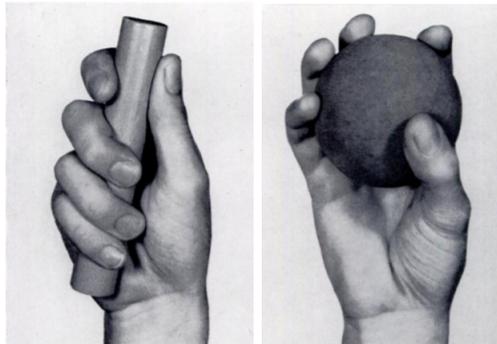
Tabla 2.4: Características en los diferentes dominios

4. Entrenamiento y clasificación

Consiste en entrenar un clasificador (véase C) y realizar la predicción de las actividades en función del modelo entrenado.

2.6. Manipulación manual de objetos: agarre

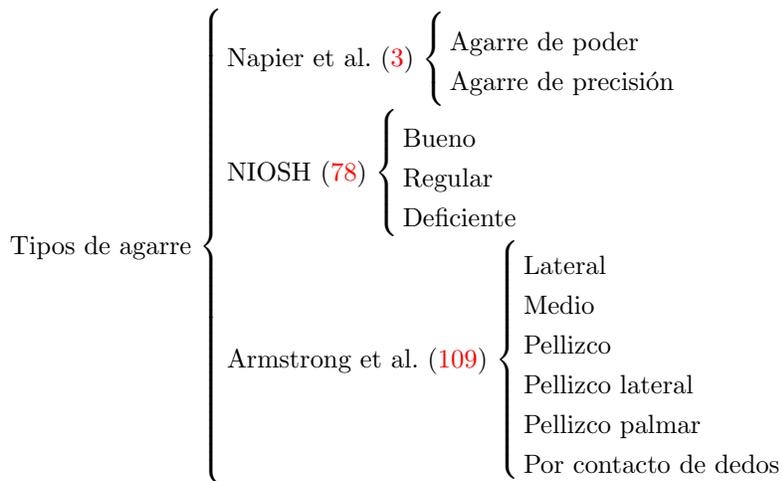
El agarre se define como la postura de la mano con la que un objeto puede ser tomado de manera segura con una mano, sin importar la orientación de la mano(104) y puede generar un riesgo en los movimientos repetitivos. La naturaleza del agarre del objeto puede afectar no solamente la fuerza máxima que un trabajador puede ejercer en un objeto, sino también la localización vertical de las manos durante la actividad de levantamientos (108). Existen diferentes clasificaciones de los tipos de agarre de objetos. Napier (3) identificó dos tipos de agarres: de precisión y de poder. El primero de ellos consiste en tomar el control de un objeto mediante el contacto de las yemas de los dedos y el pulgar, con la finalidad de realizar actividades que requieran un alto nivel de detalle. El agarre de poder se lleva a cabo en actividades que requieren un alto nivel de fuerza, cuando el objeto es sostenido entre los dedos y la palma, con el dedo pulgar en abducción.



(a) *Agarre de precisión* (b) *Agarre de poder*

Figura 2.6: Tipos de agarre identificados por Napier (3)

El National Institute of Occupational Safety and Health (NIOSH), define tres tipos de agarre: bueno, regular y deficiente (108). De acuerdo con esta clasificación, un agarre bueno puede reducir al máximo las fuerzas máximas requeridas para manipular el objeto y con ello incrementar el peso máximo recomendado para actividades de levantamientos, mientras que un agarre deficiente generalmente requiere de fuerzas máximas superiores y disminuye el peso máximo recomendado para el levantamiento(108).



Armstrong et. al. (109) propusieron seis categorías de agarre: agarre lateral, agarre medio, agarre de pellizco, agarre de pellizco lateral, agarre de pellizco-palmar y agarre por contacto de dedos (110).

Kyung-Sun Lee y Myung-Chul Jung (110), (102) indican que además de la postura de la mano, la frecuencia de la misma y las características del objeto (forma, ubicación y dirección) son variables relevantes en la clasificación adecuada de en actividades de la vida diaria.

Existen diversas investigaciones orientadas a la clasificación del agarre y la manipulación de objetos de forma automática, para su aplicación en rehabilitación (111) y en realidad virtual y video juegos (112), entre otros. De acuerdo con Martin-Brevet et.al. (110) el análisis cuantitativo de las funciones de la mano en actividades de levantamientos ha sido restringido a agarres de precisión, por lo que propusieron una taxonomía conformada por 11 clases de agarre, obtenidas a partir de la fuerza de agarre estimada mediante sensores de fuerza colocados en el objeto manipulado durante el experimento. La principal desventaja de esta clasificación es que se basa en la fuerza detectada en el objeto manipulado, sin considerar la fuerza ejercida, así como la cinemática de la mano durante la actividad.

Metodología

Para llevar a cabo el presente estudio se empleó la metodología mostrada en la figura 3.1. En ella se identifican cinco etapas principales: *identificación del somatotipo*, *diseño e implementación del sistema MoCap*, *identificación del tipo de agarre*, *evaluación ergonómica (clasificadores, automática y expertos)* y *análisis estadístico de los resultados*. Cada una de las etapas de la metodología se describen en los siguientes apartados.

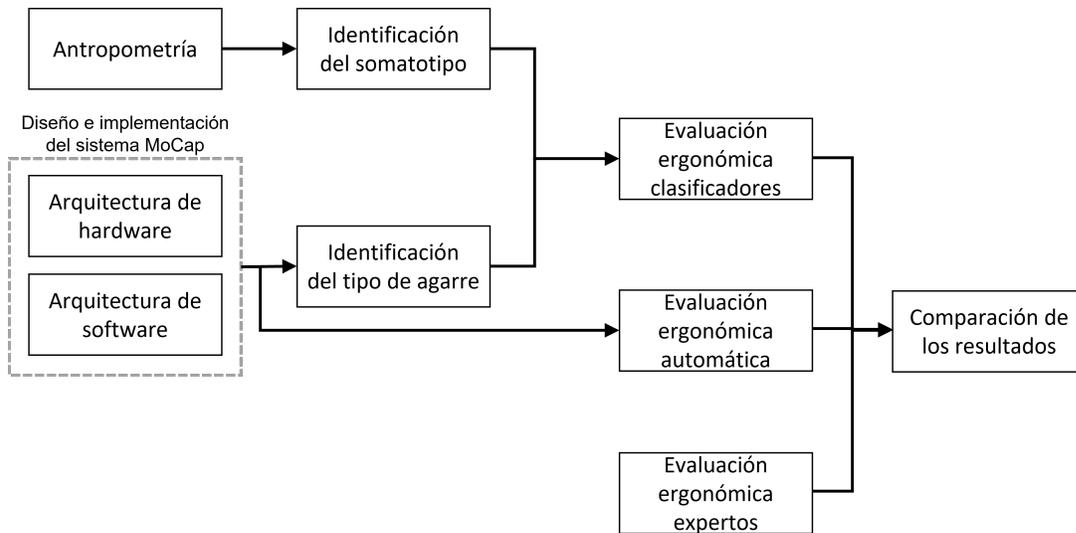


Figura 3.1: Metodología empleada para abordar el problema de investigación

3.1. Diseño e implementación del sistema MoCap: guante de datos

Se diseñó e implementó un sistema MoCap para la región anatómica mano-muñeca, cuya finalidad es recopilar datos que permitan describir los movimientos de la mano, que serán empleados en el reconocimiento del tipo de agarre mediante técnicas de clasificación clásicas.

En la etapa de diseño del sistema MoCap la selección adecuada de los sensores y de la plataforma de prototipado electrónico, así como el desarrollo de aplicaciones para el procesamiento de los datos recolectados son de gran importancia. Las arquitecturas de hardware y software implementadas son descritas a continuación.

3.1.1. Arquitectura de hardware

Para la captura de los descriptores cinemáticos de la mano y dedos se emplearon sensores inerciales. Una de las ventajas de este tipo de tecnologías es que disminuyen las interrupciones en las lecturas debidas a oclusiones ocasionadas por la saturación del entorno y por el mismo usuario. Para el registro de información concerniente al esfuerzo realizado por la mano y los dedos se integraron sensores resistivos de fuerza al guante de datos. En la figura 3.2 se presenta la arquitectura de hardware implementada en el sistema MoCap. A continuación se describen los sensores utilizados.

- Sensores inerciales.

El guante de datos está conformado por seis sensores inerciales Sparkfun IMU Breakout – MPU-9250 de 9 grados de libertad (GDL) (Figura 3.3), que combinan dos chips:

1. MPU-6500, integrado por los siguientes sensores:

- Acelerómetro de 3 ejes: permite leer las componentes de la aceleración ($aceleracion_x$, $aceleracion_y$ y $aceleracion_z$), con una escala programable de ± 2 , ± 4 , ± 8 y ± 16 gravedades. Las lecturas del acelerómetro se caracterizan por ser menos precisas en tiempos cortos, por lo que el sesgo en la medición se disminuye conforme se incrementa el tiempo de observación. Las especificaciones del acelerómetro incluyen un *offset* de ± 60 mg, ruido de $300 \mu g\sqrt{Hz}$ y $18 \mu A$ de corriente en el modo *low-power*, además de contar con un Convertidor Análogo-Digital) integrado de 16-bit. Las especificaciones del acelerómetro se muestran en la tabla 3.1.
- Giroscopio de 3 ejes: proporciona la velocidad angular en cada una de sus componentes ($velocidadAngular_x$, $velocidadAngular_y$ y $velocidadAngular_z$). La mayoría de los giroscopios comerciales presentan lecturas diferentes a cero en la medición de la velocidad angular cuando estos no están movimiento, a lo que comúnmente se

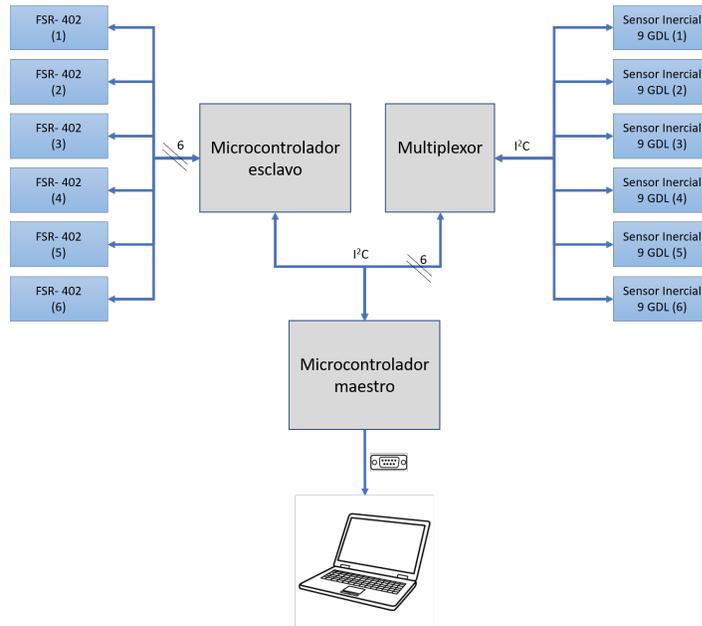


Figura 3.2: Arquitectura de hardware del guante de datos

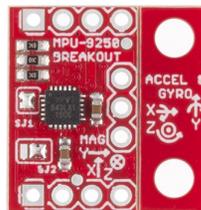


Figura 3.3: Sparkfun IMU Breakout – MPU-9250

Tabla 3.1: Especificaciones del acelerómetro MPU-6500

Rango de escala completo (°/s)	Sensibilidad LBS/°/s
±2	16384
±4	8192
±8	4096
±16	2048

Tabla 3.2: Especificaciones del giroscopio MPU-6500

Rango de escala completo mdps/rtHz	Sensibilidad g	Tasa de ruido LSB/g
±250	131	0.01
±500	65.5	0.01
±1000	32.8	0.01
±2000	16.4	0.01

Tabla 3.3: Especificaciones del magnetómetro AK8963

Característica	Especificación
Resolución de salida	14-bit (0.6 μ T/LBS) 16-bit (0.15 μ T/LBS)
Rango de medición	±4900 μ T
Corriente promedio a una tasa de repetición de 8Hz	280 μ A typ

denomina *error de compensación del sesgo* (113). Este error es aditivo, y tiene como consecuencia una desviación importante de las lecturas, que se acumula conforme se incrementa el tiempo de análisis (113). El giroscopio proporciona una salida de ± 5 dps *zero rate* además de contar con un ADC integrado de 16-bit. Las especificaciones del giroscopio se muestran en la tabla 3.2.

2. Magnetómetro AK8963 de tres ejes: este sensor mide los campos magnéticos detectados por el dispositivo, y son presentados en los tres ejes (*campoMagnético_x*, *campoMagnético_y* y *campoMagnético_z*) y su unidad de medición son microTeslas (μ T). Además de las imperfecciones comunes de los sensores (sesgos, alineación inadecuada, etc), los campos magnéticos son afectados severamente por los materiales adjuntos al marco de referencia del sensor (114). La desviación debida a los materiales magnéticos cercanos al sensor, comúnmente llamada *desviación magnética dura*, causa una error permanente en las lecturas del sensor. Por otra parte, los materiales ferromagnéticos de la plataforma del sensor alteran el campo magnético existente, causando las *desviaciones magnéticas blandas* (Figura 3.4). Las especificaciones del sensor se muestran en la tabla 3.3.

La razón principal del uso del sensor Sparkfun IMU Breakout – MPU-9250 es su tamaño y forma, ya que su diseño facilita su colocación a lo largo de los dedos, a diferencia de otros sensores inerciales comerciales de 9GDL cuyo tamaño es aproximadamente 50 % mayor (en comparación con el IMU-9150).

- Sensores resistivos de fuerza

Los Sensores Resistivos de Fuerza son películas delgadas de polímero que capturan la disminución de la resistencia al incrementar la fuerza ejercida en la superficie de contacto del

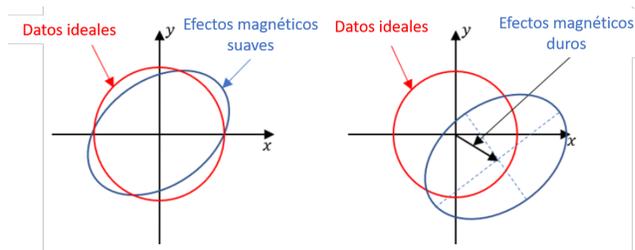


Figura 3.4: Efectos magnéticos de los magnetómetros



Figura 3.5: FSR 402

sensor. La sensibilidad a la fuerza es optimizada para el uso en interfaces hombre-máquina dentro de las que se pueden mencionar electrónicas automotrices, sistemas médicos y controles industriales y robóticos. El guante de datos cuenta con seis sensores FSR-402 (Figura 3.5) cuyas especificaciones se muestran en la tabla 3.4.

Tabla 3.4: Especificaciones FSR 402

Característica	Especificación
Actuación	0.2N min
Rango de sensibilidad	0.2N - 20N
Resolución	Analógica(continua)
Repetibilidad	$\pm 2\%$
<i>Drift</i> a largo plazo	$< 5\% \log_{10}(\text{tiempo})$

La conexión de los FSR se realizó mediante un divisor de voltaje (Figura 3.6) implementado en una Tarjeta de Circuito Impreso.

- Sistema maestro-esclavo.

Se utilizó un sistema maestro-esclavo conformado por una tarjeta de desarrollo SparkFun RedBoard Qwiic(maestro)(Figura 3.7) y una tarjeta de desarrollo Arduino Nano (esclavo).

La tarjeta SparkFun RedBoard Qwiic cuenta con un puerto qwiic además de las características

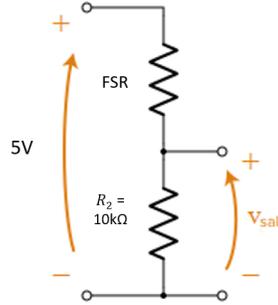


Figura 3.6: Divisor de voltaje FSR

de la tarjeta Arduino Uno R3. Los sistemas qwiic fueron desarrollados por Sparkfun en 2017, y permiten conectar sensores y actuadores mediante el protocolo I²C haciendo del prototipado una actividad más rápida y menos propensa al error. Los dispositivos qwiic (Figura 3.7) contienen un conector JST de 4 pines polarizado, que reduce las dimensiones de las tarjetas de circuitos impresos.

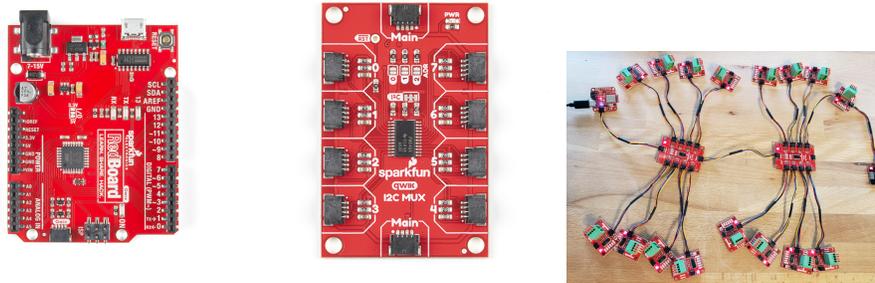
Los sensores inerciales se conectaron mediante el puerto qwiic a un multiplexor Sparkfun Qwiic de 8 canales (Figura 3.7), que permite la selección del sensor inercial. El multiplexor es a su vez, conectado mediante un puerto qwiic a la tarjeta maestra.

La tarjeta esclava captura la lectura de los seis FSR y envía la información a la tarjeta maestra mediante el protocolo I²C.

La frecuencia de muestreo del guante de datos es de 25Hz, misma que se encuentra en el rango de tasa de muestro recomendada en la literatura para el reconocimiento de actividades humanas (92),(115). Una de las ventajas de contar con frecuencias de muestreo bajas es el bajo costo computacional que representa el procesamiento de la información una vez que esta es obtenida (103).

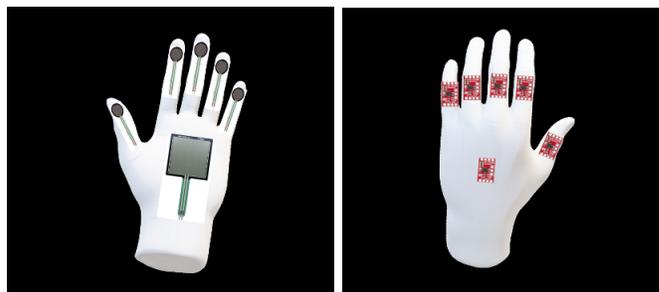
Los datos crudos obtenidos mediante el sistema MoCap son transferidos por comunicación serial a una computadora portátil con sistema operativo Windows 10, procesador Intel Core i7-8550U de 4.0 Ghz y 16 GB de RAM.

La red de sensores del sistema MoCap se colocó en un guante de uso común, en el que los sensores inerciales se posicionaron en las falanges proximales de cada dedo y en el dorso de la mano, mientras que los FSR-402 se posicionaron en la yemas de los dedos y en la palma de la mano, tal como se muestra en la fig. 3.8. La figura 3.9 muestra la versión final del guante de datos desarrollado.



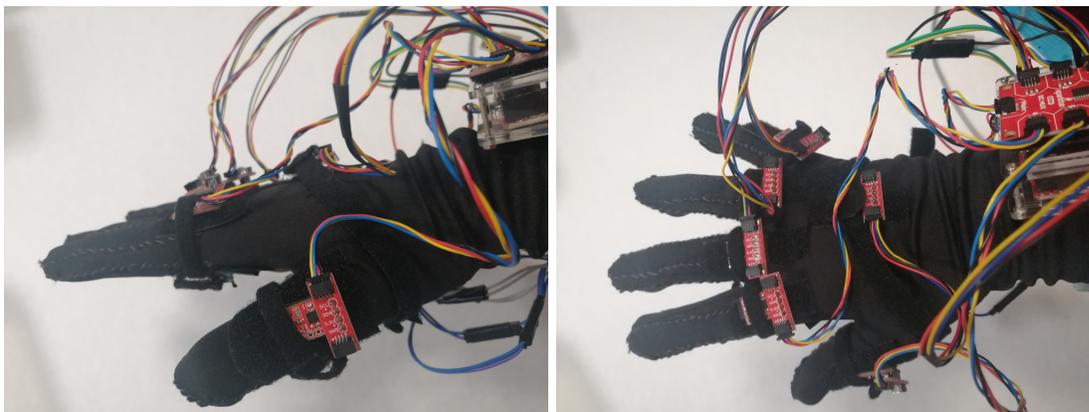
(a) SparkFun RedBoard (b) SparkFun Qwiic Breakout (c) Ejemplo de sistema qwiic

Figura 3.7: Elementos del sistema qwiic



(a) Palma - FSR (b) Dorso - sensores inerciales

Figura 3.8: Ubicación de los sensores en el guante de datos



(a) Vista lateral (b) Vista superior

Figura 3.9: Sistema MoCap - guante de datos

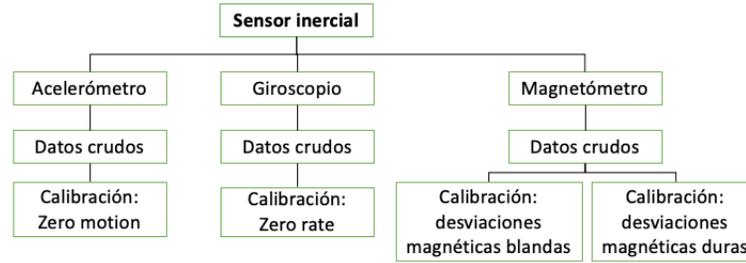


Figura 3.10: Calibración del sensor inercial

3.1.2. Arquitectura de software

Se diseñó una aplicación para administrar la comunicación entre el dispositivo MoCap y la computadora personal, así como para realizar el análisis de los datos. Se empleó el entorno de desarrollo integrado de Arduino para la programación, configuración y lectura de los sensores que conforman el guante de datos, mientras que para el procesamiento y análisis de los datos obtenidos, se empleó el software Matlab[©] 2019a.

3.1.3. Pre-procesamiento de los datos

Los datos crudos obtenidos mediante el guante de datos, fueron pre-procesados para ser utilizados posteriormente en los algoritmos de clasificación. En el caso de los sensores inerciales, las desviaciones propias de los dispositivos hacen necesaria la calibración de los acelerómetros, giroscopios y magnetómetros, así como la conversión de los datos crudos a unidades de medición convencionales. Con la finalidad de integrar la información obtenida mediante los FSR, las lecturas registradas son convertidas a diferentes unidades.

3.1.3.1. Calibración de sensores inerciales

El procedimiento de calibración se realizó de manera independiente para cada uno de los sensores que conforman la unidad de medición inercial (3.10). La calibración del acelerómetro requirió del procedimiento *zero motion*, en el que las lecturas se toman cuando el sensor se encuentra en reposo, sin movimiento, sobre una superficie plana y con el eje z orientado en dirección opuesta a la superficie plana. El *offset* del acelerómetro se obtuvo mediante el promedio de 1,000 lecturas (ecuaciones 3.1).

$$\begin{aligned}
 acc_{offset_x} &= \frac{\sum_{i=1}^{1000} Aceleracion_{x_i}}{1000} \\
 acc_{offset_y} &= \frac{\sum_{i=1}^{1000} Aceleracion_{y_i}}{1000} \\
 acc_{offset_z} &= \frac{\sum_{i=1}^{1000} Aceleracion_{z_i}}{1000}
 \end{aligned} \tag{3.1}$$

En el caso del giroscopio, el *offset* se determinó mediante el promedio de 1,000 lecturas registradas mientras el sensor estaba en reposo, sin importar su orientación (*zero rate*). Las ecuaciones correspondientes se muestran en 3.2.

$$\begin{aligned}
 gyro_{offset_x} &= \frac{\sum_{i=1}^{1000} VelocidadAngular_{x_i}}{1000} \\
 gyro_{offset_y} &= \frac{\sum_{i=1}^{1000} VelocidadAngular_{y_i}}{1000} \\
 gyro_{offset_z} &= \frac{\sum_{i=1}^{1000} VelocidadAngular_{z_i}}{1000}
 \end{aligned} \tag{3.2}$$

El magnetómetro fue calibrado tanto para los efectos magnéticos suaves como para los efectos magnéticos duros (Figura 3.4) mediante la función *magcal* disponible en el software Matlab 2019a[©].

En las figuras 3.11 y 3.12 se presentan los resultados de la calibración del acelerómetro y del giroscopio, respectivamente. En ambas figuras se puede observar que los datos calibrados (color azul) se encuentran centrados en el valor 0.

La calibración de los efectos magnéticos duros se presenta en la figura 3.13. La corrección de las lecturas se puede observar al graficar la componente *x* con respecto a la componente *y*, la componente *x* con respecto a la componente *z* y la componente *y* con respecto a la componente *z* de los lecturas de magnetómetro. Los datos calibrados, indicados en color azul, se encuentran cercanos al origen de las tres gráficas. Los resultados de la calibración de las efectos magnéticos duros, se presentan en la figura 3.14, en donde se puede observar que los datos calibrados forman tienen una forma esférica mejor definida que los datos no calibrados, además de estar más cercanos

3. METODOLOGÍA

al origen.

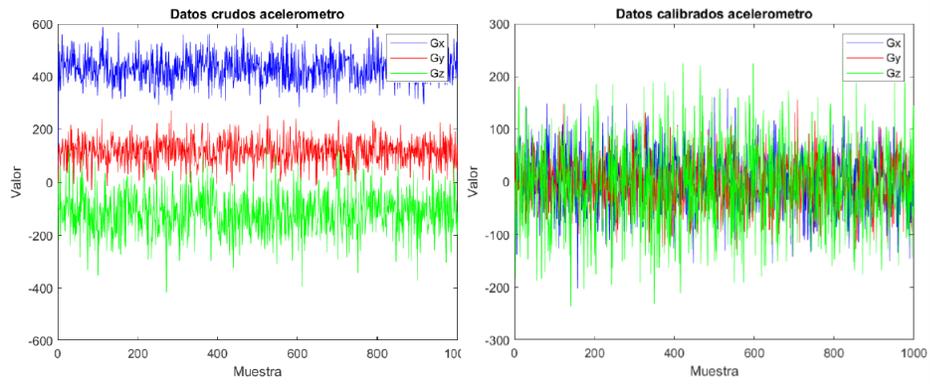


Figura 3.11: Calibración del acelerómetro

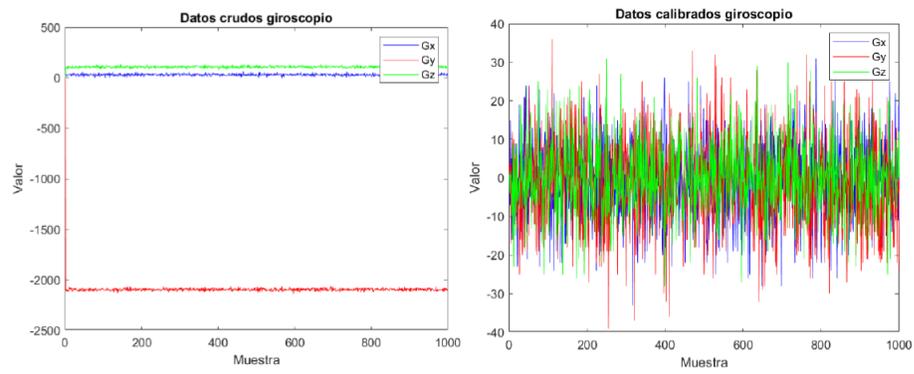


Figura 3.12: Calibración del giroscopio

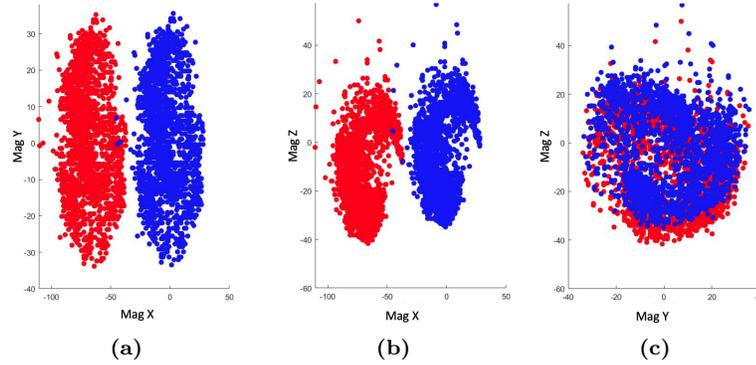


Figura 3.13: Calibración del magnetómetro

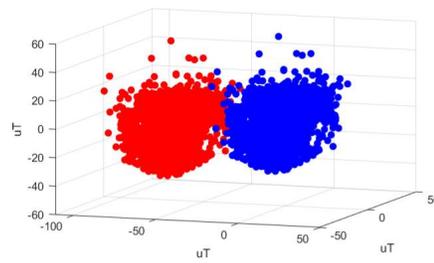


Figura 3.14: Calibración del magnetómetro vista 3D

Una vez calibradas las lecturas, los datos crudos fueron convertidos a las unidades correspondientes (m/s^2 , rad/s y μT).

3.1.3.2. Calibración de los sensores resistivos de fuerza

En el caso de los sensores resistivos de fuerza, las lecturas analógicas se convirtieron a volts mediante la ecuación 3.3, mientras que el valor de la resistencia del FSR se obtuvo mediante la ecuación 3.4. La figura 3.15 muestra las lecturas promedio de la resistencia y el voltaje obtenidas al medir diferentes pesos.

$$x = (lectura * 5)/1023 \quad (3.3)$$

$$\begin{aligned}
 v_{entrada} &= i(FSR + 10k\Omega) \\
 i &= 5V \frac{1}{(FSR + 10k\Omega)} \\
 v_{salida} &= i10k\Omega \\
 v_{salida} &= \left(5V \frac{1}{FSR + 10k\Omega}\right) 10k\Omega \\
 v_{salida} &= \left(5V \frac{10k\Omega}{FSR + 10k\Omega}\right) \\
 FSR &= 10k\Omega \frac{(5V - v_{salida})}{v_{salida}}
 \end{aligned} \tag{3.4}$$

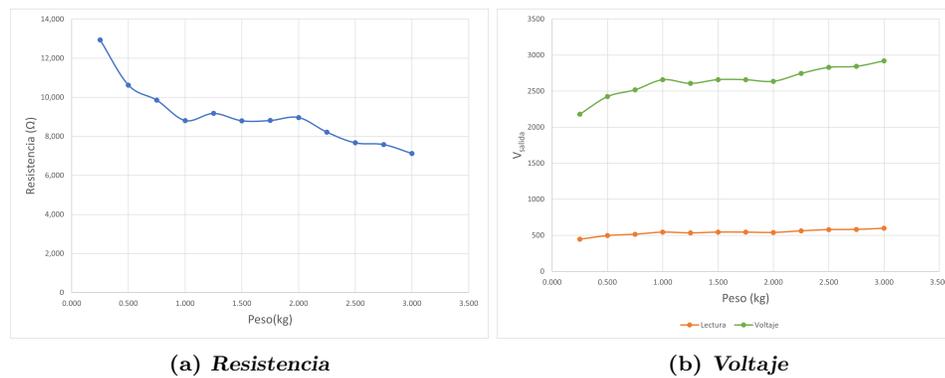


Figura 3.15: Lecturas obtenidas del FSR

Para convertir los valores de resistencia de salida de los FSR a unidades de medición de peso (kg), se emplearon barras de acero de 1 pulgada de diámetro y diferente peso (250, 500, 750 y 1000 gramos) (Figura 3.16) y se registró el valor de la resistencia del FSR cuando estos eran colocados en la zona de contacto del sensor. Se implementaron diferentes modelos de regresión para determinar la ecuación que mejor describe el comportamiento de los datos. Se seleccionó la ecuación de predicción del modelo de regresión exponencial, ya que es el que proporcionó mayor valores para el coeficiente de determinación (R^2).



Figura 3.16: Barras de acero utilizadas para la calibración de los FSR

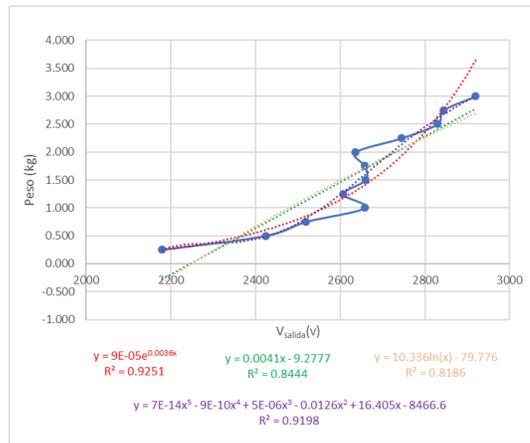


Figura 3.17: Modelos de regresión ajustados para la predicción del peso en función de las lecturas del FSR

Una vez obtenido el modelo de regresión ajustado para la predicción del peso (kg), se determinó una regla para la identificación del nivel de esfuerzo ejercido (Tabla 3.5).

Tabla 3.5: Niveles de esfuerzo

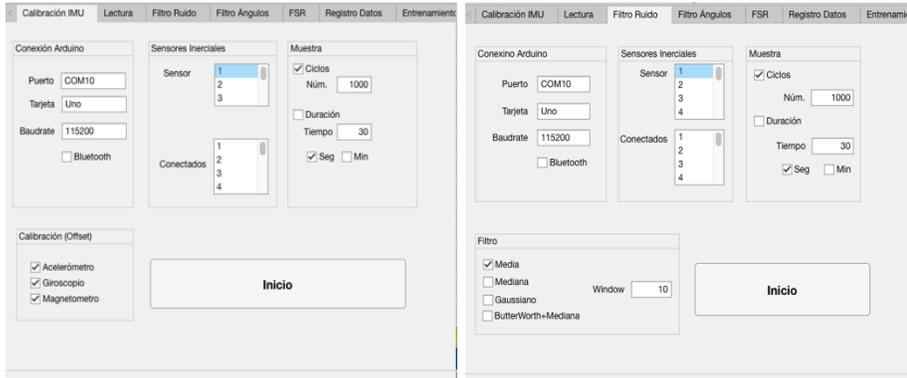
Nivel	Voltaje	Peso
I	Mínimo	0.00
	Máximo	1.00
II	Mínimo	1.00
	Máximo	2.00
III	Mínimo	2.00
	Máximo	3.00
IV	>	3.00

3.1.3.3. Interfaz para la lectura del sistema MoCap

Se desarrolló una aplicación mediante el asistente *app designer* en Matlab 2019a[©]. Se implementaron diferentes apartados para la calibración y lectura del guante de datos (Figura 3.18):

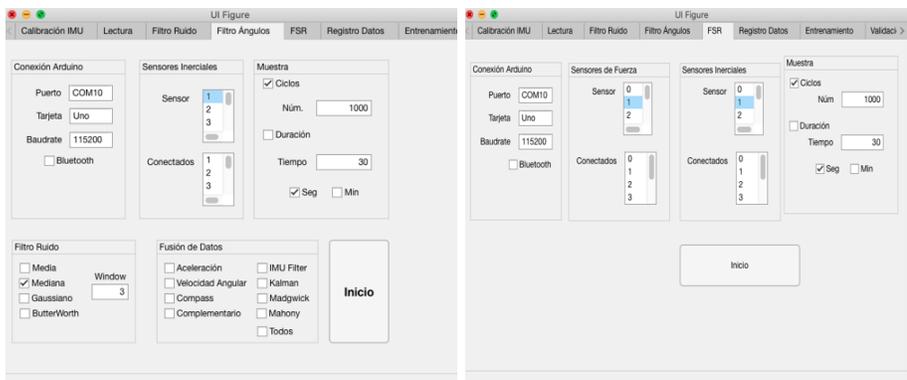
- Calibración IMU: este apartado permite obtener las lecturas para la calibración del acelerómetro, el giroscopio y el magnetómetro. Las lecturas del acelerómetro y el giroscopio pueden realizarse de forma simultánea, mientras que las lecturas para la calibración del magnetómetro deben registrarse de manera independiente. Los *offsets* se calcularon de forma automática para su posterior captura en el sistema.
- Lectura IMU: permite leer los sensores inerciales, de forma individual o grupal. En este apartado las lecturas son filtradas para disminuir el ruido de las señales adquiridas. Se implementaron filtros de la media, mediana y gaussiano, con la finalidad de disminuir el ruido de las señales.
- Filtros para la fusión de datos: esta sección permite realizar la fusión de datos para obtener la orientación de cada sensor (ángulos pitch, yaw y roll) mediante la fusión de las lecturas provenientes de los diferentes sensores: *integración directa de la aceleración*, *integración directa de la velocidad angular*, *compass*, *complementario*, *Kalman*, *Magdwick* y *Mahony*.
- Lectura de FSR: permite leer los datos provenientes de uno y/o todos los FSR.
- Registro de datos: en este apartado se obtiene la información proveniente del guante de datos, incluyendo el pre-procesamiento de las lecturas de los sensores inerciales (calibración, conversión a unidades convencionales, eliminación de ruido y fusión de datos) y FSR (conversión de las lecturas a resistencia, voltaje, peso y nivel de fuerza). También es posible agregar la etiqueta de la clase (para su uso en el entrenamiento de clasificadores).
- Entrenamiento de clasificadores: permite obtener los modelos entrenados para un conjunto de datos específico, haciendo uso de la optimización de parámetros de los modelos (*hiperparametrización*). Los clasificadores implementados son los siguientes:
 - K-vecinos más cercanos
 - SVM
 - Árboles de decisión
 - Análisis discriminante
 - Ensamblados
 - Algoritmo Naïve Bayes

3.1 Diseño e implementación del sistema MoCap: guante de datos



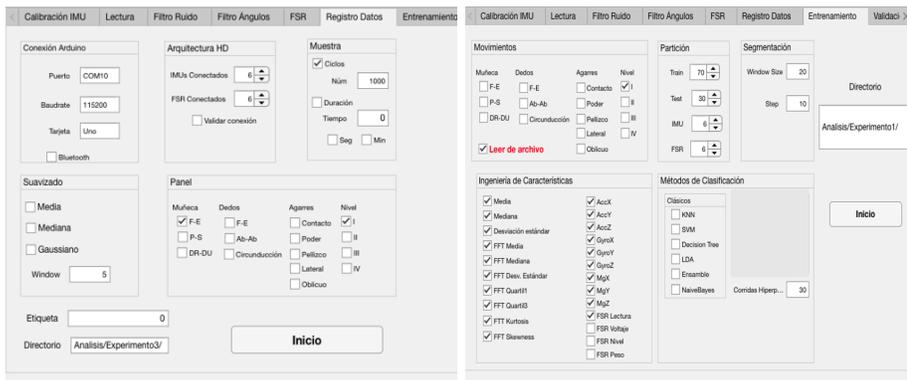
(a) Calibración IMU

(b) Lectura IMU



(c) Filtro fusión de datos

(d) Lectura FSR



(e) Registro de datos

(f) Entrenamiento de clasificadores

Figura 3.18: Aplicación desarrollada en Matlab 2019a[©]

3.2. Reconocimiento del tipo de agarre

El reconocimiento del tipo de agarre se abordó como un problema de clasificación, empleando la metodología propuesta por (105) descrita en la sección 2.5, misma que fue adaptada como se indica en la figura 3.19.

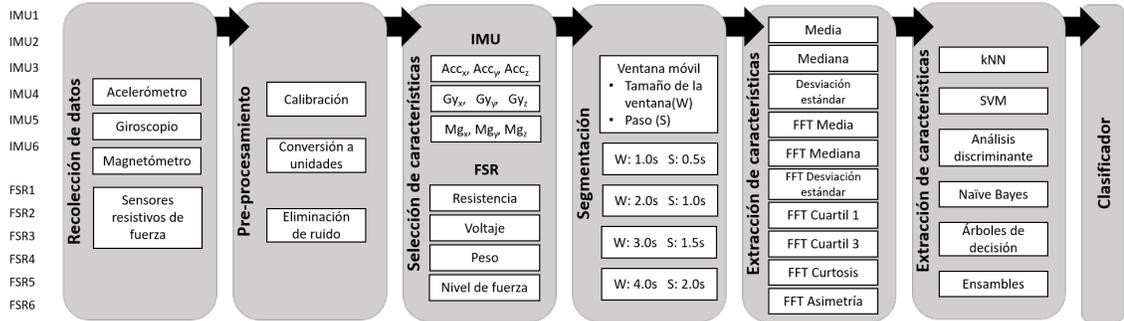


Figura 3.19: Metodología para el RAH utilizada en la investigación

■ **Adquisición de datos y pre-procesamiento.**

Se realizó la captura de los tipos de agarre mostrados en la tabla 3.20 basados en la taxonomía GRASP (104). Se capturaron 1000 lecturas para cada uno de los agarres considerados, mismos que fueron etiquetados de forma automática mediante la interfaz desarrollada en Matlab[®] 2019a. Los movimientos se ejecutaron en una mesa de trabajo con la altura recomendada para realizar trabajos de pie (Figura 3.21), en la que el usuario realizó alcances para tomar-dejar el objeto con la mano dominante, dentro de la zona de alcance máximo señalada en la Figura 3.22.



Figura 3.20: Tipos de agarre considerados en la investigación

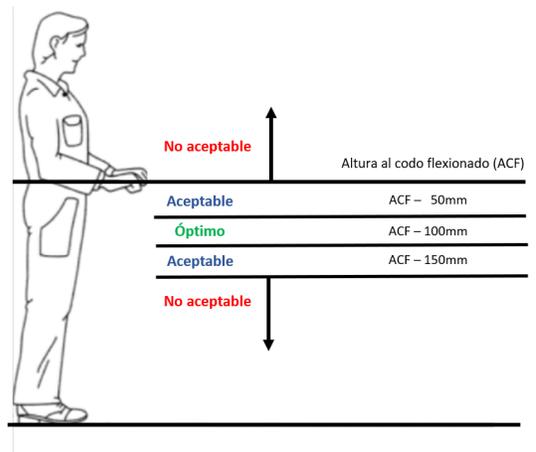


Figura 3.21: Altura recomendada del plano de trabajo

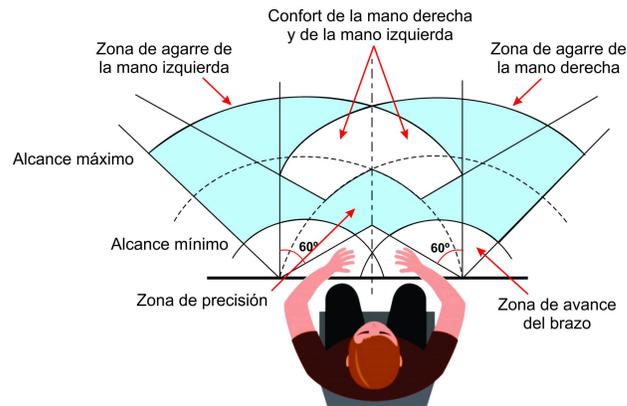


Figura 3.22: Alcances en el plano de trabajo

■ Selección de características

Debido a las diferencias encontradas en diversos estudios, relacionadas con la habilidad y contribución de las señales obtenidas mediante diferentes tipos de sensores (acelerómetros, giroscopios y magnetómetros) en el reconocimiento de actividades (107), el análisis fue efectuado con base en la combinación de la información obtenida mediante el guante de datos:

- Componentes de aceleración, además de la lectura de la resistencia de los FSR
- Componentes de aceleración y velocidad angular, además de la lectura de la resistencia de los FSR

- Componentes de aceleración, velocidad angular y campos magnéticos, además de la lectura de la resistencia de los FSR

■ Segmentación.

La segmentación empleada se basa en ventanas móviles de tamaño fijo con traslape, con la finalidad de mantener el poder discriminante de los datos que pertenecen al mismo segmento (ventana). Se analizaron diferentes combinaciones ventana-paso para determinar el mejor conjunto de variables para identificar el tipo de actividad. Se emplearon dos estrategias de traslape, en la primera de ellas dos ventanas consecutivas comparten aproximadamente el 50 % de los datos, mientras que en la segunda estrategia las ventanas comparten menos del 50 % de la información (3.6).

Tabla 3.6: Combinaciones tamaño de ventana-paso consideradas en el análisis

Código	Ventana (w)		Paso (s)		Traslape
	Hz	Seg	Hz	Seg	
W25S10	25	1.0	10	$\cong 0.5$	$\cong 50\%$
W50S25	50	2.0	25	1.0	50%
W75S350	75	3.0	35	$\cong 1.5$	$\cong 50\%$
W100S50	100	4.0	50	2.0	50%
W50S10	50	2.0	10	$\cong 0.5$	$\geq 50\%$
W75S10	75	2.0	10	$\cong 0.5$	$\geq 50\%$
W100S10	100	2.0	10	$\cong 0.5$	$\geq 50\%$

■ Extracción de características

Para abordar el problema de clasificación de series de tiempo, los datos fueron transformados al dominio del tiempo, mediante la transformada discreta de Fourier. Para lo anterior se empleó la función de transformación rápida de Fourier 2.5 disponible en Matlab[®]. Con base en el estudio de Baldominos et al. (2), se consideraron solo los coeficientes reales, ignorando la parte imaginaria de los valores transformados. Las siguientes características fueron extraídas para cada dimensión en cada una de las ventanas:

- Media del vector de datos crudos.
- Desviación estándar del vector de datos crudos.
- Mediana del vector transformado.
- Primer cuartil del vector transformado.
- Tercer cuartil del vector transformado.
- Asimetría del vector transformado.
- Curtosis del vector transformado.

■ Entrenamiento y clasificación

En esta etapa del reconocimiento del tipo de agarre, se utilizó la aplicación *Classification Learner* de Matlab[®], en la que se entrenaron modelos de clasificación de los siguientes tipos:

- k-Vecinos más cercanos (kNN)
- Máquina de Vectores de Soporte (SVM)
- Discriminante (Discr)
- Naïve Bayes (NB)
- Árboles de Decisión (DT)
- Ensamblados (Ens)

Los datos segmentados fueron divididos en conjunto de entrenamiento (70%) y conjunto de prueba (30%). El primer conjunto se empleó en el entrenamiento de cada modelo, mientras que el conjunto de prueba sirvió para medir el desempeño de los modelos de clasificación entrenados. En el conjunto de entrenamiento, las clases fueron balanceadas mediante la creación de datos sintéticos a partir de los parámetros de distribución normal del conjunto de datos original. Se utilizó la validación cruzada para $k=10$.

■ Selección del clasificador

En esta fase, se obtuvo la matriz de confusión para los modelos entrenados, utilizando para ello las predicciones realizadas en el conjunto de datos de prueba. Se seleccionó el modelo que presentó la mayor precisión en cada una de las opciones del conjunto características descritas en 3.2 para cada una de las combinaciones tamaño de ventana – paso. Finalmente, de los modelos seleccionados se determinó que el de mayor precisión es el más conveniente para el reconocimiento del tipo de agarre.

3.3. Identificación del somatotipo

Esta parte de la metodología implica la identificación de los grupos naturales de mediciones antropométricas de la mano. Para lo anterior fue necesario implementar técnicas de clusterización, para posteriormente clasificar a nuevos individuos con base en dichos grupos naturales. La metodología empleada se muestra en la Figura 3.23 y se describe en los siguientes apartados.

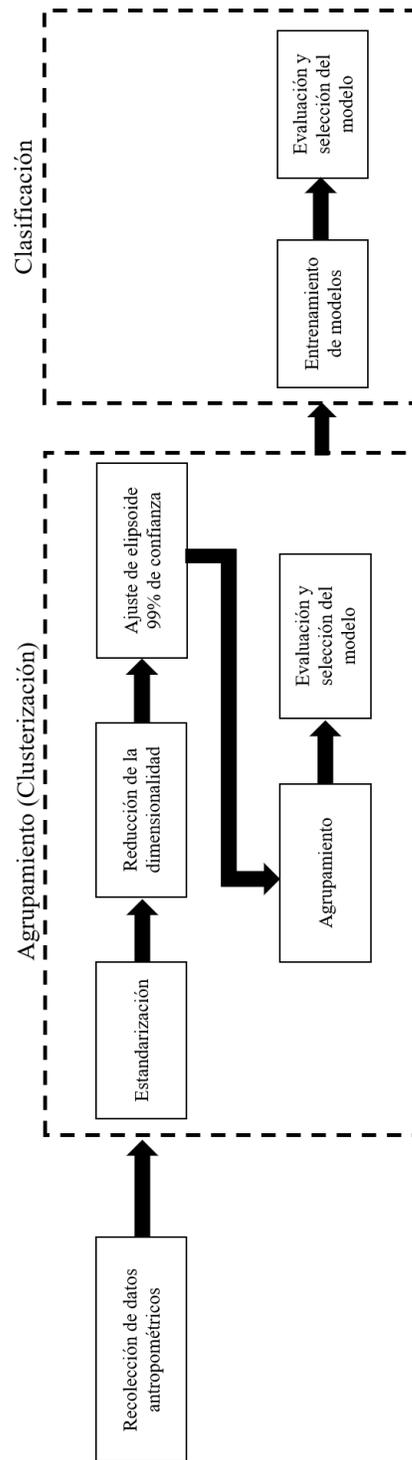


Figura 3.23: Metodología empleada para la identificación del somatotipo

3.3.1. Recolección de datos antropométricos

Se empleó una muestra de datos antropométricos de la mano conformada por 2,613 individuos del género masculino y 781 personas del género femenino. Los participantes eran trabajadores académicos y estudiantes de instituciones de educación superior y personal de la industria maquiladora, habitantes de la región noroeste de México al momento de la medición, cuyas edades oscilan entre 18 a 61 años.

Se consideraron cuatro dimensiones antropométricas de la mano dominante: Longitud de la mano (LM), Longitud de la palma (LP), Ancho de la palma (AP) y Diámetro de agarre de la mano (DAM) (Tabla 3.3.1 y Figura 3.3.1).

Tabla 3.7: Dimensiones antropométricas de la mano

Identificador	Dimensión antropométrica	Descripción	Unidad
LM	Longitud de la mano	Distancia vertical desde la base de la mano (primer pliegue de la muñeca) hasta la punta (pulpejo) del dedo medio	cm
LP	Longitud de la palma	Distancia vertical desde la base de la mano (primer pliegue de la muñeca) hasta la base del dedo medio	cm
AP	Ancho de la palma	Línea a través de los puntos finales de los huesos metacarpiano	cm
DAM	Diámetro de agarre	Diámetro interior que se puede asir con el dedo pulgar y el dedo medio, al nivel más ancho de un cono	mm

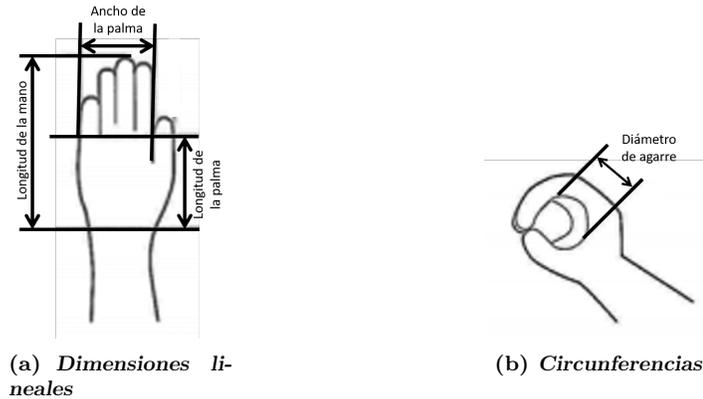


Figura 3.24: Dimensiones de la mano

Las dimensiones correspondientes a LM, LP y AP fueron recolectadas mediante un calibrador tipo vernier de 1 mm de precisión y los valores fueron registrados en centímetros. El DAM fue medido mediante un cono de empuñadura y los valores se registraron en milímetros.

3.3.2. Análisis multivariado de datos: Agrupamiento

La identificación de los grupos naturales en la muestra de datos antropométrico se realizó en función del género. El procedimiento llevado a cabo para la definición de los grupos de individuos se describe a continuación:

1. *Estandarización:* los datos fueron pre-procesados para evitar problemas de escala (valores grandes o pequeños derivados de las unidades de medición que dominan el proceso de agrupamiento). Se empleó la distribución normal mediante $x_{ij} = Z_{x_{ij}} = \frac{x_{ij} - \bar{x}_j}{s_j}$, donde i representa al i^{th} individuo, j representa las variables en el conjunto de datos y, \bar{x}_j y s_j son la media y la desviación estándar de las mediciones antropométricas, respectivamente.
2. *Reducción de la dimensionalidad:* el ACP se empleó para transformar el espacio dimensional del conjunto de datos estandarizados en dimensiones ortogonales, y reducir la dimensionalidad de los datos. En las tabla 3.8 y 3.9 se muestran los eigenvectores y eigenvalores de las dimensiones de la mano de poblaciones masculina y femenina, respectivamente. En el caso de la población masculina, es posible observar que el componente principal 1 (PC1), describe a la mano en general, mientras que el componente 2 contrasta la LM y el DA con la LP y el AP. Los componentes 3 y 4 contrastan las longitudes de la palma y de la mano con el ancho de la palma y el diámetro de agarre, y la longitud de la mano con el resto de las variables, respectivamente. Al igual que en la población masculina, el componente principal de la población femenina representa el modelo general de la mano, mientras que el resto de los componentes

contrastan el ancho de la palma de la mano con el resto de las variables (PC2), la longitud de la palma de la mano con el resto de las variables (PC3), y las longitudes de la mano y de la palma con el resto de las variables (PC4).

Tabla 3.8: Componentes principales, varianza y eigenvalores para la población masculina

Dimensión antropométrica	PC1	PC2	PC3	PC4
Longitud de la mano	0.58	-0.11	0.21	0.78
Longitud de la palma	0.53	0.04	0.63	-0.57
Ancho de la palma	0.41	0.78	-0.47	-0.07
Diámetro de agarre	0.45	-0.62	-0.59	-0.27
Varianza explicada	58.33	19.08	15.61	6.98
Varianza explicada acumulada	58.33	77.41	93.02	100
Eigenvalores	2.33	0.76	0.62	0.28

Tabla 3.9: Componentes principales, varianza y eigenvalores para la población femenina

Dimensión antropométrica	PC1	PC2	PC3	PC4
Longitud de la mano	0.58	-0.18	-0.26	0.75
Longitud de la palma	0.54	-0.08	-0.55	-0.63
Ancho de la palma	0.41	0.87	0.29	-0.01
Diámetro de agarre	0.45	-0.46	0.74	-0.20
Varianza explicada	59.85	18.30	16.14	5.71
Varianza explicada acumulada	59.85	78.15	94.29	100
Eigenvalores	2.39	0.73	0.65	0.23

3. *Ajuste de la elipsoide/esfera para el 98 %:* se seleccionó a los individuos cuyos puntos 3D se mantuvieran dentro de una elipsoide/esfera construida para un 98 % de confianza.
4. *Agrupamiento:* se implementaron las técnicas de agrupamiento basado en casos extremos (PCA y AA B) y en casos distribuidos (k-means y algoritmo jerárquico C.1.2).
5. *Evaluación y selección del modelo:* el agrupamiento fue realizado bajo un enfoque exploratorio, en el que se realizó el agrupamiento para $k = 1, \dots, 10$ grupos. Para la selección óptima de k – número de grupos– así de la mejor estrategia de agrupamiento, se emplearon las reglas de decisión indicadas en la tabla 3.10 para los índices silueta (SI), Calinski-Harabaz (CH) y Davies-Bouldin (DB).

Una vez identificado el valor óptimo del número de grupos naturales (k), se identificó al individuo representativo de cada grupo:

- Modelos basados en casos extremos:
 - ACP: individuo más cercano a cada uno de los 14 casos encontrados.

Tabla 3.10: Índices empleados para la selección del valor k

Índices ($n = 2, \dots, 15$)	Regla de decisión
$SI_k = \frac{1}{n} \sum_{i=1}^k \frac{(b_i - a_i)}{\max(a_i, b_i)}$	$SI = \max SI_k, k \in n$
$DB_k = \frac{1}{k} \sum_{i=1}^k \max_{\{j=1, \dots, k, i \neq j\}} \left\{ \frac{\text{diam}(c_i) + \text{diam}(c_j)}{d(z_i, z_j)} \right\}$	$DB = \min BD_k, k \in n$
$CH_k = \frac{BCSM}{k-1} * \frac{n-k}{WCSM}$	$CH_k = \max CH_k, k \in n$

- AA: individuo más cercano a los arquetipos seleccionados.
- Modelos basados en casos distribuidos: individuo más lejano al centroide de cada grupo.

6. Entrenamiento de los modelos de clasificación de los somatotipos:

La base de datos conformada por cuatro variables dependientes (dimensiones antropométricas) y una variable independiente (grupo) fue procesada mediante la aplicación *Classification Learner* de Matlab[®]. Se entrenaron modelos para los siguientes algoritmos de clasificación:

- kNN
- Máquinas de vectores de soporte
- Análisis discriminante
- Naïve Bayes
- Árboles de decisión
- Ensamblados

Finalmente, se obtuvieron las matrices de confusión para cada modelo entrenado y se seleccionó el modelo que arrojó la mayor precisión como el modelo óptimo.

3.4. Evaluación ergonómica

3.4.1. Métodos de evaluación ergonómica

Se emplearon dos métodos para determinar el nivel de riesgo ergonómico de las extremidades superiores: Job Strain Index y método de evaluación de la fatiga muscular de Rodgers.

3.4.1.1. Job Strain Index (JSI)

Es un método de evaluación de puestos de trabajo que busca identificar si los trabajadores están expuestos al desarrollo de WRMD debidos a movimientos repetitivos de la parte distal de las

extremidades superiores. El índice considera seis variables de la tarea correspondientes a criterios fisiológicos, biomecánicos y epidemiológicos. El puntaje JSI resulta del producto de los multiplicadores (tabla 3.12) correspondientes a los valores de cada una de las variables del método (table 3.11) (ecuación 3.5).

$$\begin{aligned} StrainIndex(SI) = & Multiplicador_{IE} * Multiplicador_{DE} * Multiplicador_{EPM} \\ & * Multiplicador_{PMM} * Multiplicador_{VT} * Multiplicador_{DA} \end{aligned} \quad (3.5)$$

Las variables analizadas por el método son las siguientes:

- *Intensidad del esfuerzo (IE)*: se define como el porcentaje máximo de fuerza requerida para realizar la actividad una vez. Es considerada la variable más crítica del método. En la tabla 3.12, es posible observar que el rango de los valores de la intensidad del esfuerzo es más grande que el del resto de las variables, por lo que su contribución en la ecuación para determinar el puntaje SI 3.5 es muy alta. Los multiplicadores del resto de las variables pueden considerarse como modificadores del multiplicador de la intensidad del esfuerzo.
- *Duración del esfuerzo (DE)*: se define como el porcentaje del tiempo que un esfuerzo es aplicado en un ciclo.
- *Esfuerzos por minuto (EPM)*: se refiere al número de esfuerzos que se realizan en un minuto y es sinónimo del término frecuencia.
- *Postura mano-muñeca (PMM)*: la postura se refiere a la posición anatómica de la muñeca o de la mano con respecto a la posición neutral. Esta variable refleja el efecto de la postura en el esfuerzo del agarre (reduciendo la fuerza de agarre) y, cuando se considera en conjunto con la intensidad del esfuerzo, refleja el estrés de compresión intrínseco a los músculos flexores y extensores de la muñeca.
- *Velocidad del trabajo (VT)*: esta variable estima el ritmo percibido de la tarea o trabajo.
- *Duración de la actividad por día (DA)*: se refiere al total del tiempo que la tarea es realizada en un día de trabajo, tratando de incorporar al método los efectos benéficos de la diversidad del trabajo, así como los efectos adversos de las actividades prolongadas.

Tabla 3.11: Valores de las seis variables consideradas en JSI

Valoración	IE	DE	EPM	PMM	VT	DA (hrs)
1	Ligero	< 10	< 4	Muy buena	Muy lenta	≤ 1
2	Poco difícil	10-29	4-8	Buena	Lenta	1-2
3	Difícil	20-49	9-14	Pobre	Pobre	2-4
4	Muy difícil	50-79	15-19	Malo	Malo	Rápida
5	Cercano al máximo	≥80	≥20	Muy malo	Muy rápido	≥8

Tabla 3.12: Tabla de multiplicadores

Valoración	IE	DE	EPM	PMM	VT	DA (hrs)
1	1	0.5	0.5	1.0	1.0	0.25
2	3	1.0	1.0	1.0	1.0	0.50
3	6	1.5	1.5	1.5	1.0	0.75
4	9	2.0	2.0	2.0	1.5	1.00
5	13	3.0	3.0	3.0	2.0	1.50

En la evaluación ergonómica mediante el método JSI, se consideraron las variables intensidad del esfuerzo y postura mano-muñeca, mismas que presentan un mayor impacto en la ecuación JSI (3.5).

3.4.1.2. Método Rodgers para la evaluación de la fatiga muscular

La evaluación de la fatiga muscular fue propuesta por Suzanne Rodgers ((8), (9)) con la finalidad de determinar la cantidad de fatiga acumulada en los músculos durante varios patrones de trabajo en un periodo de 5 minutos de trabajo. Este método es más apropiado para evaluar el riesgo de acumulación de fatiga en tareas que se desempeñan en una hora o más, en las que predominan posturas estresantes o esfuerzos frecuentes. Con base en el riesgo de fatiga es posible asignar a la tarea un puntaje de "prioridad de cambio" (de bajo a muy alto) (116).

El método considera tres factores de análisis para cada una de las regiones corporales indicadas en las tablas 3.14 y 3.13: *nivel de esfuerzo*, *duración del esfuerzo* y *frecuencia del esfuerzo*. Una vez seleccionado el nivel de esfuerzo que representa a la tarea, el tiempo de esfuerzo continuo así como los esfuerzos por minuto son asignados a cada región corporal.

Para cada uno de los factores del método, el valor máximo (4), implica que el factor por sí mismo es significativo. Si el nivel de esfuerzo es tal alto que la mayoría de los trabajadores no puede llevar a cabo la actividad, la duración del esfuerzo continuo es mayor de 30 segundos, o si la frecuencia es mayor de 15 repeticiones por minuto, existe razón suficiente para asignar un valor de 4 a la prioridad de cambio de la tarea.

Tabla 3.13: Criterios de evaluación la duración y frecuencia del esfuerzo en la metodología Suzanne Rodgers ((8),(9))

Factor	Bajo (1)	Moderado (2)	Alto (3)	Muy alto(4)
Duración del esfuerzo continuo	≤ 6 segundos	6-20 segundos	20-30 segundos	≥ 30 segundos
Frecuencia del esfuerzo	≤ 1/minuto	1-5/minuto	5-15/minuto	≥ 15/minuto

Tabla 3.14: Criterios de evaluación del nivel de esfuerzo en la metodología Suzanne Rodgers ((8),(9))

Región	Bajo (1)	Moderado (2)	Pesado (3)
Cuello	Cuello en posición neutra; Cabeza girada parcialmente a un lado, hacia atrás o ligeramente flexionada	Cabeza girada a un lado; cabeza hacia atrás completamente, cabeza flexionada 20°	Igual que moderado pero con fuerza o pesos; cabeza inclinada hacia adelante
Hombros	Brazos neutrales; brazos ligeramente alejados del cuerpo; brazos extendidos con algún soporte	Brazos despegados del cuerpo, sin soporte; trabajos por encima de la cabeza	Esfuerzos o pesos sostenidos con los brazos alejados del cuerpo o por encima de la cabeza
Espalda	De pie; sentado con soporte lumbar; inclinación lateral o flexión ligera; espalda arqueada	Espalda flexionada, sin carga; levantamientos de cargas moderadamente pesadas cercanas al cuerpo; trabajo por encima de la cabeza	Levantamientos o esfuerzos excesivos mientras se gira la espalda; fuerzas o cargas elevadas con la espalda flexionada
Brazos Codos	Neutrales; brazos alejados del cuerpo; sin carga; esfuerzos ligeros en levantamientos cercanos al cuerpo, sin giros	Brazos rotados mientras se realizan esfuerzos moderados	Fuerzas elevadas ejercidas con rotación; levantamientos con los brazos extendidos
Muñecas Manos Dedos	Esfuerzos o pesos ligeros manipulados cerca del cuerpo; muñecas rectas; agarres de poder confortables	Agarres amplos o pequeños; ángulos de las muñecas moderados, especialmente flexión; uso de guantes con fuerzas moderadas	Agarres de pelliczo; ángulos fuertes de muñecas; superficies resbaladizas
Piernas Rodillas	De pie; caminar sin flexionar o inclinar la espalda; peso en ambos pies	Inclinación hacia el frente, con apoyo en una mesa; pesos en un lado del cuerpo; esfuerzos con soporte	Esfuerzos excesivos mientras se empuja o levanta; agacharse mientras se realiza un esfuerzo
Tobillos Pies Dedos	De pie; caminar sin flexionar o inclinar la espalda; peso en ambos pies	Inclinación hacia el frente, con apoyo en una mesa; pesos en un lado del cuerpo; esfuerzos con soporte	Esfuerzos excesivos mientras se empuja o levanta; agacharse mientras se realiza un esfuerzo

3.4.2. Determinación del nivel de riesgo ergonómico

Con la finalidad de contrastar la hipótesis de investigación, se obtuvieron los niveles de riesgo ergonómico basados en las metodologías JSI y de evaluación de la fatiga muscular de Rodgers, para los diferentes tipos de agarre predichos por el sistema de evaluación ergonómica (tabla 3.20)). Estas evaluaciones son consideradas evaluaciones por expertos. Posteriormente, el sistema fue programado

3. METODOLOGÍA

para predecir el nivel de riesgo ergonómico de dos maneras diferentes:

- Evaluación automática
- Evaluación mediante modelos de clasificación somatotipo-agarre

3.4.2.1. Evaluación ergonómica por expertos

Se determinó el nivel de riesgo ergonómico para la parte distal de la extremidad superior, con base en los métodos JSI y de evaluación de la fatiga muscular de Rodgers empleados por expertos, para los diferentes tipos de agarres (tabla 3.15). En el caso del índice JSI, los valores que puede tomar la ecuación –considerando únicamente los multiplicadores correspondientes a las variables intensidad del esfuerzo y la postura mano-muñeca– van de 1 y 39. En el método de evaluación de la fatiga muscular de Rodgers, el nivel de esfuerzo puede tomar los valores 1, 2 o 3.

Tabla 3.15: Puntajes JSI y Rodgers para los diferentes tipos de agarre

Agarre	Puntaje JSI	Puntaje SR	Agarre	Puntaje JSI	Puntaje SR
 1: Diámetro grande	27	3	 2: Diámetro pequeño	9	1
 3: Medio	9	1	 9: Pellizo palmar	3	3
 10: Disco (poder)	9	3	 11: Esfera (poder)	18	1
 12: Disco (precisión)	18	3	 13: Esfera (precisión)	9	1
 14: Tripoide	9	1	 18: Extensión	3	3
 19: Distal	9	3	 20: Escritura	3	3
 26: Esfera 4-dedos	9	3	 27: Quadpod	3	1
 28: Esfera 3-dedos	2	2	 31: Anillo	18	2
 33: Pinza inferior	18	1			

3.4.3. Evaluación ergonómicas obtenidas mediante el sistema

- Evaluación automática:
 - Permite obtener el nivel de riesgo ergonómico mediante la comparación directa de las variables

obtenidas del guante de datos y los criterios específicos de las metodologías de evaluación ergonómica consideradas en la investigación (3.4.1.1 y 3.4.1.2).

- Predicción de la evaluación:

Se entrenaron clasificadores que permiten realizar la predicción del nivel de riesgo ergonómico con base en las variables somatotipo y tipo de agarre. Para llevar a cabo el entrenamiento, fue necesario balancear las clases mediante la generación de datos artificiales.

3.5. Análisis estadístico de los resultados

Se contrastó el porcentaje de evaluaciones ergonómicas que (13) consideran no corresponden a las evaluaciones de los expertos ($p = 13\%$) con el porcentaje de evaluaciones incorrectamente predichas por el sistema de evaluación ergonómica. La proporción de evaluaciones ergonómicas incorrectas obtenidas por el sistema (\hat{p}), corresponde al porcentaje de evaluaciones con índices menores a los determinados por los expertos. Las hipótesis planteadas son las siguientes:

- Evaluación automática.

$$H_{nula}: \hat{p}_1 = 0.13$$

$$H_{alternativa}: \hat{p}_1 > 0.13$$

- Evaluación mediante la predicción del agarre.

$$H_{nula}: \hat{p}_2 = 0.13$$

$$H_{alternativa}: \hat{p}_2 > 0.13$$

- Predicción de la evaluación.

$$H_{nula}: \hat{p}_3 = 0.13$$

$$H_{alternativa}: \hat{p}_3 > 0.13$$

Se empleó la prueba de hipótesis de cola superior para la comparación de proporciones independientes (117) –una aproximación normal de la distribución binomial– que compara el valor de una proporción en una muestra p_1 con una proporción esperada. El estadístico de contraste se calcula mediante la siguiente ecuación:

$$Z_{calculada} = \frac{\frac{X}{n} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} = \frac{\hat{P} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \quad (3.6)$$

3. METODOLOGÍA

donde X es el número de observaciones en una muestra aleatoria de tamaño n que pertenece a la clase asociada con la proporción p .

Resultados

En este capítulo se presentan los resultados obtenidos en cada una de las fases de la metodología de evaluación ergonómica propuesta: *reconocimiento del tipo de agarre*, en la que se entrenaron diferentes modelos de clasificación para series de tiempo, aplicados en diferentes combinaciones en la segmentación de los datos; *identificación del somatotipo*, en la que se implementaron métodos de agrupamiento basados en casos extremos y casos distribuidos con la finalidad de distinguir los grupos naturales en las características antropométricas de la mano; y por último, la *predicción de la evaluación ergonómica* (determinación del nivel de riesgo ergonómico que representa la actividad de manipulación de objetos) mediante el tipo de agarre y el somatotipo del usuario, identificados en los modelos de clasificación definidos en las fases anteriores.

4.1. Reconocimiento del tipo de agarre

Como se mencionó en la sección 3.2, el reconocimiento de los movimientos de la mano se realizó para diferentes modelos de selección de características y diferentes combinaciones de ventana-paso (3.2). Los resultados obtenidos se muestran en las siguientes secciones.

4.1.1. Selección de características: aceleración y FSR

Las tablas 4.1 y 4.2 muestran la exactitud y el F1-score de los mejores modelos de clasificación entrenados para la predicción del tipo de agarre en función de la aceleración y la resistencia de los FSR, para las opciones de segmentación con traslape del 50% y mayor al 50%. En ellas se puede observar que el modelo de clasificación que presenta una mayor exactitud y F1-score corresponde al obtenido mediante máquinas de vectores de soporte para la segmentación W75S10, seguido de la combinación ventana-paso W50S25. En las matrices de confusión presentadas en la figura 4.3, se muestran las frecuencias de las predicciones correctas (valores en la diagonal de la matriz en color azul) así como las predicciones que presentaron confusión consideradas como incorrectas (valores en

4. RESULTADOS

tonalidades café). De las matrices de confusión mencionadas se puede concluir que los agarres con mayor confusión corresponden a los agarres tipo 1, 2 y 18, mismos que son predichos como agarres tipo 12, 3 y 12, respectivamente.

Tabla 4.1: Exactitud de los modelos de clasificación entrenados para aceleración+FSR, traslape $\geq 50\%$

Ventana-Paso	Exactitud			F1-Score		
	Ens	SVM	NB	Ens	SVM	NB
W25 S10	0.7984	0.8564	0.3748	0.7967	0.8483	0.3990
W50 S10	0.8503	0.8718	0.4105	0.8481	0.8649	0.4369
W75 S10	0.7821	0.8748	0.4126	0.7805	0.8711	0.4504
W100 S10	0.7607	0.8644	0.4763	0.7472	0.8623	0.4196

Tabla 4.2: Exactitud de los modelos de clasificación entrenados para aceleración+FSR, 50 % traslape

Ventana-Paso	Exactitud			F1-Score		
	Ens	SVM	NB	Ens	SVM	NB
W25 S10	0.7984	0.8564	0.3748	0.7967	0.8483	0.3930
W50 S25	0.7109	0.8355	0.3010	0.7024	0.8299	0.3164
W75 S35	0.6385	0.8215	0.2846	0.6041	0.8187	0.3161
W100 S50	0.5399	0.7073	0.2175	0.4929	0.7226	0.2338

4.1 Reconocimiento del tipo de agarre

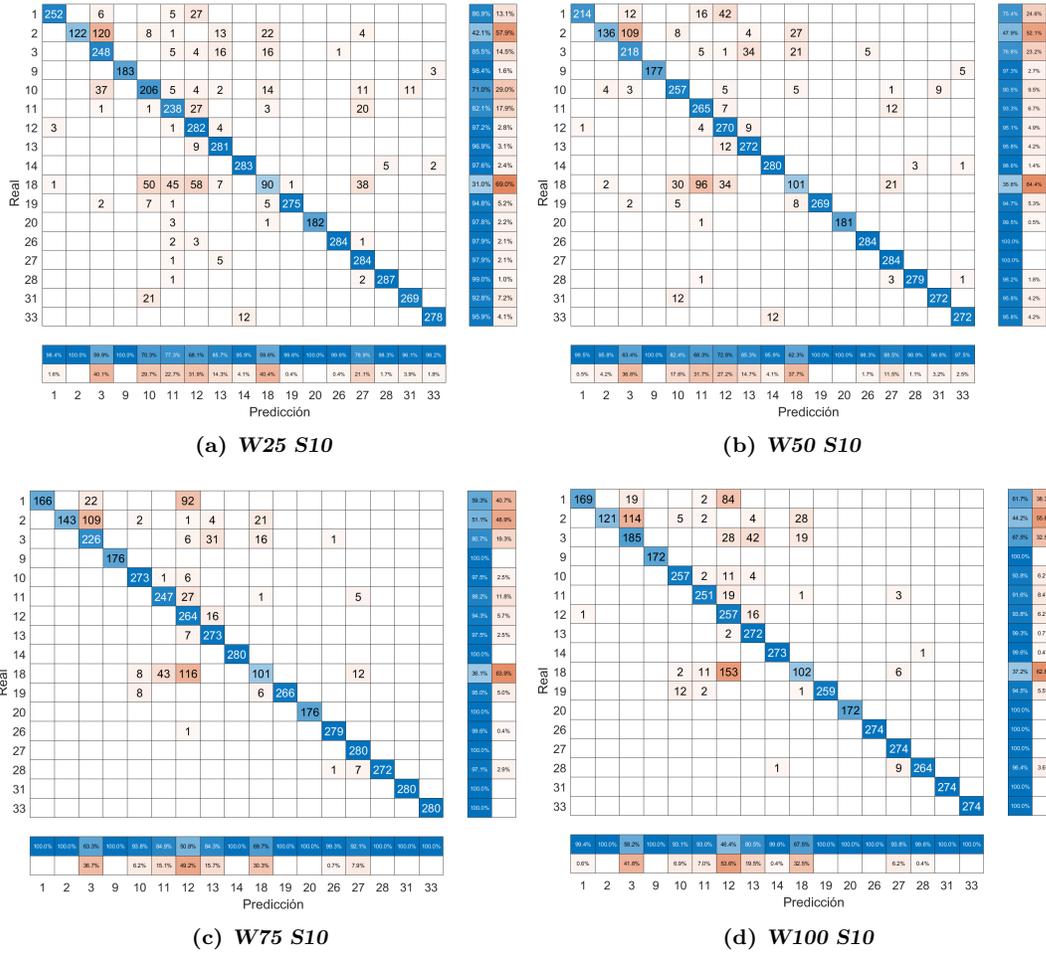


Figura 4.1: Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape $\geq 50\%$

4. RESULTADOS

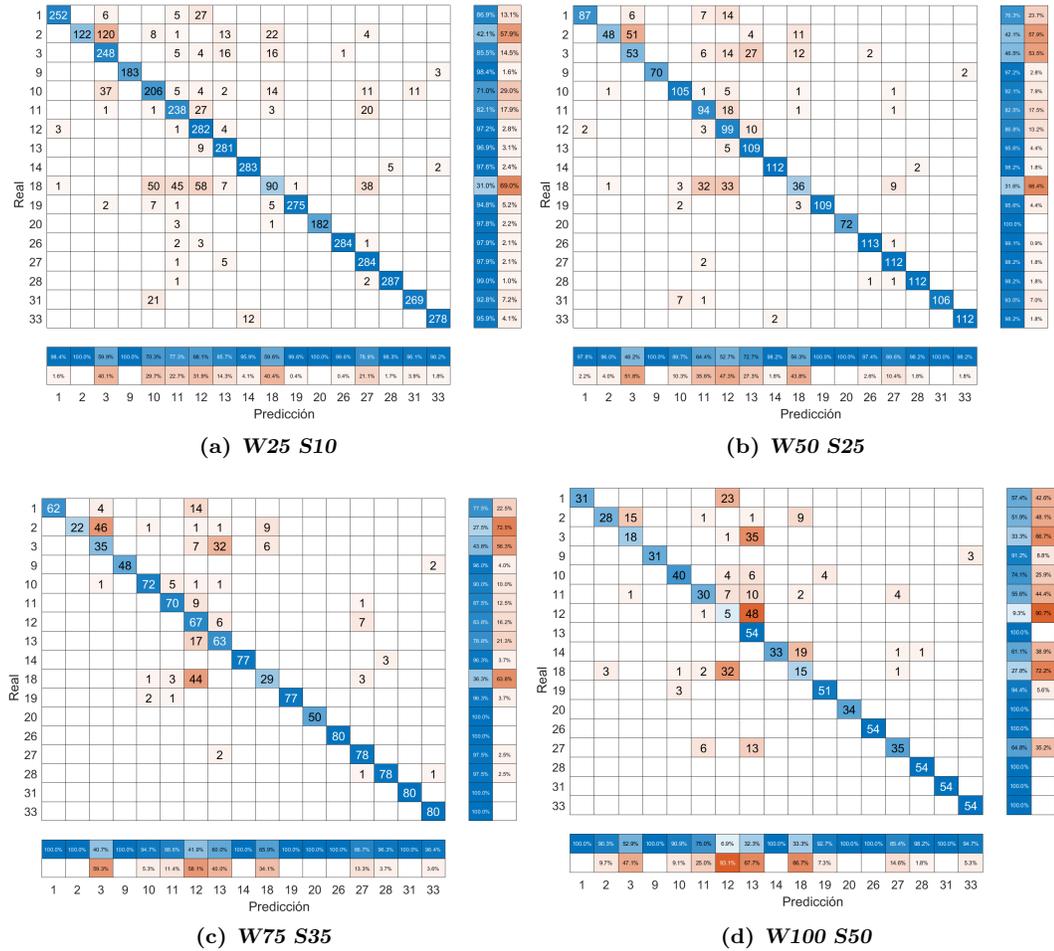


Figura 4.2: Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape 50%

4.1.2. Selección de características: aceleración, velocidad angular y FSR

La exactitud y los valores F1-score de los mejores modelos de clasificación entrenados para el reconocimiento del tipo de agarre a partir de las variables de aceleración, velocidad angular y las lecturas provenientes de los FSR se presenta en las tablas 4.3 y 4.4, para la segmentación con traslape mayor al 50 % y traslape igual al 50 %. El modelo de clasificación que optimiza la predicción del tipo de agarre corresponde a máquinas de vectores de soporte para la segmentación W75S10, seguida por las segmentaciones W50S10 y W100S10. En las matrices de confusión presentadas en las figuras 4.3 y 4.4, se observa que los tipos de agarre que presentaron un mayor error en la predicción

son los agarres 1,2 y 18.

Tabla 4.3: Exactitud de los modelos de clasificación entrenados para aceleración + velocidad angular + FSR, traslape $\geq 50\%$

Ventana-Paso	Exactitud			F1-Score		
	Ens	SVM	NB	Ens	SVM	NB
W25 S10	0.8405	0.8687	0.3911	0.8344	0.8620	0.4186
W50 S10	0.8090	0.8964	0.4258	0.7998	0.8921	0.4558
W75 S10	0.8570	0.9066	0.4246	0.8537	0.9047	0.4626
W100 S10	0.8491	0.9007	0.4039	0.8387	0.8940	0.4383

Tabla 4.4: Exactitud de los modelos de clasificación entrenados para aceleración + velocidad angular +FSR, 50% traslape

Ventana-Paso	Exactitud			F1-Score		
	Ens	SVM	NB	Ens	SVM	NB
W25 S10	0.8405	0.8687	0.3911	0.8344	0.8620	0.4186
W50 S25	0.8198	0.8700	0.3118	0.8044	0.8671	0.3291
W75 S35	0.8469	0.8669	0.2931	0.8357	0.8618	0.3244
W100 S50	0.7836	0.7973	0.2232	0.7686	0.7985	0.2423

4. RESULTADOS

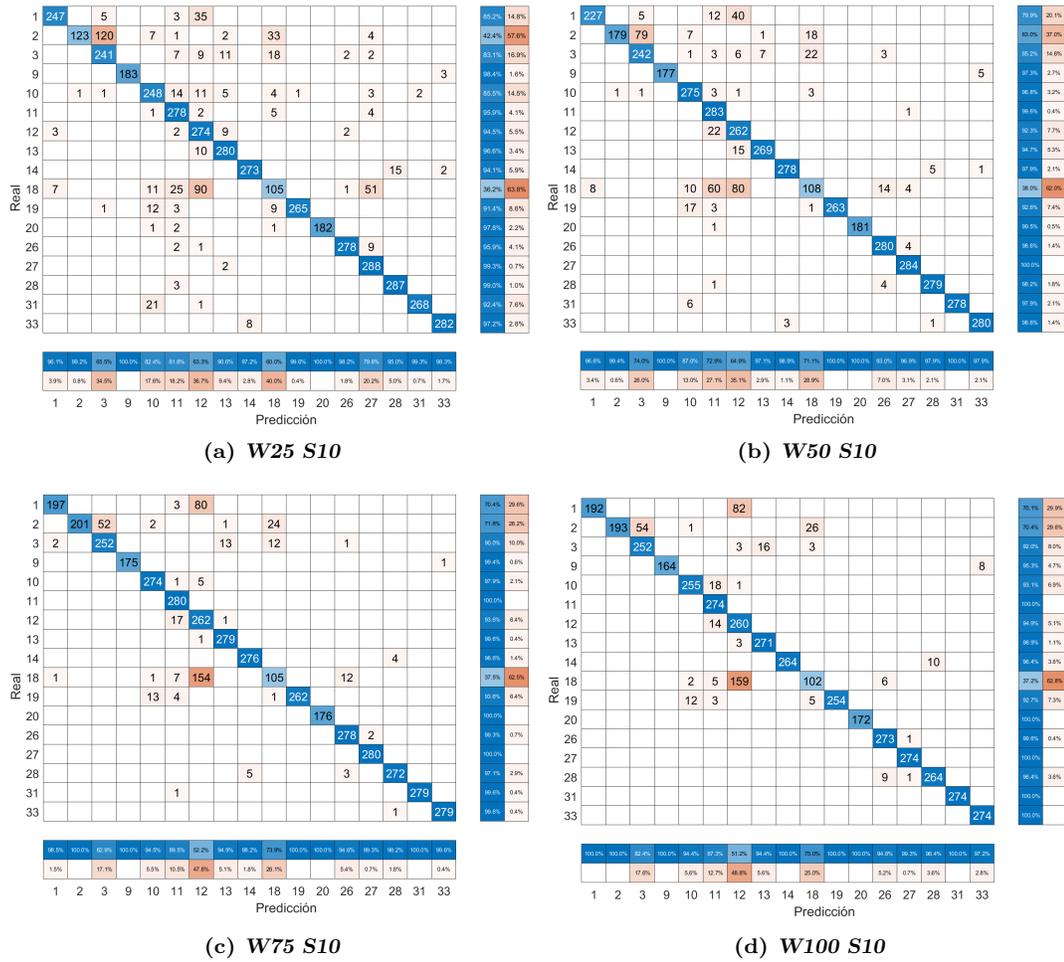


Figura 4.3: Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape $\geq 50\%$

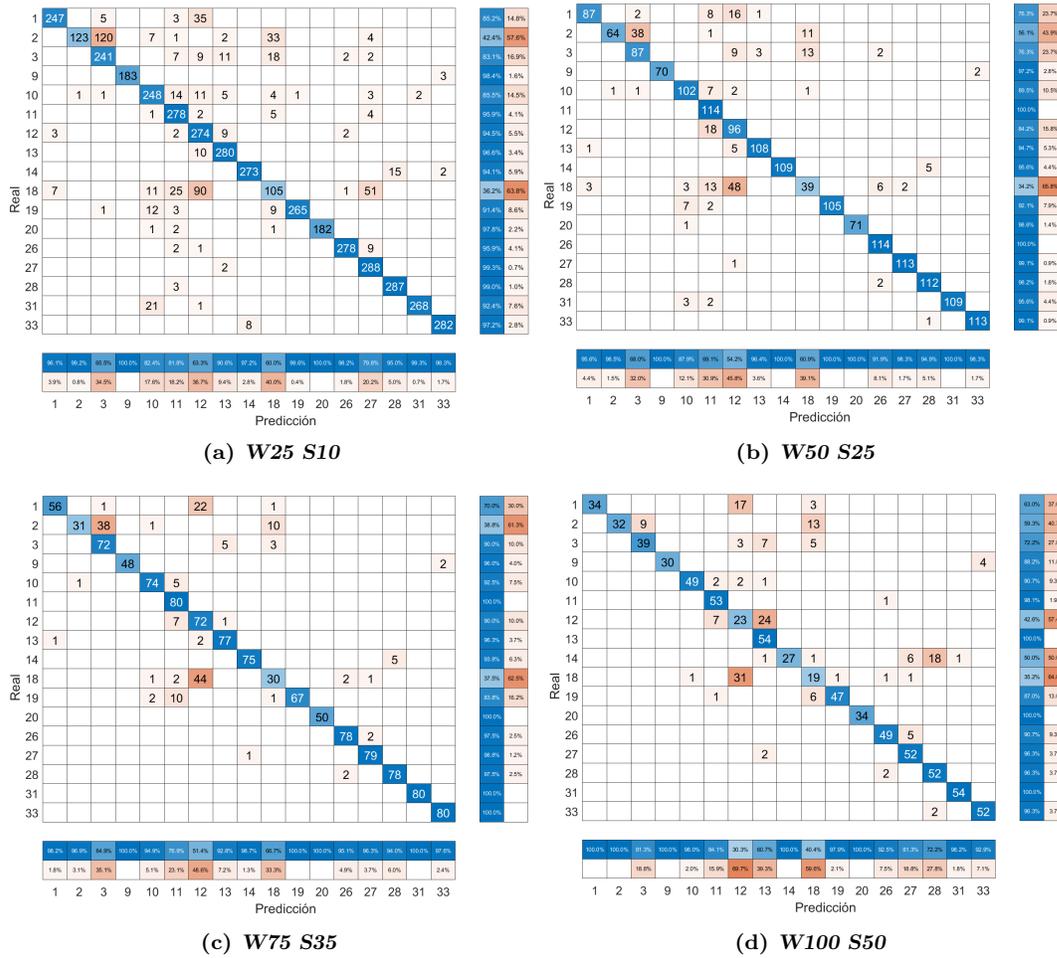


Figura 4.4: Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape 50 %

4.1.3. Selección de características: aceleración, velocidad angular, campos magnéticos y FSR

Las tablas 4.6 y 4.3 presentan los parámetros de desempeño de los mejores modelos de clasificación entrenados con las variables correspondientes a la aceleración, la velocidad angular y los campos magnéticos, provenientes de los sensores inerciales, además de las lecturas de la resistencia de los FSR. Los modelos obtenidos mediante máquinas de vectores de soporte obtuvieron valores más elevados de exactitud y F1-score, principalmente para la segmentación con traslape mayor al 50 %, principalmente para los tamaños de ventana $W=75$, $W=50$ y $W=100$. En las figuras 4.6 y

4.5 es posible observar que los tipos de agarre que presentan una mayor confusión son los tipo 2, 18 y 31.

Tabla 4.5: Exactitud de los modelos de clasificación entrenados para aceleración + velocidad angular + campos magnéticos + FSR, traslape $\geq 50\%$

Ventana-Paso	Exactitud			F1-Score		
	Ens	SVM	NB	Ens	SVM	NB
W25 S10	0.8463	0.8530	0.3676	0.8354	0.8484	0.3974
W50 S10	0.8609	0.8754	0.4273	0.8557	0.8719	0.4576
W75 S10	0.8366	0.8801	0.4200	0.8291	0.8769	0.4568
W100 S10	0.8406	0.8792	0.4091	0.8385	0.8767	0.4432

Tabla 4.6: Exactitud de los modelos de clasificación entrenados para aceleración + velocidad angular + campos magnéticos + FSR, 50 % traslape

Ventana-Paso	Exactitud			F1-Score		
	Ens	SVM	NB	Ens	SVM	NB
W25 S10	0.8463	0.8530	0.3676	0.8354	0.8484	0.3974
W50 S25	0.7983	0.8371	0.3080	0.7897	0.8331	0.3276
W75 S35	0.8131	0.8362	0.3008	0.8081	0.8319	0.3318
W100 S50	0.5900	0.7984	0.2323	0.5787	0.7937	0.2508

4. RESULTADOS

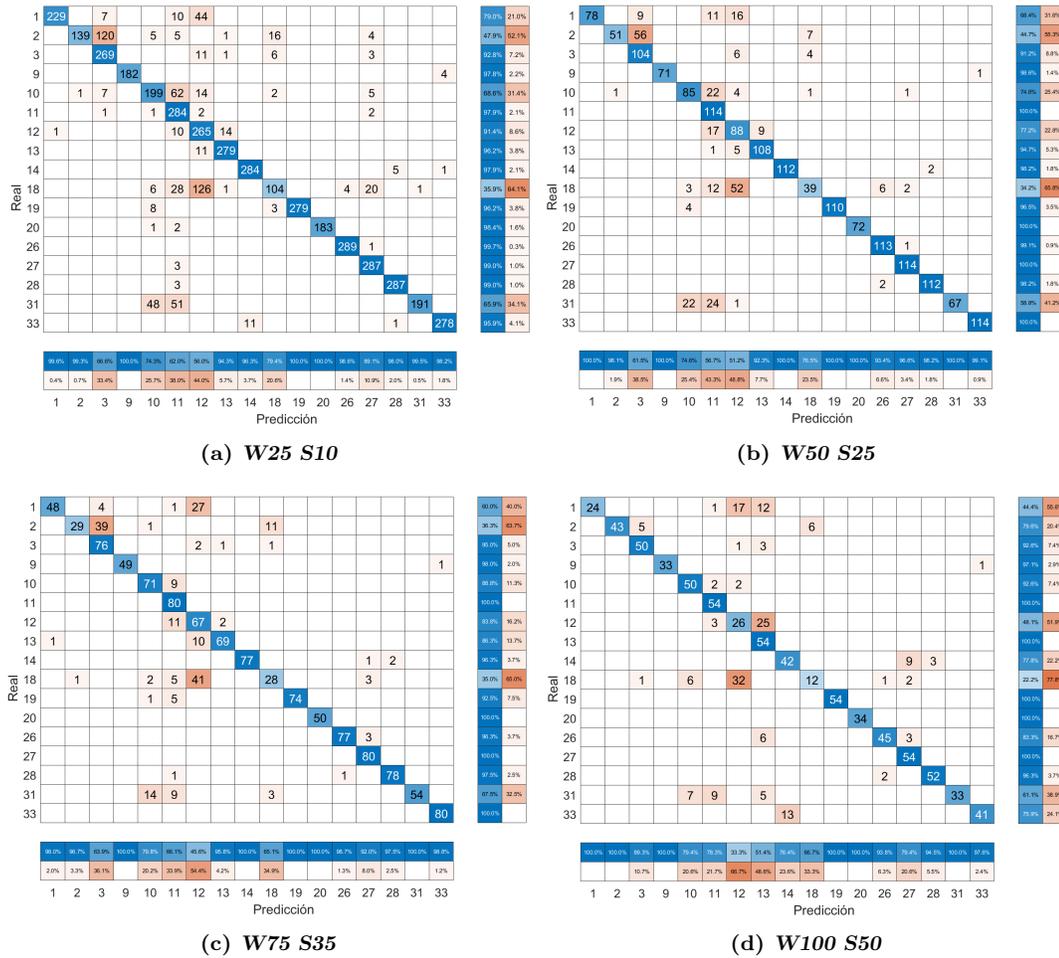


Figura 4.6: Matrices de confusión para los modelos SVM entrenados con mayor exactitud, traslape $\geq 50\%$

4.1.4. Selección del modelo de clasificación: Reconocimiento de agarre

En las tres opciones de selección de características (aceleración + FSR; aceleración + velocidad angular + FSR; y aceleración + velocidad angular + campos magnéticos + FSR), los modelos de clasificación entrenados para las diferentes combinaciones ventana-paso con traslape $\geq 50\%$ arrojaron valores mayores tanto para la exactitud global como para la métrica F1-score. Los modelos de clasificación entrenados que obtuvieron una mayor exactitud y F1-score se presentan en la tabla 4.7.

Tabla 4.7: Exactitud y valores F1 de los modelos de clasificación entrenados

Selección de características	Ventana-Paso	Clasificador	Exactitud	F1-Score
Aceleración + FSR	W75S10	SVM	0.8748	0.8711
Aceleración + Velocidad angular + FSR	W75S10	SVM	0.9066	0.9047
Aceleración + Velocidad angular + Campos magnéticos + FSR	W75S10	SVM	0.8801	0.8769

Es importante señalar que los modelos entrenados empleando la aceleración, así como los modelos entrenados con las lecturas provenientes de los tres sensores que conforman al IMU-9250, presentan valores similares de exactitud y F1-score, sin embargo, al considerar solamente la información proveniente del acelerómetro y del giroscopio (además de las lecturas de los FSR) se obtienen valores más elevados de exactitud y F1-Score. Para la fase de determinación del nivel de riesgo ergonómico el modelo de clasificación seleccionado presenta los siguientes parámetros:

- Segmentación:
 - Ventana: 75Hz
 - Paso: 10Hz
- Clasificador:
 - Máquinas de vectores de soporte (SVM)
 - Strategy: onevsone
 - Method: ECOC
 - Kernel Function: Polynomial
 - Kernel Scale: Auto
 - Kernel Polynomial Order: 2

4.2. Identificación del somatotipo

En los siguientes apartados se presentan los resultados de la identificación de grupos naturales para las dimensiones antropométricas de la mano de las poblaciones femenina y masculina. El agrupamiento se realizó mediante casos extremos (ACP y AA) y casos distribuidos (k-means y algoritmo jerárquico Ward).

4.2.1. Análisis multivariado: Casos extremos

4.2.1.1. ACP

En la tabla D.1, se presentan los valores de las dimensiones antropométricas para cada uno de los 14 casos obtenidos mediante APC. Es posible asumir que los casos 1 y 3 representan los

individuos extremos máximo y mínimo (para la mayoría de las variables antropométricas), tanto para la población masculina como para la población femenina.

4.2.1.2. Análisis de arquetipos

En la figura 4.7, se presenta el valor del RSS para el AA para $k = 1, \dots, 14$. De las gráficas se puede determinar que el número óptimo de grupos es $k = 3, 7$, y 8 para a población masculina y $k = 3, 5$, y 8 para la población femenina. Por otra parte, en las tablas D.2 y D.3 se muestran los valores de las dimensiones antropométricas para cada uno de los casos obtenidos mediante AA.

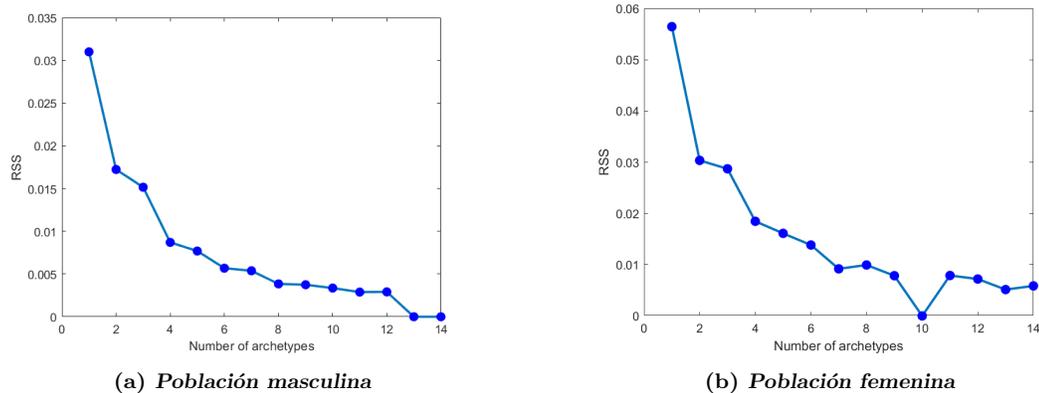


Figura 4.7: RSS del AA para diferentes valores de k

Los valores de k seleccionados para la población masculina son 3, 7 y 8, así como $k=12$, con la finalidad de asemejar la cantidad de casos a los encontrados mediante ACP.

En el caso de la población femenina se seleccionaron los valores 3, 5, 8 y 11.

4.2.2. Análisis multivariado: Casos distribuidos

En las figuras 4.8 4.9 se muestra el comportamiento de los índices silueta, Davies-Bouldin y Calinski-Harabaz para el agrupamiento mediante los algoritmos k-means y Ward para la población masculina y femenina, respectivamente. Del comportamiento mostrado por los índices se puede determinar que el número óptimo de grupos para el algoritmo k-means es $k = 2, 3, 4$ y 5 para ambas poblaciones, mientras que $k = 2, 3, 4$ y 6 y $k = 2, 3, 4$, y 5 son los valores recomendados para el análisis de la población masculina y femenina mediante el algoritmo Ward, respectivamente.

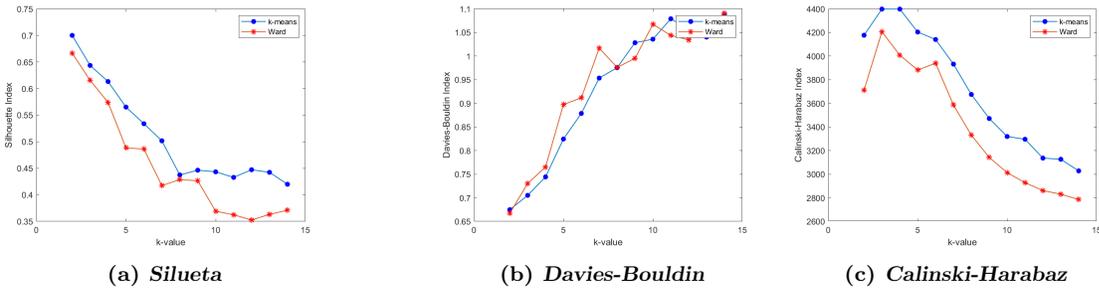


Figura 4.8: Índices para diferentes valores de k , población masculina

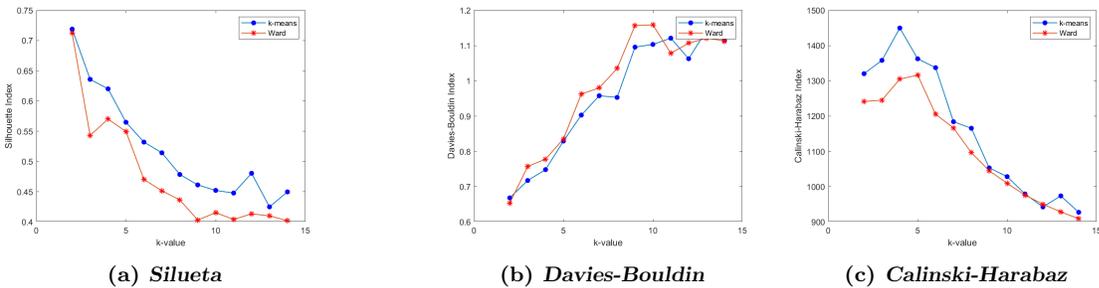


Figura 4.9: Índices para diferentes valores de k , población femenina

En las tablas D.4 y D.5 se presentan los valores de las dimensiones antropométricas para cada uno de los casos identificados para los diferentes valores de k considerados en el análisis mediante k-means.

En las tablas D.6 y D.7 se presentan los valores de las dimensiones antropométricas para cada uno de los casos identificados para los diferentes valores de k considerados en el análisis mediante el algoritmo jerárquico Ward.

4.2.3. Selección del agrupamiento

Se seleccionó el modelo que proporciona un mayor porcentaje de acomodo multivariado para cada una de las técnicas de agrupamiento implementadas. En el caso de la población masculina, se consideró $k = 12$ para el AA, mientras que el valor óptimo para el ACP, k-means y Ward es $k = 14$. Para la población femenina, el número de grupo óptimo para el análisis AA es 8 y 14 para el resto de las técnicas.

4. RESULTADOS

Tabla 4.8: Porcentaje de acomodo de los modelos para las poblaciones masculina y femenina

Análisis	k	Hombres		Mujeres	
			Porcentaje de acomodo		Porcentaje de acomodo
PCA	14		9036	14	76.70
	3		86.26	3	80.41
AA	7		84.88	5	73.24
	8		92.19	8	93.21
	12		97.32	11	91.93
k-means	2		79.30	2	4.23
	3		80.79	3	71.96
	4		83.01	4	79.39
	5		80.79	5	72.09
	14		96.21	14	97.06
Ward	2		79.30	2	4.23
	3		79.30	3	7.81
	4		80.79	4	76.70
	6		81.55	5	90.91
	14		92.58	14	96.67

4.2.4. Modelos de clasificación para el somatotipo

Se entrenaron diferentes modelos de clasificación en los agrupamientos seleccionados. Los valores de la exactitud se presentan en las tablas 4.9 y 4.10 para las poblaciones masculina y femenina, respectivamente.

Tabla 4.9: Exactitud de los modelos de clasificación para la población masculina

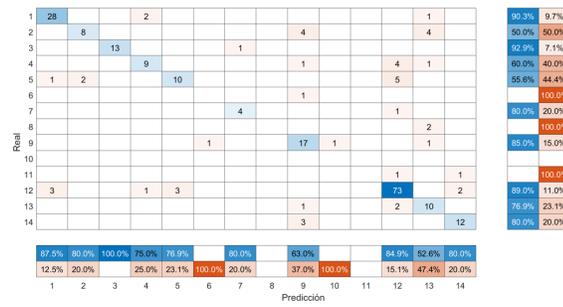
Modelo		KNN	SVM	Análisis Discriminante	NB	Ensamble
PCA	k=14	0.8633	0.9298	0.8403	0.8378	0.8621
AA	k=12	0.8748	0.9578	0.9093	0.9195	0.9361
k-means	k=14	0.8984	0.9518	0.9453	0.9231	0.8515
Ward	k=14	0.9349	0.9023	0.8411	0.7982	0.8632

Tabla 4.10: Exactitud de los modelos de clasificación para la población femenina

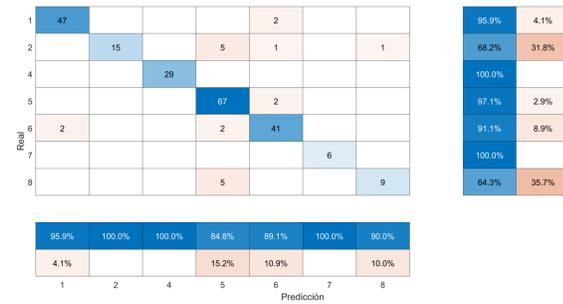
Modelo		KNN	Árboles de decisión	SVM	NB	Ensamble
PCA	k=14	0.7564	0.6111	0.7863	0.6966	0.7094
AA	k=8	0.7692	0.8333	0.9145	0.7521	0.8718
k-means	k=14	0.7554	0.6507	0.8297	0.825	0.7205
Ward	k=14	0.8209	0.5983	0.8035	0.7686	0.7161

Las matrices de confusión de los modelos que presentan la mayor exactitud se muestran en las figuras 4.10 y 4.11.

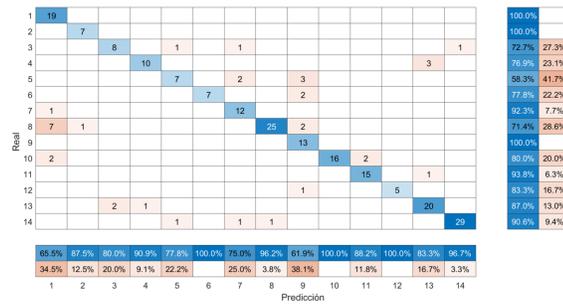
4. RESULTADOS



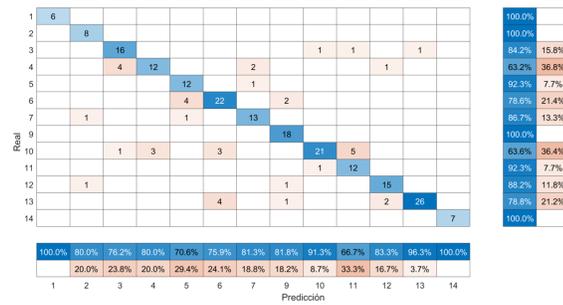
(a) PCA



(b) AA



(c) k-means



(d) Ward

Figura 4.11: Matrices de confusión para los modelos de clasificación de la población femenina

Los modelos seleccionados para la asignación del somatotipo del individuo en el algoritmo de evaluación ergonómica son los siguientes:

- Población masculina: modelo SVM para los grupos obtenidos mediante AA:
 - Preset: Cubic SVM
 - Kernel Function: Cubic
 - Kernel Scale: Automatic
 - Box constraint level: 1
 - Multiclass method: One-vs-One
 - Standardize data: true
- Población femenina: modelo SVM para los grupos obtenidos mediante AA:
 - Preset: Quadratic SVM
 - Kernel Function: Quadratic
 - Kernel Scale: Automatic
 - Box constraint level: 1
 - Multiclass method: One-vs-One
 - Standardize data: true

4.3. Modelo para la predicción del nivel de riesgo ergonómico

En la sección 3.4.2, se propuso el entrenamiento de modelos de predicción del nivel de riesgo ergonómico mediante el somatotipo del individuo y el tipo de agarre identificado. Debido a que la predicción del tipo de agarre, presentó una mayor exactitud para las segmentaciones con traslape $\geq 50\%$, se entrenaron modelos de clasificación para la predicción de la evaluación ergonómica para la misma combinación ventana-paso. La exactitud y el F1-Score de los modelos se muestran en las tablas 4.11 y 4.12.

Tabla 4.11: Exactitud y F1-Score para los modelos de predicción del nivel de riesgo ergonómico, método JSI

Clasificador	Exactitud	F1-Score
KNN	0.9607	0.9613
Ensamble	0.9626	0.9633
SVM	0.9601	0.9608
NB	0.7441	0.7306
DT	0.9627	0.9633

Tabla 4.12: Exactitud y F1-Score para los modelos de predicción del nivel de riesgo ergonómico, método Rodgers

Clasificador	Exactitud	F1-Score
KNN	0.6699	0.5654
Ensamble	0.9047	0.9030
Discriminante	0.6919	0.6815
SVM	0.8651	0.8634
NB	0.7331	0.7292
DT	0.9049	0.9036

Los modelos de clasificación entrenados considerados para la predicción del nivel de riesgo ergonómico basados en el somatotipo y el tipo de agarre son los siguientes:

- JSI: Ensamble, W75 S10
 - Method: bag
 - Number of learners: 371
- SR: Ensamble, W75 S10
 - Method: bag
 - Number of learners: 489

4.4. Análisis estadístico de la predicción del nivel de riesgo ergonómico

La evaluación ergonómica de las actividades analizadas, se realizó de dos maneras diferentes: evaluación automática y la predicción de la evaluación, con base en los valores obtenidos mediante clasificadores para el reconocimiento del tipo de agarre y del somatotipo del usuario.

4.4.1. Evaluación automática

Los resultados de contrastar las hipótesis de que la proporción de evaluaciones erróneas obtenidas de forma automática por el sistema propuesto es menor a la proporción definida en la literatura (0.13), se muestran en la tabla 4.13. Es posible observar que, en el caso de las evaluaciones mediante JSI, 4 de los 17 tipos de agarre analizados, presentaron menos del 13% de evaluaciones ergonómicas erróneas, mientras que en el caso del método para la evaluación de la fatiga muscular Rodgers, 50% de los agarres analizados presentaron menos del 13% de errores en la determinación del nivel de riesgo ergonómico. Con la finalidad de interpretar la magnitud de la diferencia

de las proporciones teórica (13%) y la obtenida en la presente investigación, se obtuvo la razón de probabilidades, en la que valores menores a 1 indican una asociación negativa de las variables, mientras que valores superiores a 1 representan una asociación positiva de las variables. Valores iguales a 1 corresponden a la ausencia de asociación. En el caso de las evaluaciones automáticas obtenidas de forma automática con base en la metodología JSI, la proporción de error los agarres tipo 18, 27 y 28 es aproximadamente 140 veces menor que la proporción teórica (13%), mientras que las evaluaciones obtenidas mediante la evaluación de fatiga muscular de Rodgers para los tipos de agarre 2, 3, 11, 13, 14 y 27 tiene valores de proporción de error similares.

Agarre	JSI				Evaluación de fatiga muscular Rodgers			
	\hat{p}	$Z_{calculada}$	Conclusión	Odds Ratio	\hat{p}	$Z_{calculada}$	Conclusión	Odds Ratio
1	1.000	79.82	La proporción es mayor	0.0002	1.000	79.82	La proporción es mayor	0.0002
2	0.006	-11.35	La proporción es menor o igual	141.4849	0.000	-11.93	La proporción es menor o igual	142.38
3	0.294	15.06	La proporción es mayor	0.3596	0.000	-11.93	La proporción es menor o igual	142.38
9	0.279	13.71	La proporción es mayor	0.3864	0.643	47.05	La proporción es mayor	0.0832
10	0.968	76.93	La proporción es mayor	0.0049	1.000	79.82	La proporción es mayor	0.0002
11	0.431	27.59	La proporción es mayor	0.1981	0.000	-11.93	La proporción es menor o igual	142.38
12	1.000	79.82	La proporción es mayor	0.0001	1.000	79.82	La proporción es mayor	0.0002
13	1.000	79.82	La proporción es mayor	0.0001	0.000	-11.93	La proporción es menor o igual	142.38
14	1.000	79.82	La proporción es mayor	0.0001	0.000	-11.93	La proporción es menor o igual	142.38
18	0.000	-11.93	La proporción es menor o igual	142.38	1.000	79.82	La proporción es mayor	0.0002
19	1.000	79.82	La proporción es mayor	0.0001	1.000	79.82	La proporción es mayor	0.0002
20	0.357	20.84	La proporción es mayor	0.2698	1.000	79.82	La proporción es mayor	0.0.0002
26	0.645	47.25	La proporción es mayor	0.0826	1.000	79.82	La proporción es mayor	0.0002
27	0.000	-11.93	La proporción es menor o igual	142.38	0.000	-11.93	La proporción es menor o igual	142.38
28	0.000	-11.93	La proporción es menor o igual	142.38	0.227	8.89	La proporción es mayor	0.5105
31	0.992	79.05	La proporción es mayor	0.0012	0.458	30.09	La proporción es mayor	0.1774
33	1.000	79.82	La proporción es mayor	0.0012	0.000	-11.93	La proporción es menor o igual	142.38

Tabla 4.13: Prueba de hipótesis para proporciones, evaluación automática W75 S10

4.4.2. Predicción de la evaluación

En la tabla 4.14 se muestran los resultados de contrastar la hipótesis de la proporción de errores en la evaluación ergonómica, menor o igual al 13%, en comparación con las evaluaciones proporcionadas por expertos. Es posible concluir que, en el caso de la metodología JSI, existe evidencia estadística para afirmar que 13 de los 17 tipos de agarre analizados, presentan errores en menos del 13% de los segmentos analizados. Los agarres que presentan proporciones de error mayores, corresponden a los agarres tipo 11, 12, 31 y 33. En el caso del análisis mediante la evaluación de fatiga muscular de Rodgers, 9 de los 17 agarres presentan un porcentaje de evaluaciones ergonómicas erróneas menor del 13%. Los agarres que presentaron porcentaje de error superior al 13% son los tipo 1, 9, 10, 12, 18, 20, 28 y 31. La razón de probabilidades obtenida para la predicción de las evaluaciones mediante JSI, indica que la proporción de error de los agarres tipo 2, 9, 10, 13, 14, 18 y 28 es 140 veces más pequeña que la proporción teórica, aproximadamente, mientras que las proporciones de error correspondientes a los agarres 1, 3, 19, 20, 26 y 27 tienen una asociación menor. En el caso de las proporciones de error que resultamos mayor a la proporción de error teórico, los cuatro tipos de agarre (11, 12, 31 y 33), tienen un acercamiento mayor a la proporción teórica en

comparación a la proporción de error obtenida para las evaluaciones automáticas de los mismos agarres.

En el caso de las predicciones de la evaluación de la fatiga muscular de Rodgers, la razón de probabilidades indica que los tipos de agarre 1, 2, 3, 11, 13, 14, 27, 33 mantuvieron la proporción de error obtenida por la evaluación automática, mientras que las evaluaciones de los tipos de agarre 9, 10, 12, 18, 19, 20 y 26 tuvieron proporciones de error más cercanas al error teórico del 13 %, a pesar de superarlo, es decir, valores de la razón de probabilidades más cercas a cero, indican una mayor diferencia o asociación negativa. En el caso de los agarres tipo 9 y 6, la cercanía a 1 de la razón de probabilidades indica que las proporciones adoptan valores similares.

Agarre	JSI			Evaluación de fatiga muscular Rodgers				
	\hat{p}	$Z_{calculada}$	Conclusion	Odds Ratio	\hat{p}	$Z_{calculada}$	Conclusion	Odds Ratio
1	0.189	-10.19	La proporción es menor o igual	7.76	0.008	-11.16	La proporción es mayor	17.66
2	0.000	-11.93	La proporción es menor o igual	142.38	0.000	-11.93	La proporción es menor o igual	142.38
3	0.002	-11.73	La proporción es menor o igual	71.01	0.000	-11.93	La proporción es menor o igual	142.38
9	0.000	-11.93	La proporción es menor o igual	142.38	0.139	0.79	La proporción es mayor	0.93
10	0.000	-11.93	La proporción es menor o igual	142.38	0.275	13.32	La proporción es mayor	0.39
11	0.258	11.78	La proporción es mayor	0.43	0.000	-11.93	La proporción es menor o igual	142.38
12	0.176	4.26	La proporción es mayor	0.69	0.168	3.49	La proporción es mayor	0.74
13	0.000	-11.93	La proporción es menor o igual	142.38	0.000	-11.93	La proporción es menor o igual	142.38
14	0.000	-11.93	La proporción es menor o igual	142.38	0.000	-11.93	La proporción es menor o igual	142.38
18	0.000	-11.93	La proporción es menor o igual	142.38	0.298	15.44	La proporción es mayor	0.35
19	0.004	-11.54	La proporción es menor o igual	35.46	0.103	-2.48	La proporción es menor o igual	1.30
20	0.002	-11.73	La proporción es menor o igual	71.01	0.242	10.24	La proporción es mayor	0.47
26	0.008	-11.16	La proporción es menor o igual	17.66	0.126	-0.36	La proporción es menor o igual	1.03
27	0.002	-11.73	La proporción es menor o igual	71.01	0.000	-11.93	La proporción es menor o igual	142.38
28	0.000	-11.93	La proporción es menor o igual	142.38	0.983	78.28	La proporción es mayor	0.00
31	0.420	26.62	La proporción es mayor	0.20	0.733	55.34	La proporción es mayor	0.05
33	0.722	54.38	La proporción es mayor	0.05	0.000	-11.93	La proporción es menor o igual	142.38

Tabla 4.14: Prueba de hipótesis para proporciones, predicción de la evaluación W75 S10

4.5. Discusión

4.5.1. Reconocimiento del tipo de agarre

Como se describió en la sección 3.1, el guante de datos empleado para la MoCap de la extremidad superior cuenta con sensores inerciales de 9 GDL, conformados por un acelerómetro, un giroscopio y un magnetómetro, además de sensores resistivos que permiten identificar la presión ejercida en ellos. El principal objetivo del reconocimiento del tipo de agarre, es identificar el conjunto de variables que permiten obtener una mejor estimación del tipo de agarre, por lo que se implementaron métodos de clasificación clásicos para la información proveniente del acelerómetro, giroscopio y magnetómetro integrados en cada uno de los sensores inerciales, además de la resistencia obtenida a través de las lecturas de los sensores resistivos.

Las métricas de desempeño de los modelos de clasificación indican que la información proveniente de magnetómetros no es significativa en el reconocimiento de los movimientos de la mano, principalmente de diferentes tipos de agarre considerados en la taxonomía GRASP. Es importante

señalar, que esta conclusión debe ser interpretada de forma cautelosa debido a que las condiciones magnéticas del entorno de laboratorio en el que se llevó a cabo la experimentación en la presente investigación, pueden ser diferentes a las presentes en entornos de trabajo reales.

Los algoritmos de clasificación presentaron una exactitud y F1-score que pueden considerarse adecuados para el reconocimiento de actividades humanas. Los modelos de clasificación entrenados mediante SVM fueron los que observaron un mejor desempeño, tal como se muestra en la literatura relacionada con el RAH ((115), (74)).

En el caso de la segmentación, mejores resultados fueron obtenidos mediante ventanas con traslape, tal como se señala en la literatura para el RAH((115), (74)).

Dentro de los factores que pueden impactar el rendimiento de los modelos de clasificación de datos de series de tiempo para el RAH, podemos encontrar los siguientes:

- Selección de sensores: Debido a la pequeña área de la que se dispone para colocar los sensores en el guante de datos, es necesario contar con tecnologías que requieran un espacio menor al de las diferentes opciones comerciales de sensores inerciales. En esta investigación, se seleccionaron sensores de la marca Sparkfun, debido a que su tamaño es casi 50% menor al de la mayoría de los sensores inerciales disponibles en el mercado. Sin embargo, es posible implementar tecnologías de menor tamaño a un mayor costo.
- Colocación de los sensores en el guante de datos: Para evitar, o en su defecto disminuir, el desplazamiento de los sensores inerciales y resistivos durante su uso, estos fueron sujetos a los dedos y yemas de los dedos, respectivamente, sin embargo, es posible identificar e implementar estrategias alternativas a la propuesta.
- Usuarios muestreados: Es importante que en la recolección de datos participen individuos que representen adecuadamente a la población de interés, tanto del género masculino como femenino, así como de las diferentes morfologías y rangos de edad.

4.5.2. Identificación del somatotipo

Debido a que se desconocen los patrones naturales de la población mexicana, fue necesario realizar el agrupamiento de los datos, considerando para ello métodos para grupos extremos y métodos para grupos distribuidos, para posteriormente entrenar diferentes modelos de clasificación sobre los grupos asignados a cada individuo que conforma la base de datos antropométricos.

Los modelos de clasificación que presentaron un mejor desempeño en la identificación del somatotipo, se obtuvieron para los agrupamientos provenientes del análisis de arquetipos, una técnica poco explorada e implementada en el análisis de datos antropométricos.

4.5.3. Evaluación ergonómica

En el caso de JSI: Los tipos de agarre que presentaron un error cercano al 100 % en la predicción de la evaluación ergonómica son mayores en las evaluaciones automáticas que en la predicción del sistema, principalmente las evaluaciones correspondientes a los agarres esféricos. La predicción de la evaluación ergonómica, presenta errores principalmente en los tipos de agarre de anillo y pinza inferiores, los cuales presentan ciertas similitudes en la geometría del movimiento. En el caso de SR: Los tipos de agarre que presentaron un error cercano al 100 % en la predicción de la evaluación ergonómica son mayores en las evaluaciones automáticas que en la predicción del sistema, principalmente las evaluaciones correspondientes tanto a agarres de poder como de precisión. La predicción de la evaluación ergonómica, presenta errores principalmente en los tipos de agarre de anillo y esfera 3-dedos.

Conclusiones

5.1. Observaciones finales

En la presente tesis, se diseñó e implementó un sistema de evaluación ergonómica para la extremidad superior distal, que permite determinar el nivel de riesgo ergonómico que representa la realización de tareas de manipulación de objetos en el plano de trabajo. Los resultados obtenidos permitieron llegar a las siguientes conclusiones en cada uno de los objetivos de investigación establecidos:

- *Objetivo general:* Diseñar e implementar un sistema de evaluación ergonómica en línea, que permita determinar el nivel de riesgo ergonómico mediante técnicas de clasificación.

Se comprobó que para la mayoría de los tipos de agarres analizadas de la taxonomía GRASP, la predicción del nivel de riesgo mediante el uso de técnicas de clasificación, permitió disminuir el porcentaje de evaluaciones ergonómicas erróneas empleando las metodologías Job Strain Index y la evaluación de fatiga muscular de Rodgers.

- *Objetivos específicos:*

- Diseñar e implementar un sistema de captura de movimiento (MoCap) a través de cual se obtengan las variables que describan a la tarea.

Se determinó que 6 sensores inerciales, colocados en la parte proximal de los dedos y en la palma de la mano, así como 6 sensores resistivos de fuerza, permiten identificar los 17 tipos de agarre analizados pertenecientes a la taxonomía GRASP. La frecuencia de muestreo obtenida del sistema al utilizar un diseño esclavo-maestro y empleando multiplexores es de 25Hz adecuado para el análisis de los movimientos de cuerpo.

- Implementar algoritmos para la clasificación de las características antropométricas y de la tarea.

- Identificación de las características antropométricas(somatotipo)

Se analizaron diferentes técnicas de agrupamiento, que permitieron entrenar modelos de clasificación para la predicción del somatotipo al que más se acerca el individuo bajo análisis. Se encontró que las máquinas de vectores de soporte (SVM), presentan una mayor exactitud en la predicción de las características antropométricas de la mano, previamente agrupadas mediante el análisis de arquetipos (AA).

- Identificación del tipo de agarre

Se encontró que el conjunto de predictores conformados por las variables correspondientes a aceleración, velocidad angular y resistencia de los sensores resistivos de flexión, permiten obtener una mayor precisión en la identificación del tipo de agarre, mediante máquinas de vectores de soporte (SVM). La segmentación empleada es de ventana de tamaño 5 y un paso de 10 observaciones.

- Implementar algoritmos de clasificación para la determinación del nivel de riesgo por carga postural.

El análisis estadístico realizado, permite concluir que existe suficiente evidencia estadística para asumir que la predicción del nivel de riesgo ergonómico –para las variables intensidad del esfuerzo y postura mano-muñeca– de 13 de los 17 tipos de agarre presentan un menor error de predicción al emplear modelos de clasificación entrenados mediante SVM. En el caso de la metodología para la evaluación de la fatiga de Rodgers –variable intensidad del esfuerzo para manos y dedos– se encontró que 9 de los 17 tipos de agarre tuvieron un menor error en la estimación del nivel de riesgo ergonómico, en comparación de la proporción determinada en la literatura.

5.2. Principales hallazgos y contribuciones

Existen diferentes perspectivas sobre la contribución de la presente investigación. La primera de ellas es la generación de los casos y modelos de las dimensiones antropométricas de la mano, mismos que hasta el momento eran desconocidos para la población del noroeste de México. Esta información puede ser de gran utilidad para el diseño de puestos de trabajo y herramientas de mano, así como en el diseño de productos.

Una segunda contribución es la determinación del conjunto de variables que pueden ser empleadas en el reconocimiento de los tipos de agarre considerados en la taxonomía GRASP (aceleración, velocidad angular y resistencia relacionada al esfuerzo de los dedos y mano), así como la segmentación de la serie de tiempo obtenida a partir del sistema de captura de movimiento que permitió el mejor desempeño de los modelos de clasificación.

Por último, se comprobó que el error en la determinación de los niveles de riesgo ergonómico

para la extremidad superior distal, disminuye al emplear modelos de predicción basados en las características antropométricas de la mano y la predicción del tipo de agarre.

5.3. Recomendaciones y trabajo futuro

Es importante mencionar que el trabajo realizado en la presente investigación, puede ser mejorado mediante las siguientes acciones:

- Incrementar el tamaño de muestra para la predicción del nivel de riesgo ergonómico.
- Analizar el impacto de la colocación de los sensores inerciales en diferentes puntos de la mano, en la identificación del tipo de agarre y en la predicción del nivel de riesgo ergonómico.
- Analizar diferentes variables antropométricas de la mano en la identificación del somatotipo y su impacto en la predicción del nivel de riesgo ergonómico.
- Considerar otras variables de la metodología, tales como la duración del esfuerzo y la frecuencia del mismo.

Contribuciones científicas

- Artículos en revistas indexadas de alto impacto
 - **Rodríguez-Vega, Graciela** and Zaldívar-Colado, Ulises and Zaldívar-Colado, Xiomara and Rodríguez-Vega, Dora and De la Vega-Bustillos, Enrique, 2021. Comparison of Univariate and Multivariate Anthropometric Accommodation of the Northwest Mexico Population. **Ergonomics** Vol. 64, No. 08, pp. 1018-1034, doi: 10.1080/00140139.2021.1892832, url: <http://www.tandfonline.com/doi/abs/10.1080/00140139.2021.1892832>

- Actas de congresos (Conference proceedings)
 - **Rodríguez-Vega G.**, Rodríguez-Vega D.A., Zaldívar-Colado X.P., Zaldívar-Colado U., Castillo-Ortega R. (2022) A Motion Capture System for Hand Movement Recognition. In: Black N.L., Neumann W.P., Noy I. (eds) Proceedings of the 21st Congress of the International Ergonomics Association (IEA 2021). IEA 2021. **Lecture Notes in Networks and Systems**, vol 223. Springer, Cham. https://doi.org/10.1007/978-3-030-74614-8_13
 - **Rodríguez-Vega G.**, Zaldívar-Colado X.P., Zaldívar-Colado U., De la Vega-Bustillos E.J., Rodríguez-Vega D.A. (2022) Hand Shape Modeling for the Mexican Population. In: Black N.L., Neumann W.P., Noy I. (eds) Proceedings of the 21st Congress of the International Ergonomics Association (IEA 2021). IEA 2021. **Lecture Notes in Networks and Systems**, vol 223. Springer, Cham. https://doi.org/10.1007/978-3-030-74614-8_14

- Memorias en extenso
 - **Graciela Rodríguez Vega**, Ulises Zaldívar Colado y Xiomara Zaldívar Colado (2018). Metodología para el diseño e implementación de un sistema de evaluación ergonómica en tiempo real. En: Memorias del XX Congreso Mexicano de Robótica 2018. ISBN: 978-607-98174-1-1.

- **Graciela Rodríguez Vega**, Xiomara P. Zaldívar Colado, Ulises Zaldívar Colado, Dora A. Rodríguez Vega y Rafael Castillo Ortge (2020). Propuesta de un guante de captura de movimiento para aplicaciones en salud ocupacional. En: Memorias del XXII Congreso Mexicano de Robótica 2020/I Congreso virtual COMRON 2020. ISBN: 98-607-98174-8-0.

Técnicas de análisis multivariado basado en extremos

El acomodo antropométrico multivariado fue introducido en el análisis antropométrico en la década de 1980's. Su objetivo era reducir el conjunto de datos antropométricos a un número manejable e interpretable de dimensiones, que permitiera el mayor porcentaje de acomodo removiendo la mayor cantidad de ruido en los datos (118). Dos de las técnicas más utilizadas en el análisis antropométrico multivariado basado en casos extremos son el Análisis de Componentes Principales y el Análisis de Arquetipos (AA).

B.1. Análisis de Componentes Principales (ACP)

ACP es una transformación lineal que convierte los datos originales en un nuevo espacio dimensional, de tal manera que el nuevo conjunto de variables son funciones lineales de los datos originales y no poseen correlación. El objetivo principal de este método es reducir la dimensionalidad mientras se preserva la mayor cantidad de variabilidad posible (119) (véase C.1.3). En el análisis antropométrico de casos extremos, una vez que ACP es calculado en el conjunto original de datos, se selecciona el número de componentes que representan la mayor cantidad posible de variabilidad (comúnmente $> 70\%$) –por lo general los primeros dos o tres componentes principales (32)– ya que estos representan más del 80% de la variabilidad de la población objetivo. El procedimiento general para identificar los casos extremos a partir del ACP es el siguiente (120):

1. Implementar ACP para reducir la variación antropométrica de las dimensiones consideradas, y seleccionar 2 o 3 dimensiones (componentes) ortogonales (independientes).
2. Graficar la población objetivo en el “espacio ACP”.

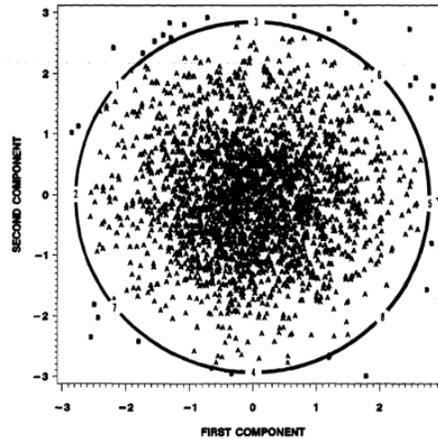


Figura B.1: Solución Análisis de Componentes Principales 2-Dimensiones: Porcentaje de acomodo del 99.5% (99.5% de los sujetos en la muestra se encuentran dentro del círculo ajustado, el cual es definido por los ocho casos representativos) (4)

3. Ajustar una elipse/elipsoide que represente el porcentaje de acomodo deseado (generalmente 90-95%), que representa el límite de acomodo multivariado.
4. Identificar los casos extremos:
 - Caso 2D: es posible identificar ocho modelos extremos (Figura B.1):
 - Cuatro modelos localizados en las intersecciones de la elipse/círculo con los PCs
 - Cuatro modelos en los puntos medio de los cuadrantes de la elipse/círculo
 - Caso 3D: es posible determinar 14 modelos o casos extremos (Figura B.2):
 - Seis modelos localizados en las intersecciones de la elipsoide/esfera con los tres PCs
 - Ocho modelos en los puntos medios de cada uno de los octantes de la elipse/esfera

B.2. Análisis de Arquetipos (AA)

El AA fue introducido en el análisis antropométrico multivariado por Cutler y Breiman (121), quienes clasificaron seis dimensiones que describen la forma y tamaño de la cabeza. En el AA se asume la existencia de algunos individuos “puros”, denominados **arquetipos**, quienes se encuentran en los “extremos” de los datos, y el resto de los individuos son considerados una mezcla de estos individuos puros (121), (39).

Para implementar AA, considere una matriz \mathbf{X} de tamaño $n \times m$ que representa un conjunto de datos multivariados con n observaciones y m variables. AA busca encontrar una matriz \mathbf{Z} de

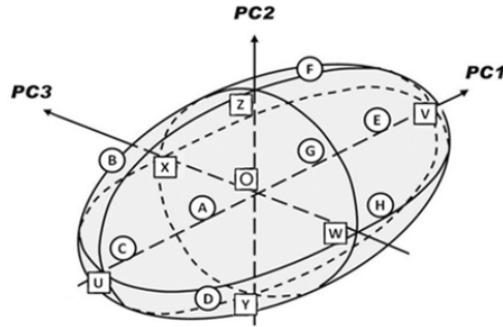


Figura B.2: Centroide, intersecciones (cuadrados) y puntos medios de los octantes (círculos) de la elipsoide ajustada (5).

tamaño $k \times m$ que caracteriza los patrones de los arquetipos en los datos, de tal forma que los datos pueden ser representados como una mezcla de estos arquetipos, es decir, AA trata de encontrar las dos matrices de coeficientes α y β de tamaño $n \times k$ que minimizan la suma de los errores residuales (39):

$$RSS = \sum_{i=1}^n \left\| X_i - \sum_{j=1}^k \alpha_{ij} Z_j \right\|^2 \quad (B.1)$$

$$RSS = \sum_{i=1}^n \left\| X_i - \sum_{j=1}^k \alpha_{ij} \sum_{l=1}^n \beta_{ij} X_l \right\|^2,$$

donde

$$\sum_{j=1}^k \alpha_{ij} = 1 \text{ para } \alpha_{ij} \geq 0 \text{ y } i = 1, \dots, n \quad (B.2)$$

$$\sum_{l=1}^n \beta_{ij} = 1 \text{ para } \beta_{ij} \geq 0 \text{ y } j = 1, \dots, k \quad (B.3)$$

La restricción B.2 implica que los predictores de \mathbf{x}_i son una mezcla finita de los arquetipos, $\mathbf{x}_i = \sum_{j=1}^k \alpha_{ij} \mathbf{z}_j$, mientras que la restricción B.3 significa que los arquetipos \mathbf{z}_j son una combinación convexa de los puntos de datos, $\mathbf{z}_j = \sum_{l=1}^n \beta_{jl} \mathbf{x}_l$.

Para asegurar el porcentaje de acomodo multivariado deseado, Epifanio et al. (39), removieron el 5% más extremo de los datos. Lo anterior se puede realizar en función de la distribución de

probabilidad de los datos:

1. Si los datos provienen de una distribución normal multivariada (es común asumir que los datos antropométricos provienen de distribuciones normales), es posible emplear la distancia mahalanobis de una observación con respecto a la media, definida por:

$$D^2 = (\mathbf{x} - \hat{\boldsymbol{\mu}})^T \hat{\boldsymbol{\Sigma}}^{-1} (\mathbf{x} - \hat{\boldsymbol{\mu}}) \quad (\text{B.4})$$

donde $\hat{\boldsymbol{\mu}}$ es la media estimada y $\hat{\boldsymbol{\Sigma}}$ es la matriz de covarianzas, que sigue una distribución Chi-cuadrada con m grados de libertad, por lo que los datos que superen el valor de la distribución Chi-cuadrada para el porcentaje de acomodo deseado, son removidos del conjunto de datos.

2. Si los datos no siguen una distribución normal multivariada, se recomienda emplear alternativas no paramétricas, como lo es la profundidad de los datos, sin embargo, en esta estrategia el porcentaje de acomodo deseado no está dentro de control del analista.

Dado que el número de arquetipos es un dato proporcionado por el analista, y el análisis multivariado para el acomodo antropométrico es una técnica exploratoria, es necesario realizar el análisis estadístico de los resultados obtenidos para diferentes números de arquetipos. La métrica comúnmente utilizada para dicho fin, es la regla del codo (*elbow rule*), que requiere la graficación de alguna métrica de disimilitud como la suma del error cuadrático (SSE, RSS) para diferentes valores de k arquetipos. Valores pequeños de SSE indican que cada grupo es más convergente. En la interpretación de la gráfica, los valores de SSE disminuyen drásticamente para los valores óptimos de k , mientras que los valores de SSE presentan decrementos poco significativos cuando el valor de k es superior a su valor óptimo (122).

Técnicas de aprendizaje de máquina

C.1. Aprendizaje de máquina

El aprendizaje de máquina (ML) es una rama de la inteligencia artificial que busca construir modelos matemáticos con la finalidad de hacer predicciones o decisiones sin que hayan sido explícitamente programados para ello (123). En este contexto, el aprendizaje es definido con la habilidad de aprender de acuerdo a un estímulo externo y recordar la mayoría de las experiencias previas (124). Mitchell (125) señala que un programa computacional aprende de la experiencia E con respecto a una serie de tareas T y una medida de desempeño P , si su desempeño en las tareas T , medido por P , mejora con la experiencia E .

ML realiza el análisis estadístico en dos conjuntos de datos: entrenamiento y prueba. El conjunto de datos de entrenamiento se conforma de datos “etiquetados” y “no etiquetados” disponibles para los aprendices automáticos, mientras que el conjunto de datos de prueba considera datos desconocidos para el aprendiz. ML define un regresor o un clasificador a través del aprendizaje obtenido mediante el análisis del conjunto de entrenamiento y posteriormente, evalúa el desempeño del regresor o clasificador en el conjunto de prueba (123). Con base en la naturaleza de los datos de entrenamiento, ML puede clasificarse en (124), (123):

1. Aprendizaje de datos estructurados:

- a) Aprendizaje supervisado (SL): Este tipo de aprendizaje se basa en el concepto de “maestro-^o supervisor (datos etiquetados) que proporcionan al estudiante el problema de identificar la relación entre las entradas (predictores) y las salidas (etiquetas) y sus soluciones (etiquetas o datos de salida). Lo anterior se puede traducir en que, a partir de un conjunto de entrenamiento dado de datos etiquetados $(X_{train}, Y_{train}) = (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)$, SL aprende una regla general para convertir las entradas en salidas (123). Los modelos determinados mediante SL, deben tener la habilidad de formalizar generalizaciones y de evitar el *sobreajuste* (*overfitting*), que puede causar *sobreaprendizaje* (*overlearning*)

(124). En los problemas de SL, se pueden encontrar dos tipos de algoritmos: regresión y clasificación. Los primeros buscan encontrar la regla general de clasificación para datos de salida de tipo continuo, mientras que los clasificadores son aplicados en problemas en los que las salidas son de tipo categórico o discretas. (124).

- b) Aprendizaje no supervisado (NSL): En los problemas de NSL, el conjunto de entrenamiento está conformado por datos no etiquetados $X_{train} = \mathbf{x}_1, \dots, \mathbf{x}_u$. En este contexto, el problema se caracteriza por la ausencia de un 'maestro' supervisor y por ende de una medida del error absoluto. Este tipo de aprendizaje es empleado cuando se desea identificar los patrones naturales de un conjunto de datos, lo que permite agruparlos (clusterizarlos) de acuerdo a su similitud (o medida de distancia) (123).
- c) Aprendizaje semi-supervisado (SSL): Este tipo de aprendizaje el conjunto de entrenamiento es una mezcla de una pequeña cantidad de datos etiquetados y una gran cantidad de no etiquetados $(X_{train}, Y_{train}) = (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l) \cup \mathbf{x}_{l+1}, \dots, \mathbf{x}_{l+u}$ para $l \ll u$ (123).
- d) Aprendizaje reforzado (RL): En este modo de aprendizaje, los datos de entrenamiento, en la forma de premios (valores positivos) y castigos (valores negativos) son proporcionados solo como retroalimentación a un agente de inteligencia artificial en un ambiente dinámico (123).

2. Aprendizaje de máquina gráfico: El agente aprende una estructura de una gráfica a partir de muestra de datos de entrenamiento en los casos de aprendizaje semi-supervisado y no supervisado.

C.1.1. Técnicas de clasificación

C.1.1.1. Estrategias multiclase

Cuando el conjunto de datos contiene más de una clase, existen dos formas de abordar el problema de clasificación(124):

1. Estrategia *one-vs-one*: Es considerada la estrategia más empleada. Si se tienen n clases y n clasificadores entrenados en paralelo considerando siempre que existe una separación entre la clase actual y el resto. Sólo se requieren $n - 1$ comparaciones para encontrar la clase correcta, por lo que la complejidad del algoritmo es $O(n)$.
2. Estrategia *one-vs-all*: En esta estrategia, se entrena un modelo para cada par de clases, por lo que su complejidad no es lineal ($O(n^2)$) y la clase correcta es determinada por voto mayoritario.

C.1.1.2. Máquinas de vectores de soporte

El algoritmo de Máquinas de Vectores de Soporte(SVM) fue desarrollado por Cortes y Vapnik en 1995 (126) y ha demostrado que es más preciso que la mayoría de las alternativas empleadas en los problemas de clasificación tales como máxima verosimilitud y redes neuronales (127). Este método es de utilidad en aplicaciones en las que el número de atributos es mayor que el número de objetos de entrenamiento, debido que el número de parámetros requeridos por SVM está relacionado con el número de objetos de entrenamiento y no con el número de atributos (128). SVM se basa en estadísticas más que en otras características garantizando un buen desempeño (129). SVM busca un hiperplano óptimo de separación (OSH) entre las clases, enfocándose en el entrenamiento de las muestras que estan a los extremos, los vectores de soporte. EL OSH esta orientado de tal manera que se posicione a la distancia máxima entre los conjuntos de vectores de soporte (130). La base del algoritmo SVM recae en el hecho que solo las observaciones de entrenamiento que corresponden a los límites de la clase, son necesarios para realizar la discriminación (130). El *overfitting* es controlado a través del principio de minimización del riesgo estructural, desarrollado por Vanik y Vladimir (131). El riesgo de misclasificación se minimiza mediante la maximización del margen entre los datos y los límites de decisión(132).

Lo anterior puede ser expresado matemáticamente de la siguiente manera: Dado un conjunto de datos \mathbf{D} , con n puntos \mathbf{x}_i en un espacio conformado por d dimensiones. El hiperplano esta definido por los puntos $\mathbf{x} \in \mathbb{R}^d$ que satisfacen la ecuación $h(\mathbf{x}) = 0$, donde $h(\mathbf{x})$ es la función del hiperplano definida por:

$$h(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = w_1 x_1 + w_2 x_2 + \dots + w_d x_d + b \quad (\text{C.1})$$

donde \mathbf{w} es vector de ponderaciones de d dimensiones y b es un escalar denominado *bias*.

La distancia mínima de un punto al hiperplano de separación, denominado margen del clasificador lineal, puede calcularse mediante:

$$\delta^* = \min_{x_i} \left\{ \frac{y_i(\mathbf{w}^T \mathbf{x}_i + b)}{\|\mathbf{w}\|} \right\} \quad (\text{C.2})$$

Los *vectores de soporte* \mathbf{x}^* son los puntos que se encuentran dentro del margen del clasificador, y que por ende, satisfacen la siguiente condición:

$$\delta^* = \frac{y_i(\mathbf{w}^T \mathbf{x}_i + b)}{\|\mathbf{w}\|} \quad (\text{C.3})$$

donde y^* es la etiqueta de la clase para el vector de soporte \mathbf{x}^* . El numerador representa la distancia absoluta del vector de soporte al hiperplano, mientras que el denominador $\|\mathbf{w}\|$ lo convierte en la distancia relativa en términos de \mathbf{w} .

En el caso de hiperplanos canónicos ($y^* h(\mathbf{x}^*) = 1$ para el vector de soporte \mathbf{x}^* , Figura C.2), el

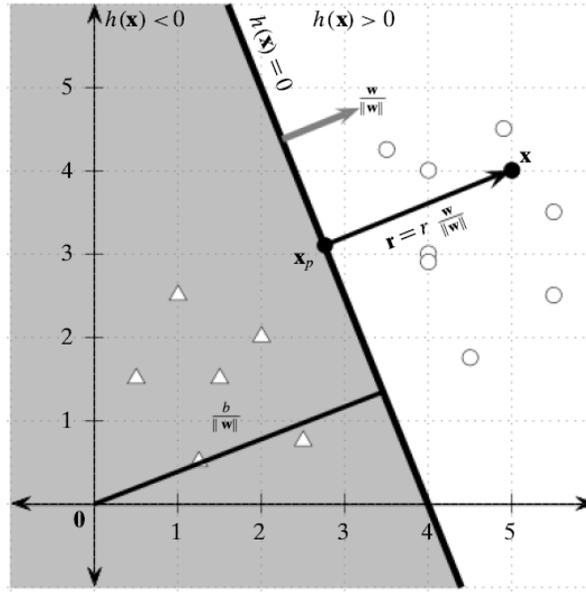


Figura C.1: Geometría de la separación del hiperplano en 2D².

margen está determinado por:

$$\delta^* = \frac{y^* h(\mathbf{x}^*)}{\|\mathbf{w}\|} = \frac{1}{\|\mathbf{w}\|} \quad (\text{C.4})$$

El algoritmo emplea kernels, que son las funciones utilizadas para proyectar los datos del espacio de entrada al espacio de características, tales como las funciones polinomiales, gaussiana y cuadráticas, que por lo general son determinadas a través de procesos de validación cruzada (133).

Los algoritmos SVM fueron diseñados para la clasificación binaria, sin embargo se desarrollaron aplicaciones que permiten su uso en el análisis multiclase, mediante la descomposición del problema en series de análisis binario que tratados como un problema SVM binario, combinado con estrategias *one-against-one* and *one-against-all* (133). La estrategia *one-against-all* divide el conjunto de datos of N clases, en N casos de dos clases. En contraparte, la estrategia *one-against-one* construye una máquina para cada par de clases resultantes en $N(N-1)/2$ máquinas. En la etapa de comprobación con el conjunto de prueba, cada clasificación otorga un voto a la clase ganadora y la observación es etiquetada con la clase que contenga mayoría de votos (133). Una de las principales desventajas de la estrategia *one-against-one* es que demanda una intensidad computacional mayor, mientras que

²Los puntos calificados como +1 se representan mediante círculos, mientras que los puntos etiquetados como -1 se muestran en triángulos. El hiperplano $h(\mathbf{x}) = 0$ divide el espacio en dos mitades. La región sombreada comprende los puntos \mathbf{x} que satisfacen la condición $h(\mathbf{x}) < 0$, mientras que la región no sombreada está conformada por los puntos que satisfacen la condición $h(\mathbf{x}) > 0$. El vector unitario $\frac{\mathbf{w}}{\|\mathbf{w}\|}$ (de color gris) es ortogonal al hiperplano. La distancia del origen al hiperplano es $\frac{b}{\|\mathbf{w}\|}$ (6).

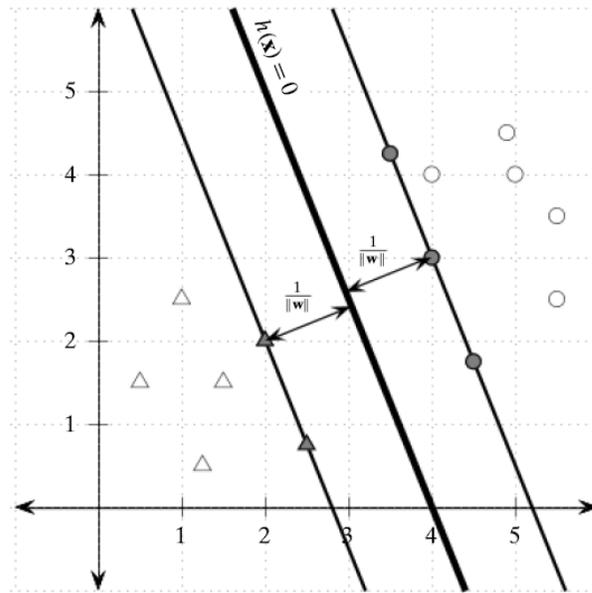


Figura C.2: Margen de separación del hiperplano. $\frac{1}{\|\mathbf{w}\|}$ corresponde al margen y los puntos sombreados representan los vectores de soporte (6).

el desempeño de la estrategia one-against-all puede ser menor en conjunto de datos no balanceados (133).

C.1.1.3. k vecinos más cercanos

La regla de los vecinos más cercanos es probablemente el clasificador más empleado y uno de los primeros clasificadores no paramétricos propuestos en la literatura (134). Este algoritmo no construye un modelo explícito, por lo contrario desempeña un aprendizaje basado en instancias: nuevas instancias son clasificadas comparándolas con el conjunto de datos en su totalidad (135). Lo anterior puede expresarse de la siguiente manera: Dado un conjunto de entrenamiento $\tau = \{(\mathbf{x}_i, y_i)\}_{i=1}^n$, donde $y_i \in \{0, \dots, c-1\}$, y \mathbf{x} un nuevo vector de características; $\mathbf{x}_{(1)}, \mathbf{x}_{(2)}, \dots, \mathbf{x}_{(n)}$ es el conjunto de vectores de características ordenados ascendentemente de acuerdo a alguna distancia (por ejemplo, mahalanobis, euclídeana); $\tau(\mathbf{x}) = \{(\mathbf{x}_{(1)}, y_{(1)}), \dots, (\mathbf{x}_{(K)}, y_{(K)})\}$ es un subconjunto de K vectores de características \mathbf{x}_i más cercanos a \mathbf{x} . La regla de clasificación de K -vecinos más cercanos clasifica \mathbf{x} de acuerdo a la clase con mayor frecuencia en $\tau(\mathbf{x})$. Si dos o más clases obtienen el mismo número de votos, el vector de características es clasificado mediante la selección aleatoria de uno de estas clases (136).

Algoritmo 1: Algoritmo de k -vecinos más cercanos (6).

- Datos:** Conjunto de datos $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)$; función de distancia $d(\mathbf{a}, \mathbf{b})$; número de vecinos k ; instancia x
- 1 Se tiene al i -ésimo subconjunto de datos de vecinos $L_i = \{x_1^{(i)}, \dots, x_{n_i}^{(i)}\}$ para $y_1, \dots, y_N \in \{i\}$, donde $n_1 + \dots + n_k = N$
 - 2 Calcular los centros de los k vecinos $\mathbf{m}^{(i)} = \frac{1}{N_i} \sum_{j=1}^{n_i} \mathbf{x}_j^{(i)}$ para $i = 1, \dots, k$
 - 3 Encontrar las distancias $d(\mathbf{x}, \mathbf{m}_i)$ entre \mathbf{m}_i y el i -ésimo vecino, para $i = 1, \dots, k$
 - 4 Encontrar al vecino más cercano de \mathbf{x} y asignando la etiqueta de $y \leftarrow \min_i \{d(\mathbf{x}, \mathbf{m}^{(1)}), \dots, d(\mathbf{x}, \mathbf{m}^{(k)})\}$
-

C.1.1.4. Gaussian Naïve Bayes

Los modelos probabilísticos realizan el aprendizaje supervisado mediante inferencia de la distribución de probabilidad de los datos. En los modelos probabilísticos de clasificación, el clasificador óptimo para las clases $0, \dots, c - 1$ divide el espacio de características en c regiones, dependiendo de la $f(y|\mathbf{x})$: la función de densidad de probabilidad (pdf) de la respuesta Y dado un vector de características $\mathbf{X} = \mathbf{x}$. En particular, si $s(y|\mathbf{x}) > f(z|\mathbf{x})$ para toda $z \neq y$, el vector de características \mathbf{x} es clasificado como y . La probabilidad condicional $f(y|\mathbf{x})$ es interpretada como la probabilidad a posteriori, de la forma: $f(y|\mathbf{x}) \propto f(\mathbf{x}|y)f(y)$, donde $f(\mathbf{x}|y)$ es la probabilidad de obtener el vector de características \mathbf{x} de la clase y y $f(y)$ es la probabilidad a priori de la clase y . La clase \hat{y} es asignada a un vector \mathbf{x} de acuerdo a la probabilidad a posteriori más alta, es decir, mediante la regla de decisión óptima de Bayes:

$$\hat{y} = \operatorname{argmax}_y f(y|\mathbf{x}) \quad (\text{C.5})$$

Dada la función de densidad discreta $f(y|\mathbf{x}), y = 0, \dots, c - 1$ es usualmente desconocida, suele aproximarse mediante la función $g(y|\mathbf{x})$ proveniente de alguna clase de función \mathcal{G} . En el caso específico del algoritmo naïve Bayes, la función de aproximación \mathcal{G} es seleccionada de tal manera que $g(\mathbf{x}|y) = g(x_1|y) \dots g(x_p|y)$, clases o etiquetas condicionales, con características independientes. Asumiendo una probabilidad uniforme a priori, la pdf a posteriori puede ser definida mediante:

$$g(y|\mathbf{x}) \propto \prod_{j=1}^p g(x_j|y) \quad (\text{C.6})$$

donde las pdf marginales $g(x_j|y), j = 1, \dots, p$ pertenecen a una clase determinada de funciones de aproximación \mathcal{G} . Para clasificar \mathbf{x} , se selecciona y que maximice la pdf a posteriori sin normalizar (136).

Una variante del clasificador naïve Bayes, es el clasificador naïve Bayes gaussiano, que considera

que la verosimilitud de las categorías sigue una distribución gaussiana (135):

$$P(x_i|y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma_y^2}\right) \quad (\text{C.7})$$

donde σ_y y μ_y se estiman mediante máxima verosimilitud.

C.1.1.5. Análisis discriminante lineal y cuadrático

En el caso de clasificación binaria, considere una clase de funciones de aproximación \mathcal{G} tal que, condicional a la clase $y \in \{0, 1\}$, el vector de características $\mathbb{X} = [X_1, \dots, X_p]^T$ posee una distribución normal $\mathcal{N}(\underline{\mu}_y, \Sigma_y)$:

$$g(\mathbf{x}|\underline{\mu}, y) = \frac{1}{\sqrt{(2\pi)^p |\Sigma_y|}} e^{-\frac{1}{2}(\mathbf{x} - \underline{\mu})^T \Sigma_y^{-1} (\mathbf{x} - \underline{\mu})}, \mathbf{x} \in \mathbb{R}^p, y \in \{0, 1\} \quad (\text{C.8})$$

dónde, $\underline{\mu} = \{\alpha_j, \Sigma_j\}_{j=0}^{c-1}$ contiene todos los parámetros del modelo, incluyendo el vector de probabilidad \mathbf{f} que es auxiliar en la definición de la densidad a priori: $g(y|\underline{\mu}) = \alpha_y, y \in \{0, 1\}$. Entonces, la densidad a posteriori es definida por:

$$g(y|\underline{\mu}, \mathbf{x}) \propto \alpha_y \times g(\mathbf{x}|\underline{\mu}, y) \quad (\text{C.9})$$

La función

$$\delta_y(\mathbf{x}) = \ln \alpha_y - \frac{1}{2} \ln |\Sigma_y| - \frac{1}{2} (\mathbf{x} - \underline{\mu}_y)^T \Sigma_y^{-1} (\mathbf{x} - \underline{\mu}_y), \mathbf{x} \in \mathbb{R}^p \quad (\text{C.10})$$

es denominada función cuadrática discriminante para la clase $y = \{0, 1\}$, mientras que la función

$$\delta_y(\mathbf{x}) = \ln \alpha_y - \frac{1}{2} \ln \Sigma_y^{-1} - \mathbf{x}^T \mathbf{a}^{-1} - y, \mathbf{x} \in \mathbb{R}^p \quad (\text{C.11})$$

corresponde a la función lineal discriminante. Un punto \mathbf{x} es clasificado en la clase con $\delta_y(\mathbf{x})$ máximo (136).

C.1.1.6. Árboles de decisión

Los árboles de decisión son clasificadores que pueden ser interpretados como una estructura de árbol jerárquica. Un árbol de decisión está conformado por nodos internos que representan las decisiones correspondientes a los hiperplanos o puntos de división, y hojas, que representan las regiones o particiones del espacio de datos y que son etiquetados con la clase mayoritaria. Una región es caracterizada por el subconjunto de datos que pertenecen a dicha región. En particular, un árbol de decisión puede visualizarse como un conjunto de reglas de decisión, cada una de ellas

representa las decisiones de los nodos internos a través de una ruta hacia una hoja y la asignación de la etiqueta correspondiente al nodo de la hoja. Además, debido a que las regiones son mutuamente excluyentes y cubren el espacio en su totalidad, el conjunto de reglas pueden ser interpretadas como un conjunto de alternativas o disyunciones. Un hiperplano $h(\mathbf{x})$ es definido como un conjunto de puntos \mathbf{x} que satisfacen la siguiente ecuación:

$$h(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = 0 \quad (\text{C.12})$$

donde $\mathbf{w} \in \mathbb{R}^d$ es un vector de ponderaciones normal al hiperplano, y b es la compensación (*offset*) del hiperplano con respecto al origen. Un árbol de decisión solo considera hiperplanos paralelos a los ejes, es decir, el vector de ponderaciones debe ser paralelo a una de las dimensiones originales o ejes X_j . En otros casos, el vector de ponderaciones \mathbf{w} es restringido *a priori* a uno de los vectores base estándar $\{\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_d\}$ donde $\mathbf{e}_i \in \mathbb{R}$ toma el valor de 1 para la i -ésima dimensión, y 0 para todas las otras dimensiones. Si, $\mathbf{x} = (x_1, x_2, \dots, x_d)$ y asumiendo $\mathbf{w} = \mathbf{e}_j$, sustituyendo en C.12, se obtiene

$$h(\mathbf{x}) : \mathbf{e}_j^T \mathbf{x} + b = 0 \quad h(\mathbf{x}) : x_j + b = 0 \quad (\text{C.13})$$

donde la selección del valor de b puede generar diferentes hiperplanos en la dimensión X_j . Un hiperplano especifica una decisión o *punto de división* ya que divide el espacio de datos \mathbb{R} en dos espacios. Los puntos \mathbf{x} en los que $h(\mathbf{x}) \leq 0$ se encuentran en un lado del hiperplano, mientras que los puntos en los que $h(\mathbf{x}) \geq 0$ se encuentran en el lado opuesto. La forma genérica de un *punto de división* es $X_j \leq v$, donde $v = -b$ es algún valor en el dominio de los atributos de X_j , que divide el espacio \mathbb{R} en las regiones \mathcal{R}_Y y \mathcal{R}_N :

$$\mathbf{D}_Y = \{\mathbf{x}^T | \mathbf{x} \in \mathbf{D}, x_j \leq v\} \quad \mathbf{D}_N = \{\mathbf{x}^T | \mathbf{x} \in \mathbf{D}, x_j > v\} \quad (\text{C.14})$$

donde \mathbf{D}_Y es el subconjunto de datos que pertenecen a la región \mathcal{R}_Y , y \mathbf{D}_N corresponde al subconjunto de datos en \mathcal{R}_N . La pureza de cada región \mathcal{R}_j es definida en términos de la mezcla de clases para los puntos en la partición \mathbf{D}_j correspondiente:

$$pureza(\mathbf{D}_j) = \max_i \left\{ \frac{n_{ji}}{n_j} \right\} \quad (\text{C.15})$$

donde $n_j = |\mathbf{D}_j|$ corresponde al total de datos en la región \mathcal{R}_j y n_{ji} es el número de puntos en \mathbf{D}_j con etiqueta de clase c_i .

El pseudo-código del algoritmo básico de árboles de decisión se muestra en 2. En él, se puede observar que el método de árboles de decisión es recursivo en \mathbf{D}_Y y \mathbf{D}_N . La condición más simple para detener el algoritmo recursivo se basa en el tamaño de la partición \mathbf{D} . Si el número de puntos

n en \mathbf{D} es menor al tamaño umbral \mathbf{j} especificado por el usuario, el proceso de partición se detiene, y \mathbf{D} se convierte en hoja. Esta condición previene el *sobreaajuste* (*overfitting*) del modelo en el conjunto de entrenamiento al evitar dividir el modelo en subconjuntos muy pequeños de datos. La recursividad del proceso de partición es finalizado también, si la *pureza* de \mathbf{D} es mayor al umbral de pureza π (6).

Algoritmo 2: Algoritmo árboles de decisión (6)

```

Datos: Árbol de decisión ( $\mathbf{D}, \eta, \pi$ )
1  $n \leftarrow |\mathbf{D}|$  ;                               /* tamaño de la partición */
2  $n_i \leftarrow |\{\mathbf{x}_j | \mathbf{x}_j \in \mathbf{D}, y_i = c_i\}|$  ;   /* tamaño de la clase  $c_i$  */
3  $pureza(\mathbf{D}) \leftarrow \max_i \{\frac{n_i}{n}\}$ 
4 si  $n \leq \eta$  o  $pureza(\mathbf{D}) \geq \pi$  entonces
5    $c^* \leftarrow \operatorname{argmax}_{c_i} \{\frac{n_i}{n}\}$  ;           /* clase mayoritaria */
6   Crear hoja de nodo, y nombrarla con la etiqueta de la clase  $c^*$ 
7   return
8 fin
9  $(puntodedivision^*, puntaje^*) \leftarrow (\phi, 0)$  ; /* Inicializar el mejor punto de división */
10 para cada (atributo  $X_j$ ) hacer
11   si ( $X_j$  es numerico) entonces
12      $(v, puntaje) \leftarrow$  Evaluar el atributo numérico ( $\mathbf{D}, X_j$ )
13     si  $puntaje > puntaje^*$  entonces
14        $puntodedivision^*, puntaje^* \leftarrow (X_j \leq v, puntaje)$ 
15     fin
16   fin
17   en otro caso  $X_j$  es categorico
18      $(V, puntaje) \leftarrow$  Evaluar el atributo categórico ( $\mathbf{D}, X_j$ )
19     si  $puntaje > puntaje^*$  entonces
20        $puntodedivision^*, puntaje^* \leftarrow (X_j \in V, puntaje)$ 
21     fin
22   fin
23 fin
24 Particionar  $\mathbf{D}$  en  $\mathbf{D}_Y$  y  $\mathbf{D}_N$  utilizando el  $puntodedivision^*$ , y llamar recursivamente
25  $\mathbf{D}_Y \leftarrow \{\mathbf{x}^T | \mathbf{x} \in \mathbf{D} \text{ satisface el } puntodedivision^*\}$ 
26  $\mathbf{D}_N \leftarrow \{\mathbf{x}^T | \mathbf{x} \in \mathbf{D} \text{ No satisface el } puntodedivision^*\}$ 
27 Crear el  $puntodedivision^*$  del nodo interno, con dos nodos hijos,  $\mathbf{D}_Y$  y  $\mathbf{D}_N$ 
28 ÁRBOL DE DECISIÓN ( $\mathbf{D}_Y$ ); ÁRBOL DE DECISIÓN ( $\mathbf{D}_N$ )

```

La complejidad computacional asociada al método de árboles de decisión mostrado en 2 está en función del costo de evaluar todos los puntos de división para un atributo numérico o categórico ($O(n \log n)$, donde $n = |\mathbf{D}|$ es el tamaño del conjunto de datos). El algoritmo de árboles de decisión evalúa los d atributos, con costo ($dn \log n$). El costo total depende de la profundidad del árbol de decisión. En el peor escenario, el árbol puede tener una profundidad n y por ende un costo total $= (dn^2 \log n)$ (6).

C.1.1.7. Ensamblados

Los modelos de ensambles representan combinaciones de modelos y son considerados una de las técnicas de aprendizaje de máquina más poderosas, con un desempeño superior al de otros métodos. Esta ventaja trae consigo un incremento de la complejidad computacional y algorítmica (137). En el aprendizaje de máquina, los modelos de ensamble poseen las siguientes características generales:

- Construyen múltiples y diversos modelos predictivos a partir de versiones adaptadas de un conjunto de entrenamiento (en la mayoría de los casos re-ponderado o re-muestreado)
- Combinan predicciones de estos modelos de alguna manera, por lo general mediante el promedio simple o mediante votaciones (probablemente ponderadas).

Los métodos de ensamble más comunes son *bagging* y *boosting* (137):

1. *Bagging*

El término *bagging* proviene de la contracción de *bootstrap aggregating*, es considerado un simple pero altamente efectivo método de ensamble que crea diversos modelos en diferentes muestras aleatorias tomadas del conjunto original de datos. Estos algoritmos permiten reducir la varianza y evitar el *sobreajuste*. A pesar de que comúnmente son aplicados a árboles de decisión, pueden ser aplicados a cualquier método. El pseudocódigo del algoritmo se implementa en dos fases principales:

- Bootstrap sampling

Consiste en recolectar muestras aleatorias del conjunto total de datos D con reemplazo (para evitar la dependencia en el muestreo), llamadas *bootstrap samples*. Pueden contener puntos duplicados y algunos de los puntos originales puede no ser considerados aún si el tamaño de la muestra *bootstrap sample* es igual al tamaño del conjunto original de datos. Una aproximación de la diversidad de las muestras *bootstraps* puede obtenerse mediante el cálculo de la probabilidad de que un punto específico no sea seleccionado por una muestra de tamaño n : $(1 - \frac{1}{n})^n$ (137). Estos subconjuntos de datos son empleados para entrenar a los modelos de árboles de decisión.

- Agregación

Las salidas de los modelos entrenados en la fase de *bootstrap sampling*, son agregados en una sola predicción como parte de un modelo final, donde la categoría con la frecuencia mayor es la salida seleccionada.

El pseudocódigo del algoritmo *bagging* se presenta en 3.

Algoritmo 3: Algoritmo *bagging* (137)

Datos: Conjunto de datos (\mathbf{D} ; tamaño del ensamble T , algoritmo de aprendizaje \mathcal{A})

- 1 **para** $t = 1$ *to* T **hacer**
- 2 | Construir una *bootstrap sample* D_t a partir de \mathbf{D} muestreando $|\mathbf{D}|$ puntos de datos con reemplazo Ejecutar \mathcal{A} en D_t para producir el modelo M_t
- 3 **fin**
- 4 Return $\{M_t | 1 \leq t \leq T\}$

Bagging es de gran utilidad en combinación con modelos de árbol, los cuales son sensibles a las variaciones en el conjunto de entrenamiento. El método de ensamble *random forests* construye cada árbol a partir de un subconjunto aleatorio y diferente de características, denominado *subspace sampling*. Como resultado, el tiempo de entrenamiento se reduce considerablemente (137).

Al igual de los árboles de decisión, en *random forests* la partición del espacio correspondiente a la instancia es en esencia la intersección de las particiones de los árboles individuales en el ensamble. En *random forests*, la partición es más fina que en la mayoría de las particiones de árboles, por lo que pueden ser mapeadas de regreso a un modelo de árbol sencillo, a diferencia de los clasificadores lineales *bagging*, donde el ensamble tiene un perímetro de decisión que no puede ser aprendido mediante un clasificador sencillo. El algoritmo se muestra en 4(137).

Algoritmo 4: Algoritmo *bagging - random forests*

Datos: Conjunto de datos (\mathbf{D} ; tamaño del ensamble T , dimensión del subespacio d)

- 1 **para** $t = 1$ *to* T **hacer**
- 2 | Construir una *bootstrap sample* D_t a partir de \mathbf{D} muestreando $|\mathbf{D}|$ puntos de datos con reemplazo Seleccionar d características de forma aleatoria y reducir la dimensionalidad de D_t Entrenar el modelo de árboles M_t en D_t sin poda
- 3 **fin**
- 4 Return $\{M_t | 1 \leq t \leq T\}$

2. Boosting

En la técnica *boosting*, la fase de muestreo se realiza de una forma diferente a *bootstrap*. Asumiendo que se cuenta con un primer clasificador con una tasa de error ϵ y se desea agregar

un nuevo clasificador al ensamble que disminuya los fallos en las clasificaciones efectuadas por el primer clasificador. Para lograr dicho objetivo, existen dos estrategias para seleccionar la muestra del segundo clasificador: 1) duplicar las instancias con fallos en la clasificación y 2) asignar una ponderación mayor a las instancias con fallos en la clasificación y modificar el clasificador para implementar estos pesos. La literatura recomienda que la asignación de los pesos comience con una distribución uniforme de los pesos que en su totalidad sumen 1, donde la mitad del peso (0.5) se asigne a las instancias con fallos en la clasificación y la otra mitad sea asignada de manera uniforme también a las instancias correctamente clasificadas. Posteriormente, los pesos asignados a las instancias con fallos en la clasificación son multiplicadas por $1/2\epsilon$, mientras que los pesos de las instancias correctamente clasificadas se multiplican por $1/2(1 - \epsilon)$ (137). El factor de confianza es importante en el ensamble de una predicción obtenida mediante la media ponderada de las salidas de modelos individuales. Es recomendable que un incremento en α proporcione una disminución en ϵ , de tal forma que se puede calcular mediante la siguiente ecuación (137):

$$\alpha_t = \frac{1}{2} \ln \frac{1 - \epsilon_t}{\epsilon_t} = \ln \sqrt{\frac{1 - \epsilon_t}{\epsilon_t}} \quad (\text{C.16})$$

El pseudocódigo del algoritmo boosting se muestra en 5.

Algoritmo 5: Algoritmo *boosting* para el ensamble de clasificadores binarios con conjuntos de datos de entrenamiento re-ponderados (137).

Datos: Conjunto de datos (\mathbf{D} ; tamaño del ensamble T , algoritmo de aprendizaje \mathcal{A})

```

1  $w_{1i} \leftarrow 1/|\mathbf{D}|$  para cada  $x_i \in \mathbf{D}$  para  $t = 1$  to  $T$  hacer
2   | Ejecutar el algoritmo mathcal{A} en  $\mathbf{D}$  con pesos  $w_{ti}$  para producir el modelo  $M_t$  Calcular
   | el error ponderado  $\epsilon_t$  si  $\epsilon_t \geq 1/2$  entonces
3   |   Definir  $T \leftarrow t - 1$  y continuar
4   fin
5    $\alpha_t \leftarrow \frac{1}{2} \ln \frac{1 - \epsilon_t}{\epsilon_t}$  ; /* Confianza para este modelo */
6    $w_{(t+1)i} \leftarrow \frac{w_{ti}}{2\epsilon_t}$  para las instancias con fallos en la clasificación  $X_i \in \mathbf{D}$  ; /* incrementar
   | los pesos */
7    $w_{(t+1)j} \leftarrow \frac{w_{tj}}{2(1-\epsilon_t)}$  para las instancias correctamente clasificadas  $x_j \in \mathbf{D}$  ; /* disminuir
   | los pesos */
8 fin
9 Return  $M(x) = \sum_{t=1}^T \alpha_t M_t(x)$ 
```

C.1.1.8. Evaluación de los modelos de clasificación entrenados

En las técnicas de clasificación es común encontrar que el conjunto de datos originales \mathbf{D} es dividido en conjunto de entrenamiento $\mathbf{D}_{training}$ y conjunto de prueba \mathbf{D}_{test} . El primero de ellos es utilizado para el aprendizaje del modelo M , mientras que el segundo es empleado para obtener alguna métrica de evaluación del desempeño (θ) del clasificador. Existen dos métodos comúnmente utilizados para determinar el valor esperado de la métrica del desempeño del clasificador $E[(\theta)]$ en todos los posibles conjuntos de prueba: 1) k -fold Cross-Validation y 2) Bootstrap resampling (6).

1. k -fold cross-validation

Esta técnica divide el conjunto de datos \mathbf{D} en K subconjuntos de igual tamaño, denominados *folds* $\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k$. Cada subconjunto \mathbf{D}_i se designa como conjunto de prueba, mientras que el resto de los subconjuntos conforman el conjunto de entrenamiento $\mathbf{D} \setminus \mathbf{D}_i = \cup_{j \neq i} \mathbf{D}_j$. Después de entrenar el modelo M_i en $\mathbf{D} \setminus \mathbf{D}_i$ se evalúa el desempeño del clasificador en el conjunto de prueba \mathbf{D}_i para obtener la i -ésima estimación de θ_i . El valor esperado de la métrica de desempeño puede ser estimado mediante

$$\hat{\mu}_0 = E[\theta] = \frac{1}{K} \sum_{i=1}^K \theta_i \quad (\text{C.17})$$

y la varianza

$$\hat{\sigma}_\theta^2 = \frac{1}{K} \sum_{i=1}^K (\theta_i - \hat{\mu}_\theta)^2 \quad (\text{C.18})$$

El pseudocódigo del algoritmo k -folds cross validation se muestra en 6. El valor de K es por lo general 5 o 10. Cuando $K = n$, se denomina validación leave-one-out, donde el conjunto de prueba se conforma de un sólo punto y el resto de los datos son utilizados como conjunto de entrenamiento (6).

Algoritmo 6: Algoritmo de validación cruzada k -folds (6).

Datos: Conjunto de datos (\mathbf{D} ; Folds K)

1 $\mathbf{D} \leftarrow$ ordenar aleatoriamente \mathbf{D} $\{\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_K\} \leftarrow$ particionar \mathbf{D} en K partes iguales

para $i \in [1, K]$ **hacer**

2 $M_i \leftarrow$ modelo entrenado en $\mathbf{D} \setminus \mathbf{D}_i$ $\theta_i \leftarrow$ evaluar M_i en \mathbf{D}_i

3 **fin**

4 $\hat{\mu}_\theta = \frac{1}{K} \sum_{i=1}^K \theta_i$ $\hat{\sigma}_\theta^2 = \frac{1}{K} \sum_{i=1}^K (\theta_i - \hat{\mu}_\theta)^2$ Return $\hat{\mu}_\theta, \hat{\sigma}_\theta^2$

2. Bootstrap

Esta técnica genera K muestras aleatorias de tamaño n con reemplazo a partir del conjunto de datos original \mathbf{D} . Cada muestra \mathbf{D}_i contiene algunos puntos repetidos. La probabilidad de que un punto determinado esté incluido en la muestra \mathbf{D}_i es $p = \frac{1}{n}$, por lo que la probabilidad de

que no este incluido es $q = 1 - p = (1 - 1/n)$. Dado que \mathbf{D}_i contiene n puntos, la probabilidad de que el punto \mathbf{x}_j no esté seleccionado después de n intentos, está dada por:

$$P(\mathbf{x}_k \notin \mathbf{D}_i) = q^n = \left(1 - \frac{1}{n}\right) \simeq \exp^{-1} = 0.368 \quad (\text{C.19})$$

mientras que la probabilidad de que $\mathbf{x}_j \in \mathbf{D}_i$ es

$$P(\mathbf{x}_k \in \mathbf{D}_i) = 1 - P(\mathbf{x}_j \notin \mathbf{d}_i) = 1 - 0.368 = 0.632 \quad (\text{C.20})$$

Lo anterior significa que cada muestra contiene aproximadamente 63.2% de los puntos de \mathbf{D} . El pseudocódigo del re-muestro bootstrap se muestra en 7. Una de las limitaciones de ésta tecnica es que la estimación del valor esperado y la varianza pueden resultar optimistas, debido al traslape entre el conjunto de entrenamiento y el conjunto de prueba (63.2%), a diferencia de la validación cruzada, donde los conjuntos de prueba y entrenamiento no contienen elementos en común (6).

Algoritmo 7: Algoritmo de re-muestro bootstrap (6).

Datos: Conjunto de datos (\mathbf{D} ; Folds K)

- 1 **para** $i \in [1, K]$ **hacer**
- 2 $\mathbf{D}_i \leftarrow$ muestra de tamaño n con reemplazo obtenida de \mathbf{D} $M_i \leftarrow$ modelo entrenado en \mathbf{D}_i
- 3 $\theta_i \leftarrow$ evaluar M_i en \mathbf{D}_i
- 3 **fin**
- 4 $\hat{\mu}_\theta = \frac{1}{K} \sum_{i=1}^K \theta_i$
- 5 $\hat{\sigma}_\theta^2 = \frac{1}{K} \sum_{i=1}^K (\theta_i - \hat{\mu}_\theta)^2$
- 6 **Return** $\hat{\mu}_\theta, \hat{\sigma}_\theta^2$

C.1.1.9. Métricas para el desempeño del clasificador

Existen diferentes métricas y estrategias principales que permiten identificar el desempeño de los clasificadores: la tasa de error, la precisión y las tablas de contingencia (6). Considere un conjunto de prueba \mathbf{D} conformado por n puntos en un espacio dimensional d , k etiquetas de clases $\{c_1, c_2, \dots, c_k\}$, y y_i representa la clase verdadera y \hat{y}_i la predicción de la clase en $\mathbf{x}_i \in \mathbf{D}$; las métricas mencionadas se pueden definir como (6):

1. Tasa de error

Se define como la fracción de predicciones incorrectas en el conjunto de prueba,

$$\text{Tasa de Error} = \frac{1}{n} \sum_{i=1}^n I(y_i \neq \hat{y}_i) \quad (\text{C.21})$$

donde I es un indicador de la función con valor 1 si el argumento es verdadero, y 0 en cualquier otro caso. Valores pequeños de la tasa de error corresponden a un mejor clasificador.

2. Precisión

Es la fracción de predicciones correctas en el conjunto de prueba,

$$Precisión = \frac{1}{n} \sum_{i=1}^n I(y_i = \hat{y}_i) = 1 - Tasa\ de\ error \quad (C.22)$$

Valores altos de precisión, representan mejores clasificadores.

3. Tablas de contingencia

Son métricas que proporcionan mayor información sobre el error de clasificación mediante la tabulación de la concordancia entre las etiquetas verdaderas y predichas para cada una de las clase. Considere $\mathbf{D} = \{\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k\}$, que denota la partición del conjunto de prueba basado en las etiquetas de clase positivas en el que

$$\mathbf{D}_j = \{\mathbf{x}_i^T y_i = c_j\} \text{ y } n_i = |\mathbf{D}_i| \quad (C.23)$$

donde n_i corresponde al tamaño de la clase verdadera c_i . Considere también, $\mathbf{R} = \{\mathbf{R}_1, \mathbf{R}_2, \dots, \mathbf{R}_k\}$, que denota la partición del conjunto de prueba basado en las etiquetas predichas, esto es:

$$\mathbf{R}_j = \{\mathbf{x}_i^T |\hat{y}_i = c_j\} \text{ y } m_j = |\mathbf{R}_j| \quad (C.24)$$

donde m_j representa el tamaño de la clase predicha c_j . Las particiones \mathbf{R} y \mathbf{D} generan una tabla de contingencia \mathbf{N} de tamaño $k \times k$, también conocida como matriz de confusión, definida como sigue:

$$\mathbf{N}(i, j) = n_{ij} = |\mathbf{R}_i \cap \mathbf{D}_j| = |\{\mathbf{x}_a \in \mathbf{D} \mid \hat{y}_a = c_i \text{ y } t_a = c_j\}| \quad (C.25)$$

donde $1 \leq i, j \leq k$. n_{ij} denota el número de puntos con predicción de clase c_i y cuya clase verdadera es c_j ; n_{ii} (para $1 \leq i \leq k$) representa el número de casos en los que el clasificador concuerda con la clase verdadera c_i . El resto de los datos n_{ij} , con $i \neq j$, representan los casos en los que el clasificador y las etiquetas verdaderas difieren.

La **exactitud o precisión** del clasificador M para la clase c_i está dada por la proporción de predicciones correctas en el total de datos predichos para la clase c_i :

$$exactitud_i = precision_i = \frac{n_{ii}}{m_i} \quad (C.26)$$

donde m_i es el número de muestras predichas como c_i or el clasificador M . La **Exactitud o Precisión general** del clasificador es una media ponderada de la exactitud específica de

cada clase:

$$Exactitud = Precision = \sum_{i=1}^k \left(\frac{m_i}{n} \right) Exactitud_i = \frac{1}{n} \sum_{i=1}^{kn_i} \quad (C.27)$$

La **cobertura o recall** de una clase específica de un clasificador M para la clase c_i , es la porción de predicciones correctas en el total de puntos de la clase c_i :

$$cobertura_i = recall_i = \frac{n_{ii}}{n_i} \quad (C.28)$$

donde n_i es el número de puntos en la clase c_i . La métrica **F-Score o F-measure** de una clase específica trata de balancear los valores de la precisión y la cobertura mediante la media armónica de la clase c_i :

$$F_i = \frac{2}{\frac{1}{precision_i} + \frac{1}{recall_i}} = \frac{2 \cdot precision_i \cdot recall_i}{precision_i + recall_i} = \frac{2n_{ii}}{n_i + m_i} \quad (C.29)$$

La métrica **F-Score o F-measure general** para el clasificador M corresponde a la media de los valores específicos de las clases:

$$F = \frac{1}{k} \sum_{i=1}^r F_i \quad (C.30)$$

Para el caso de un clasificador perfecto, el máximo valor de F es 1.

- Clasificación binaria: Clases positivas y negativas

Cuando el problema de clasificación consta de $k = 2$ clases, se denomina a la clase c_1 clase positiva y a la clase c_2 clase negativa, en la que (Figura C.3):

- Positivos verdaderos (TP): corresponde al número de puntos en los que el clasificador predijo correctamente como positivos.
- Falsos Positivos (FP): número de puntos para los que el clasificador predijo como positivos, mientras que realmente pertenecen a la clase negativa.
- Falsos Negativos (FN): número de puntos que el clasificador predijo como clase negativa, mientras que pertenecen a la clase positiva.
- Negativos verdaderos (TN): número de puntos que el clasificador predijo como clase negativa, pero que realmente pertenecen a la clase positiva.

A partir de estos conceptos se puede obtener las siguientes métricas de desempeño del clasificador, mismas que pueden ser generalizadas a la clasificación multiclase (6):

- Tasa de error

$$Tasa\ de\ Error = \frac{FP + FN}{n} \quad (C.31)$$

- Exactitud

$$Exactitud = \frac{TP + TN}{n} \quad (C.32)$$

- Precisión de la clase

$$precision_P = \frac{TP}{TP + FP} = \frac{TP}{m_1} precision_N = \frac{TN}{TN + FN} = \frac{TN}{m_2} \quad (C.33)$$

donde $m_i = |\mathbf{R}_i|$ es el número de puntos predichos por M para la clase c_i

- Sensibilidad o Tasa de Positivos Verdaderos (TPR): corresponde a la proporción de predicciones correctas con respecto a todos los puntos positivos de la clase, esto es, el *recall* o cobertura de la clase positiva:

$$TRP = recall_P = \frac{TP}{TP + FN} = \frac{TP}{n_1} \quad (C.34)$$

donde n_1 es el tamaño de la clase positiva.

- Especificidad o Tasa de Negativos Verdaderos (TNR): también denominada cobertura o *recall* de la clase negativa:

$$TNR = especificidad = recall_N = \frac{TN}{FP + TN} = \frac{TN}{n_2} \quad (C.35)$$

donde n_2 es el tamaño de la clase negativa.

- Tasa de Falsos Negativos (FNR):

$$FNR = \frac{FN}{TP + FN} = \frac{FN}{n_1} = 1 - sensibilidad \quad (C.36)$$

- Tasa de Falsos Positivos (FPR):

$$FPR = \frac{FP}{FP + TN} = \frac{FP}{n_2} = 1 - especificidad \quad (C.37)$$

C.1.2. Análisis de conglomerados (clústers)

El análisis de conglomerados es una técnica estadística multivariante comúnmente conocida como análisis de clústers, que ha sido ampliamente utilizada para el análisis exploratorio de datos (123). En minería de datos, es considerado una técnica de aprendizaje no supervisado para la clasificación automática de datos, donde las observaciones son agrupadas de acuerdo a patrones naturales identificados mediante una métrica de similitud mutua. La finalidad del análisis de clústers es que aquellos objetos con un alto grado de similitud se agrupen para conformar un grupo homogéneo

Predicción	Positivos Verdaderos (PV)	Falsos Positivos (FP)
	Falsos Negativos (FN)	Negativos Verdaderos (TN)
	Clase real	

Figura C.3: Matriz de confusión clasificación binaria

fácilmente diferenciables del resto de los grupos. En el análisis de conglomerados se pueden encontrar dos tipos principales de algoritmos (138):

1. Algoritmos jerárquicos. Este tipo de algoritmos buscan agrupar los clústers para formar uno nuevo, o bien, dividir algún clúster existente en otros dos (138). La jerarquía de los clústers es comúnmente representada mediante dendogramas. Estos algoritmos a su vez se dividen en dos tipos principales (138),(139):
 - Aglomerativos (bottom-up): se consideran algoritmos ascendentes, en los que cada observación conforma un clúster inicial, en los que dos o más clústers con la mayor similitud se combinan recursivamente (140).
 - Divisivos (top-down): también se conocen como disociativos o descendentes, en los que el análisis inicial considera un clúster conformado por la totalidad de las observaciones, mismo que se va dividiendo o separando en sub-grupos de forma recursiva (140).

Dentro de las ventajas de los algoritmos jerárquicos se encuentra, (140):

- Flexibilidad al leer el nivel de granularidad.
- Fácil manejo de cualquier forma de similitud o distancia.
- Es aplicable a cualquier tipo de atributo.

Dentro de las desventajas se pueden mencionar (140):

- La selección del criterio de finalización adecuado.
- La mayoría de los algoritmos jerárquicos no analizan los clústers una vez que son conformados.

2. Algoritmos particionales: Los algoritmos no-jerárquicos o particionales, identifican una partición o agrupamiento inicial, mismo que se va reajustando hasta obtener un número dado

de clústers o bien hasta que se cumpla con una función objetivo (138),(139). k -means, es uno de los algoritmos particionales mas utilizado debido a su simplicidad y a la eficiencia en el cálculo (139),(141).

C.1.2.1. k -means clustering

El algoritmo k -means es una de las herramientas de clusterización más empleadas en aplicaciones científicas e industriales (140). El algoritmo comienza con la división del conjunto total de datos en k grupos C_j definidos por el analista con base en su experiencia o en datos históricos. Posteriormente se obtienen los centroides de cada grupo. Se obtiene la similitud de cada observación con cada uno de los grupos iniciales, y estos son asignados al grupo con el que presenten una mayor afinidad (140), (138). Existen diversas métricas para obtener de manera objetiva la similitud entre los elementos de un conjunto de datos y los centroides de los grupos, tales como las distancias Euclidiana, Manhattan y Mahalanobis. Una vez que los objetos son asignados a su nuevo clúster, se calculan los centroides de cada grupo, y una nueva iteración se ejecuta con los centroides actualizados. El proceso se detiene cuando se minimiza el error cuadrático medio de las diferencias entre los centroides μ_k de cada clúster y los objetos x_i , asignados a cada clúster, de acuerdo a la ecuación C.38 (138).

$$J(C) = \sum_{x_i \in C_k} \|x_i - \mu_k\|^2 \tag{C.38}$$

donde k representa el numero de clústers. La función objetivo se denota por C.39 , que representa la suma del error cuadrático medio de todos los clústers (138):

$$J(C) = \sum_{k=1}^K \sum_{x_i \in C_k} \|x_i - \mu_k\|^2 \tag{C.39}$$

El pseudo-código del algoritmo se muestra en el Algoritmo 8 (6).

Algoritmo 8: Algoritmo k-means (6)

Datos: k-Means (\mathbf{D}, k, E)

- 1 $t = 0$ Inicialización aleatoria de k centroides: $\mu_1^t, \mu_2^t, \dots, \mu_k^t \in R^d$
 - 2 **repetir**
 - 3 $t \leftarrow t + 1$ $C_i \leftarrow 0$ for all $i = 1, \dots, k$ Asignación de clúster **para cada** $x_j \in \mathbf{D}$ **hacer**
 - 4 $i^* \leftarrow \operatorname{argmin}_i \|x_j - \mu_i^{t-1}\|^2$ $C_{i^*} \leftarrow C_{i^*} \cup x_j$; /* Asignar x_j al centroide más cercano */
 - 5 Actualización de los centroides **para cada** $i = 1, \dots, k$ **hacer**
 - 6 $\mu_i^t \leftarrow \frac{1}{|C_i|} \sum_{x_j \in C_i} x_j$
 - 7 **hasta que** $\sum_{i=1}^k \|\mu_i^t - \mu_i^{t-1}\|^2 \leq \epsilon$;
-

La principal limitación del algoritmo k -means es que la función objetivo puede ser minimizada solamente para un número específico de clústers, dado que el error cuadrático medio disminuye conforme se incrementa el número de clústers (k) (138).

Además, la confiabilidad del algoritmo se ve influenciada negativamente cuando se analizan datos multi-dimensionales, debido al uso de la distancia euclidiana (139). La fase de asignación del clúster tiene una complejidad computacional de $O(nkd)$, dado que se debe obtener la distancia de los n puntos a cada uno de los k clústers, lo que conlleva d operaciones en d dimensiones. Por otra parte, el re-cálculo de los centroides conlleva una complejidad computacional $O(nd)$ (n puntos con d dimensiones). Asumiendo la ejecución de t iteraciones, la complejidad computacional total del algoritmo es $O(tnkd)$ (6).

C.1.2.2. Algoritmo aglomerativo de clusterización jerárquica

El algoritmo aglomerativo puede ser definido formalmente como sigue(6):

Dado un conjunto de clusters $C = C_1, C_2, \dots, C_m$, es posible encontrar el par de clústers C_i y C_j más cercanos y combinarlos en un nuevo clúster $C_{ij} = C_i \cup C_j$. Posteriormente, el conjunto de clústers es actualizado, eliminando los clústers C_i y C_j e incluyendo el nuevo clúster C_{ij} . El proceso se repite hasta que el conjunto de clústers C , contenga solamente un clúster. Debido a que el número de clústers disminuye en uno en cada paso, el proceso resulta en una secuencia de n clústers anidados. El pseudocódigo de este algoritmo se presenta en el Algoritmo 9.

Algoritmo 9: Algoritmo aglomerativo jerárquico (6)

Datos: Algoritmo jerárquico aglomerativo (\mathbf{D}, k)

```

1  $C \leftarrow \{C_i = \{\mathbf{X}_i\} | \mathbf{x}_i \in \mathbf{D}\}$ ; /* Cada punto es un clúster separado */
2  $\Delta \leftarrow \{\|\mathbf{x}_i - \mathbf{x}_j\| : \mathbf{x}_i, \mathbf{x}_j \in \mathbf{D}\}$ ; /* Cálculo de la matriz de distancias */
3 repetir
4   Encontrar el par de clústers más cercanos  $C_i, C_j \in C$   $C_{ij} \leftarrow C_i \cup C_j$ ; /* Combinar los
   clústers */
5    $C \leftarrow (C / \{C_i, C_j\}) \cup \{C_{ij}\}$ ; /* Actualizar los clústers */
6   Actualizar la matriz de distancia  $\Delta$  con el nuevo clúster
7 hasta que  $|C| = k$ ;
```

El algoritmo aglomerativo Ward's se basa en el criterio de la mínima suma de cuadrados. La medida de similitud que emplea este algoritmo consiste en la distancia mínima entre los objetos y los centroides de cada grupo (C.38 y C.39), (142). El algoritmo inicia con n subconjuntos de un elemento (143). En cada iteración posterior, se combinan los dos clústers que generen el menor incremento en el valor total de la suma de cuadrados de las diferencias, dentro de cada clúster, de

cada individuo al centroide del clúster (C.40) (143).

$$E = \sum_{k=1}^h E_k \quad (\text{C.40})$$

$$E_k = \sum_{i=1}^{n_k} \sum_{j=1}^n (x_{ij}^k - m_j^k)^2 = \sum_{i=1}^{n_k} \sum_{j=1}^n (x_{ij}^k)^2 - n_k \sum_{j=1}^n (m_j^k)^2 \quad (\text{C.41})$$

donde E es la suma de cuadrados de los errores para los h clústers, E_k es la suma de cuadrados de los errores del clúster k , es decir, el cuadrado de la distancia euclídeana entre cada individuo del clúster k a su centroide C.41, m^k es el centroide del clúster k , con componentes m_j^k , x_{ij}^k es el valor de la j -ésima variable sobre el i -ésimo individuo del k -ésimo clúster, suponiendo que dicho clúster posee n_k individuos. La medida de Ward's empleada en este tipo de algoritmo aglomerativo C.42, pondera la distancia cuadrada entre la media y la media armónica del tamaño del clúster, donde la media armónica de los tamaños de clúster n_1 y n_2 está dada por $\frac{2}{\frac{1}{n_1} + \frac{1}{n_2}} = \frac{2n_1n_2}{n_1+n_2}$ (6).

$$\delta(C_i, C_j) = SSE_{ij} = \left(\frac{n_i n_j}{n_i + n_j} \right) \| \boldsymbol{\mu}_i - \boldsymbol{\mu}_j \|^2 \quad (\text{C.42})$$

C.1.2.3. Análisis de Componentes Principales

El objetivo primordial del Análisis de Componentes Principales (ACP) es la reducción de la dimensionalidad de un conjunto de datos conformado por múltiples variables (136). ACP es una transformación lineal que convierte el conjunto de datos en un nuevo espacio dimensional tal que en el nuevo conjunto de variables no-correlacionadas son funciones lineales del conjunto original de datos (119). ACP es considerada una técnica de reducción/extracción de características que determina el espacio r -dimensional que mejor captura la variabilidad del conjunto de datos inicial (6). En la mayoría de los análisis estadísticos que emplean el ACP, el objetivo principal es determinar el número de componentes, r , que representen la mejor aproximación al conjunto de datos inicial \mathbf{D} (6). Una vez calculados los principales componentes (PCs) de un conjunto de datos dado, es posible determinar a los individuos extremos

C.1.2.4. Evaluación del agrupamiento

El objetivo del análisis de clústers es detectar los patrones naturales en un conjunto de datos. Existen tres criterios para determinar la eficiencia del agrupamiento: la separación física (variabilidad inter-clústers), la conexión y la compactación (variabilidad intra-clúster), mientras que la conexión asume que datos vecinos deben pertenecer al mismo clúster o grupo (123). La separación consiste en determinar la diferencia entre los valores centrales de un clúster, mientras que la compactación permite conocer el grado de similitud entre los elementos de cada grupo. A mayor

compactación de los clústers y mayor separación entre clústers, mejores resultados se obtendrán en el agrupamiento (144). Algunos índices comúnmente utilizados en la literatura son el índice Dunn(DI), el índice Davies-Bouldin (145), el índice Calinski-Harabaz (146) y el índice Silueta (147).

■ Índice Dunn

El índice Dunn (Eq. C.43) es de gran costo computacional ($O(n)^2$), además de presentar un alto grado de sensibilidad al ruido (139). El valor óptimo de k (relacionado a la compactación) se determina por la distancia del vecino mas cercano, mientras que la separación se obtiene mediante el máximo diámetro del clúster (148):

$$DI_x = \min_{i=1,\dots,k} \left\{ \min_{j=1+1,\dots,k} \left(\frac{diss(c_i, c_j)}{\max_{m=1,\dots,k} diam(c_m)} \right) \right\} \quad (C.43)$$

donde $diss(c_i, c_j) = \min_{x \in c_i, y \in c_j} d(x, y)$ representa la disimilitud entre los clústers c_i y c_j (compactación) y $diam(C) = \max_{x, y \in C} d(x, y)$ es la dispersión inter-clusters (separación) (139). Valores grandes del índice de Dunn, indican una mayor compactación y separación de los clústers (139).

■ Índice Calinski-Harabaz

El índice Calinski-Harabaz (Eq. C.44) relaciona la variabilidad entre clústers y la variabilidad dentro de cada clúster(146). La variabilidad de cada cluster se determina mediante la distancia que existe entre los elementos del clúster y el centroide. La variabilidad entre clústers es obtenida mediante la distancia entre los centroides de cada grupo y el centroide global. Valores altos del índice Calinski-Harabaz representan una mejor partición del conjunto de datos inicial (148).

$$CHI_k = \frac{BCSM}{k-1} \cdot \frac{n-k}{WCSM} \quad (C.44)$$

■ Índice Davies-Bouldin

El índice Davies-Bouldin determina el nivel de separación y la compactación de los subconjuntos mediante la ecuación (Eq. C.45), donde $diam(c_i) = \sqrt{\frac{1}{n} \sum_{x \in c_i} d(x, z_i)^2}$, z_i representa el centro del clúster c_i , y n_i el número de objetos en el clúster c_i (139), (145). Valores pequeños del índice Davies-Bouldin representan una mejor división del conjunto de datos (148).

$$DBI_k = \frac{1}{k} \sum_{i=1}^k \max_{\{j=1,\dots,k, i \neq j\}} \left\{ \frac{diam(c_i) + diam(c_j)}{d(z_i, z_j)} \right\} \quad (C.45)$$

■ Índice Silueta

El índice Silueta se obtiene mediante la Eq. C.46, donde n es el total de puntos u objetos, a_i es la distancia promedio entre cada punto del cluster i y todos los puntos restantes del clúster, y b_i es la distancia promedio mínima entre el punto i y los puntos que no pertenecen al clúster (139), (147). Se recomienda seleccionar las particiones con valores altos del índice Silueta (148).

$$SI_k = \frac{1}{n} \sum_{i=1}^k \frac{(b_i - a_i)}{\max a_i, b_i} \quad (\text{C.46})$$

C.1.3. Técnicas de reducción de la dimensionalidad

En la actualidad, muchas disciplinas requieren del análisis de conjuntos de datos de gran dimensionalidad, por lo que para interpretarlos es necesario reducir drásticamente su dimensionalidad, reduciendo al mínimo la pérdida de información. Para lo anterior, se han desarrollado algunas técnicas, sin embargo, el Análisis de Componentes Principales(ACP) es una de las primeras y más utilizadas (119). El ACP es una técnica de aprendizaje no supervisado que permite realizar una reducción de dimensionalidad, identificando las r -dimensiones que capturan la mayor cantidad de la variabilidad de los datos, así como la extracción de características y la visualización de los datos (119). Existen dos definiciones comunes de APC. La primera de ellas lo considera una proyección ortogonal de los datos en un espacio lineal de menor dimensionalidad, comúnmente conocido como *subespacio principal*, tal que la varianza de los datos proyectada sea maximizada (149). La segunda lo define como la proyección lineal que minimiza el costo promedio de proyección, denotada como la distancia cuadrada media entre los puntos de datos y sus proyecciones (149).

- ACP para maximizar la varianza

La técnica ACP general más sencilla considera un valor de $r = 1$, es decir, el espacio unidimensional o línea \mathbf{u} que mejor se aproxima a \mathbf{D} en términos de varianza de los puntos proyectados. Se asume que \mathbf{u} tiene magnitud $\|\mathbf{u}\|^2 = \mathbf{u}^T \mathbf{u} = 1$, y que la matriz de datos \mathbf{D} es una matriz centrada mediante la sustracción de la media μ (6):

$$\bar{\mathbf{D}} = \mathbf{D} - \mathbf{1} \cdot \mu^T \quad (\text{C.47})$$

donde $\bar{\mathbf{D}}$ es la matriz de datos centrados con media $\text{mathbf{1}}^T \bar{\mathbf{D}} \mathbf{1} = 0$ La proyección del punto centrado $\mathbf{x}_i \in \bar{\mathbf{D}}$ en el vector \mathbf{u} está dada por:

$$\mathbf{x}'_i = \left(\frac{\mathbf{u}^T \bar{\mathbf{x}}_i}{\mathbf{u}^T \mathbf{u}} \right) \mathbf{u} = (\mathbf{u}^T \bar{\mathbf{x}}_i) \mathbf{u} = a_i \mathbf{u} \quad (\text{C.48})$$

donde $a_i = \mathbf{u}^T \bar{\mathbf{x}}_i$ es un escalar de proyección o ajuste de \mathbf{x}_i en \mathbf{u} . a_i también es llamado

punto proyectado. La media de un punto proyectado a_i es cero. Es necesario seleccionar la dirección \mathbf{u} de tal forma que la varianza de los puntos proyectados sea maximizada. La varianza proyectada en \mathbf{u} está dada por

$$\sigma_{\mathbf{u}}^2 = \mathbf{u}^T \Sigma \mathbf{u} \quad (\text{C.49})$$

donde Σ es la matriz de covarianzas de la muestra para los datos centrados $\bar{\mathbf{D}}_1$. Para maximizar la varianza proyectada, es necesario resolver el problema de optimización de $\sigma_{\mathbf{u}}^2$ con restricción $\mathbf{u}^T \mathbf{u} = 1$, mediante multiplicadores de Lagrange:

$$\underset{\mathbf{u}}{\text{máx}} J(\mathbf{u}) = \mathbf{u}^T \Sigma \mathbf{u} - \alpha(\mathbf{u}^T \mathbf{u} - 1) \quad (\text{C.50})$$

al derivar $J(\mathbf{u})$ con respecto a \mathbf{u}

$$\Sigma \mathbf{u} = \alpha \mathbf{u} \quad (\text{C.51})$$

Lo anterior implica que α es un eigenvalor de la matriz de covarianza Σ , asociado a un eigenvector \mathbf{u} . Para maximizar la varianza proyectada $\sigma_{\mathbf{u}}^2$ es necesario seleccionar el valor máximo de los eigenvalores de Σ . En otras palabras, el eigenvector dominante, también llamado *primer componente principal*, \mathbf{u}_1 especifica la dirección de la mayor parte de la varianza $\mathbf{u} = \mathbf{u}_1$. Además, el máximo eigenvalue λ_1 define la varianza proyectada $\sigma_{\mathbf{u}}^2 = \alpha = \lambda_1$

En el caso de la obtención mejor aproximación r -dimensional de \mathbf{D} , donde $2 < r \leq d$, es necesario obtener los eigenvalores de Σ . Debido a que Σ es semidefinida positivamente, sus eigenvalores deben ser todos no-negativos, y pueden ordenarse de forma descendente como sigue

$$\lambda_1 \geq \lambda_2 \geq \dots \lambda_r \geq \lambda_{r+1}, \dots \geq \lambda_d \geq 0 \quad (\text{C.52})$$

Se seleccionan los r eigenvalores más altos y sus correspondientes eigenvectores para conformar la mejor aproximación r -dimensional al conjunto de datos original \mathbf{D} . El pseudocódigo del

algoritmo ACP se presenta en 10.

Algoritmo 10: Algoritmo ACP (6)

Datos: PCA (\mathbf{D}, α)

```

1  $\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$ ; /* Calcular la media */
2  $\bar{\mathbf{D}} = \mathbf{D} - \mathbf{1} \cdot \bar{\mathbf{x}}^T$ ; /* Centrar los datos */
3  $\Sigma = \frac{1}{n} (\bar{\mathbf{D}}^T \bar{\mathbf{D}})$ ; /* Calcular la matriz de covarianzas */
4  $(\lambda_1, \lambda_2, \dots, \lambda_d) = \text{eigenvalores}(\Sigma)$ ; /* Calcular los eigenvalores */
5  $\mathbf{U} = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d) = \text{eigenvalores}(\Sigma)$ ; /* Calcular los eigenvectores */
6  $f(r) = \frac{\sum_{i=1}^r \lambda_i}{\sum_{i=1}^d \lambda_i}$ , para toda  $r = 1, 2, \dots, d$ ; /* Proporción de la varianza total */
7 Seleccionar el valor de  $r$  más pequeño, tal que  $f(r) \geq \alpha$ ; /* Seleccionar la
   dimensionalidad */
8  $\mathbf{U}_r = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_r)$ ; /* Reducción de la base */
9  $\mathbf{A} = \{\mathbf{a}_i | \mathbf{a}_i = \mathbf{U} - r^T \mathbf{x} \text{ para } i = 1, 2, \dots, n\}$ ; /* Reducir la dimensionalidad del
   conjunto de datos */
```

■ Geometría de ACP

Partiendo de que cada componente principal \mathbf{u}_i le corresponde un eigenvector de la matriz de covarianzas Σ , es decir(6):

$$\Sigma \mathbf{U} = \mathbf{U} \Lambda \quad (\text{C.53})$$

Multiplicando C.53 por $\mathbf{U}^{-1} = \mathbf{U}^T$ se tiene

$$\Sigma = \mathbf{U} \Lambda \mathbf{U}^T \quad (\text{C.54})$$

que es denominada *eigen-descomposición* de Σ , dado que:

$$\Sigma = \mathbf{U} \Lambda \mathbf{U}^T = \lambda_1 \mathbf{u}_1 \mathbf{u}_1^T + \lambda_2 \mathbf{u}_2 \mathbf{u}_2^T + \dots + \lambda_d \mathbf{u}_d \mathbf{u}_d^T = \sum_{i=1}^d \lambda_i \mathbf{u}_i \mathbf{u}_i^T \quad (\text{C.55})$$

Además, asumiendo que Σ es invertible y no singular, se tiene que:

$$\Sigma^{-1} = (\mathbf{U} \Lambda \mathbf{U}^T)^{-1} = \mathbf{U} \Lambda^{-1} \mathbf{U}^T \quad (\text{C.56})$$

Considerando la ecuación

$$\mathbf{x}^T \Sigma^{-1} \mathbf{x} = 1 \quad (\text{C.57})$$

que define una elipsoide de d -dimensiones, que los eigenvectores \mathbf{u}_i de Σ (los principales

componentes) definen la dirección de los ejes principales de la elipsoide, y que la raíz cuadrada de los eigenvalores ($\sqrt{\lambda_i}$) proporcionan la longitud de los semi-ejes. Sustituyendo C.56 en C.57, y empleando el hecho de que $\mathbf{x} = \mathbf{U}\mathbf{a}$ donde $\mathbf{a} = (a_1, a_2, \dots, a_d)^T$ representa las coordenadas de \mathbf{x} en la nueva base, se obtiene

$$\sum_{i=1}^d \frac{a_i^2}{\lambda_i} = 1 \tag{C.58}$$

que es la ecuación de la elipse con centro en el origen, y longitud de los semiejes $\sqrt{\lambda_i}$. $\mathbf{x}^T \Sigma^{-1} \mathbf{x} = 1$ define una elipsoide de d -dimensiones, donde la longitud de los semi-ejes es igual a las desviaciones estándar ($\sqrt{\lambda_i}$) de cada eje. De igual manera, la ecuación $\mathbf{x}^T \Sigma^{-1} \mathbf{x} = s$, para diferentes valores del escalar s , representa elipsoides concéntricas.

Dimensiones antropométricas de los somatotipos

D.1. Casos extremos: ACP

DA	Hombres				Mujeres			
	LM	LP	AP	DAM	LM	LP	AP	DAM
Caso 1	21	12.2	9.6	57	18.4	11.5	8.4	52
Caso 2	18.8	11.1	9.8	43	16.7	9.9	8.8	40
Caso 3	16.2	9.4	7.8	40	15.6	8.7	7.1	40
Caso 4	18.9	10.2	7.8	52	17.8	10.4	7	48
Caso 5	18.3	11.5	8.1	42	17.1	9.2	8.2	51
Caso 6	18.1	10	9.1	53	17.6	10	7.3	39
Caso 7	18.8	10.7	8.1	43	16.4	9.2	6.8	43
Caso 8	18.8	11.2	9	44	15.7	9.3	7.1	42
Caso 9	16.9	10.2	8.2	38	17	9.9	7.6	40
Caso 10	20.1	12	9	47	16.6	9.7	7.3	39
Caso 11	18.1	10.3	8	45	16.7	9.7	7.1	42
Caso 12	20.2	11.5	9.4	48	17.4	9.7	7.5	47
Caso 13	20	11.1	8.5	50	16.6	9.8	7.4	43
Caso 14	19.5	10.6	8.7	47	17	9.5	7.2	44

Tabla D.1: Casos obtenidos mediante APC

D.2. Casos extremos: AA

k	Caso	LM	LP	AP	DAM
3	1	18.9	10.2	7.8	52
	2	20.6	12.2	9.9	53
	3	16.5	9.6	8.4	39
5	1	20.3	12.2	9.6	56
	2	20.3	11.6	8.5	47
	3	19.1	9.5	9	53
	4	16.9	9.7	8.5	39
	5	17.6	10.1	7.6	49
7	1	20.2	11.7	9.3	58
	2	17.2	9.3	9.1	41
	3	20	11.3	9.3	40
	4	18.6	12.8	9.1	50
	5	17.1	10	7.3	45
	6	16.9	8.8	8.1	48
	7	21.1	12	8.7	54
8	1	17.8	9.6	8.1	51
	2	19.7	11.5	10.1	46
	3	19.7	11	8.4	45
	4	16.4	10.7	9.5	46
	5	16.9	9.7	8	38
	6	19.1	10.2	9.6	55
	7	20.9	12.4	9.3	58
	8	18.8	11.6	8.6	43
12	1	17.2	10.4	7.2	46
	2	19.4	11.4	10.1	49
	3	16.2	9.6	8.6	39
	4	19.5	10.9	8.2	44
	5	20.9	12.4	9.3	58
	6	19.1	10.3	8.5	55
	7	19.6	12.0	9.6	44
	8	20.0	10.9	10.1	46
	9	17.9	10.4	8.3	37
	10	17.9	11.2	8.4	49
	11	16.8	8.8	8.1	43
	12	19.6	11.1	9.6	57

Tabla D.2: Casos obtenidos mediante AA para la población masculina

k	Caso	LM	LP	AP	DAM
3	Caso 1	16.6	9.1	7.1	45
	Caso 2	19.1	10.8	8.8	52
	Caso 3	16.1	9.5	8.1	37
5	Caso 1	16	9.5	8.2	41
	Caso 2	18.7	10.3	7.5	54
	Caso 3	18.2	10.1	8.1	40
	Caso 4	16.1	9.3	7	42
	Caso 5	18.8	11.2	8.4	51
8	Caso 1	17.5	10.8	7.1	45
	Caso 2	19.9	11.6	8.6	50
	Caso 3	17.3	9.7	7.2	34
	Caso 4	17.2	10.6	8.9	42
	Caso 5	18.2	8.9	7.4	50
	Caso 6	17.3	9.6	9.2	46
	Caso 7	15.6	8.7	7.1	40
	Caso 8	17.8	10.6	7.6	55
11	Caso 1	17.7	9.7	7.7	38
	Caso 2	17.8	8.8	8.1	45
	Caso 3	19.1	10.8	8.8	52
	Caso 4	17	10.2	7.7	44
	Caso 5	17.6	9.4	8	53
	Caso 6	18.6	10.7	7.5	49
	Caso 7	16.5	9.7	8	41
	Caso 8	18.3	9.6	7.6	45
	Caso 9	17.8	11.4	7.6	45
	Caso 10	15.7	8.8	7	41
	Caso 11	17.4	10.3	7.1	50

Tabla D.3: Casos obtenidos mediante AA para la población femenina

D.3. Casos distribuidos: k-means

k	Caso	LM	LP	AP	DAM
2	Caso 1	16.2	9.4	7.8	40
	Caso 2	21.2	12.6	9.7	53
3	Caso 1	21.2	12.6	9.7	53
	Caso 2	16.2	9.4	7.8	40
	Caso 3	19	11.2	7.6	44
4	Caso 1	16.2	9.4	7.8	40
	Caso 2	18.2	10.3	9.6	41
	Caso 3	20	11.5	7.9	54
	Caso 4	21.2	12.6	9.7	53
5	Caso 1	19	11.2	7.6	44
	Caso 2	21.2	12.6	9.7	53
	Caso 3	18.2	10.3	9.6	41
	Caso 4	16.2	9.4	7.8	40
	Caso 5	17.9	9.9	7.8	53
14	Caso 1	19.4	11.4	8.9	41
	Caso 2	17.3	9.7	8.6	51
	Caso 3	20.0	11.5	7.9	54
	Caso 4	19.0	11.2	7.6	44
	Caso 5	17.0	9.4	7.5	47
	Caso 6	16.2	9.4	7.8	40
	Caso 7	21.2	12.6	9.7	53
	Caso 8	19.4	11.2	9.8	58
	Caso 9	19.8	11.3	10.3	48
	Caso 10	20.0	12.6	9.1	49
	Caso 11	17.6	10.2	9.0	41
	Caso 12	17.9	10.4	8.3	37
	Caso 13	18.8	11.1	9.8	43
	Caso 14	19.0	10.7	8.2	56

Tabla D.4: Casos obtenidos mediante el algoritmo k-means para la población masculino

k	Caso	LM	LP	AP	DAM
2	Caso 1	19.9	11.6	8.6	50
	Caso 2	15.4	8.6	8.2	41
3	Caso 1	19.9	11.6	8.6	50
	Caso 2	18.6	9.7	7	53
	Caso 3	15.4	8.6	8.2	41
4	Caso 1	18.6	9.7	7	53
	Caso 2	15.6	8.7	7.1	40
	Caso 3	16.7	9.9	8.8	40
	Caso 4	19.9	11.6	8.6	50
5	Caso 1	16.7	8.8	7.4	50
	Caso 2	15.6	8.7	7.1	40
	Caso 3	19.9	11.6	8.6	50
	Caso 4	16.1	9.5	8.1	37
	Caso 5	18.7	11.3	7.4	46
14	Caso 1	17.5	10.8	7.1	45
	Caso 2	15.4	8.6	8.2	41
	Caso 3	18.3	11.2	9.1	43
	Caso 4	19.9	11.6	8.6	50
	Caso 5	16.1	9.5	8.1	37
	Caso 6	16.6	9.0	6.6	42
	Caso 7	18.0	10.5	7.9	41
	Caso 8	16.7	8.8	7.4	50
	Caso 9	16.6	9.2	7.7	42
	Caso 10	18.7	10.3	7.5	54
	Caso 11	18.7	11.3	7.4	46
	Caso 12	17.3	9.7	7.2	34
	Caso 13	19.1	10.8	8.8	56
	Caso 14	17.3	9.6	9.2	46

Tabla D.5: Casos obtenidos mediante el algoritmo k-means para la poblaci3n femenina

D.4. Casos distribuidos: Ward

k	Caso	LM	LP	AP	DAM
2	Caso 1	16.2	9.4	7.8	40
	Caso 2	21.2	12.6	9.7	53
3	Caso 1	21.2	12.6	9.7	53
	Caso 2	19.6	12	9.6	44
	Caso 3	16.2	9.4	7.8	40
4	Caso 1	19.6	12	9.6	44
	Caso 2	19	11.2	7.6	44
	Caso 3	21.2	12.6	9.7	53
	Caso 4	16.2	9.4	7.8	40
6	Caso 1	18.2	10.1	7.3	47
	Caso 2	16.2	9.4	7.8	40
	Caso 3	19	11.2	7.6	44
	Caso 4	17.9	9.7	8.8	53
	Caso 5	19.6	12	9.6	44
	Caso 6	21.2	12.6	9.7	53
14	Caso 1	16.2	9.4	7.8	40
	Caso 2	16.2	9.6	8.6	39
	Caso 3	19.2	10.6	8.8	57
	Caso 4	17.9	9.7	8.8	53
	Caso 5	18.3	10.8	8.2	39
	Caso 6	18.2	10.1	7.3	47
	Caso 7	20.1	12.0	9.6	60
	Caso 8	19.7	11.1	8.4	57
	Caso 9	16.7	9.3	8.6	49
	Caso 10	21.1	12.0	8.7	54
	Caso 11	17.7	10.0	9.6	44
	Caso 12	19.6	12.0	9.6	44
	Caso 13	21.2	12.6	9.7	53
	Caso 14	19.0	11.2	7.6	44

Tabla D.6: Casos obtenidos mediante el algoritmo Ward para la población masculina

k	Caso	LM	LP	AP	DAM
2	Caso 1	19.9	11.6	8.6	50
	Caso 2	15.4	8.6	8.2	41
3	Caso 1	15.4	8.6	8.2	41
	Caso 2	17.3	9.6	9.2	46
	Caso 3	19.9	11.6	8.6	50
4	Caso 1	18.6	9.7	7	53
	Caso 2	17.3	9.6	9.2	46
	Caso 3	15.4	8.6	8.2	41
	Caso 4	19.9	11.6	8.6	50
5	Caso 1	17.3	9.7	7.2	34
	Caso 2	17.3	9.6	9.2	46
	Caso 3	18.6	9.7	7	53
	Caso 4	15.4	8.6	8.2	41
	Caso 5	19.9	11.6	8.6	50
14	Caso 1	17.5	10.8	7.1	45
	Caso 2	17.3	9.7	7.2	34
	Caso 3	18.2	9.7	8.5	51
	Caso 4	18.3	11.2	9.1	43
	Caso 5	17.8	10.4	7.0	48
	Caso 6	18.6	9.7	7.0	53
	Caso 7	18.2	10.6	7.9	46
	Caso 8	15.8	9.8	7.2	38
	Caso 9	16.6	9.0	6.6	42
	Caso 10	19.2	11.1	8.4	55
	Caso 11	19.9	11.6	8.6	50
	Caso 12	17.3	9.6	9.2	46
	Caso 13	16.7	8.8	7.4	50
	Caso 14	15.4	8.6	8.2	41

Tabla D.7: Casos obtenidos mediante el algoritmo Ward para la poblaci3n femenina

Bibliografía

- [1] J. Harrison and L. Dawson, “Occupational health: Meeting the challenges of the next 20 years,” *Safety and Health at Work*, vol. 7, no. 2, pp. 143–149, 2016. [7](#), [8](#)
- [2] A. Baldominos, A. Cervantes, Y. Saez, and P. Isasi, “A comparison of machine learning and deep learning techniques for activity recognition using mobile devices,” *Sensors*, vol. 19, no. 3, 2019. [28](#), [29](#), [52](#)
- [3] J. R. Napier, “The prehensile movements of the human hand,” *Jnl. Bone Jt. Surg.*, vol. 38, no. 4, pp. 902–913, 1956. [32](#), [33](#)
- [4] G. Zehner, R. Meindl, and J. Hudson, “A multivariate anthropometric method for crew station design,” p. 43, 03 1993. [15](#), [16](#), [94](#)
- [5] B. B. K. T. R. M. J. S. L. J. H. H. P. D. Guan J, Hsiao H, “U.s. truck driver anthropometric study and multivariate anthropometric models for cab designs,” *Hum Factors*, vol. 54, no. 5, pp. 849–871, 2012. [16](#), [95](#)
- [6] J. Mohammed J. Zaki, Wagner Meira, *Data mining and machine learning : fundamental concepts and algorithms*. Cambridge, United Kingdom ; New York, NY: Cambridge University Press, 2020. [100](#), [101](#), [102](#), [105](#), [106](#), [109](#), [110](#), [112](#), [115](#), [116](#), [117](#), [119](#), [121](#)
- [7] G. C. David, “Ergonomic methods for assessing exposure to risk factors for work-related musculoskeletal disorders,” *Occupational Medicine*, vol. 55, pp. 190–199, 05 2005. [XIII](#), [10](#), [12](#), [13](#), [14](#)
- [8] S. Rodgers, “A functional job analysis technique,” *Occupational medicine (Philadelphia, Pa.)*, vol. 7, no. 4, p. 679—711, 1992. [60](#), [61](#)
- [9] S. Rodgers, “Muscle fatigue assessment: Functional job analysis technique,” 2004. [60](#), [61](#)

- [10] X. Li, S. Han, M. Gül, M. A. Hussein, , and M. E. Rich, “3d visualization-based ergonomic risk assessment and work modification framework and its validation for a lifting task,” *Journal of Construction Engineering and Management*, vol. 144, no. 1, pp. 1–13, 2018. [1](#), [3](#), [13](#), [20](#)
- [11] S. Niu, “Ergonomics and occupational safety and health: An ilo perspective,” *Applied Ergonomics*, vol. 41, no. 6, pp. 744–753, 2010. Special Section: Selection of papers from IEA 2009. [2](#), [9](#), [10](#), [11](#), [17](#)
- [12] O. I. del Trabajo, *S. Social, Día Mundial de la Seguridad y Salud en el Trabajo*. Suiza: Organización Internacional del Trabajo, primera ed., 2013. [2](#)
- [13] J. A. Diego-Mas and J. Alcaide-Marzal, “Using kinectTM sensor in observational methods for assessing postures at work,” *Appl Ergon*, vol. 45, no. 4, pp. 976–985, 2014. [3](#), [5](#), [9](#), [20](#), [24](#), [63](#)
- [14] L. Burdorf A, “Comparison of methods for the assessment of postural load on the back,” *Scandinavian Journal of Work and Environmental Health*, vol. 17, no. 6, pp. 425–429, 1991. [3](#)
- [15] M. Bortolini, M. Faccio, M. Gamberi, and F. Pilati, “Motion analysis system (mas) for production and ergonomics assessment in the manufacturing processes,” *Computers and Industrial Engineering*, vol. 139, p. 105485, 2020. [3](#)
- [16] Y.-C. Wu, T.-Y. Wu, P. Taele, B. Wang, J.-Y. Liu, P.-s. Ku, P.-E. Lai, and M. Y. Chen, “Activeergo: Automatic and personalized ergonomics using self-actuating furniture,” in *Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems*, CHI ’18, (New York, NY, USA), p. 1–8, Association for Computing Machinery, 2018. [3](#)
- [17] T. D. Nguyen, C. Bloch, and J. Krüger, “The Working Posture Controller: Automated Adaptation of the Work Piece Pose to Enable a Natural Working Posture,” *Procedia CIRP*, vol. 44, pp. 14–19, 2016. [3](#)
- [18] X. Zhu and K. F. Li, “Real-time motion capture: An overview,” in *2016 10th International Conference on Complex, Intelligent, and Software Intensive Systems (CISIS)*, pp. 522–525, 2016. [3](#)
- [19] F. Sánchez Margallo, F. Pérez-Duarte, J. A. Sánchez-Margallo, A. Azevedo, and I. Díaz-Güemes Martín-Portugués, “Use of a motion capture data glove for hand and wrist ergonomic analysis during laparoscopy,” 06 2014. [4](#), [27](#)
- [20] I. V. Grinyagin, E. V. Biryukova, and M. A. Maier, “Kinematic and dynamic synergies of human precision-grip movements,” *Journal of Neurophysiology*, vol. 94, no. 4, pp. 2284–2294, 2005. PMID: 15917316. [4](#), [27](#)

-
- [21] G. Tao, S. Sun, S. Huang, Z. Huang, and J. Wu, “Human modeling and real-time motion reconstruction for micro-sensor motion capture,” in *2011 IEEE International Conference on Virtual Environments, Human-Computer Interfaces and Measurement Systems Proceedings*, pp. 1–5, 2011. [4](#)
- [22] I. E. Association, “What is ergonomics?.” [8](#), [9](#)
- [23] M. Mengoni, M. Matteucci, and D. Raponi, “A multipath methodology to link ergonomics , safety and efficiency,” *Procedia Manuf*, vol. 11, no. June, pp. 1311–1318, 2017. [8](#), [12](#), [13](#)
- [24] L. Punnett and D. H. Wegman, “Work-related musculoskeletal disorders: the epidemiologic evidence and the debate,” *Journal of Electromyography and Kinesiology*, vol. 14, no. 1, pp. 13–23, 2004. [10](#)
- [25] T. R. Hales and B. P. Bernard, “Epidemiology of work-related musculoskeletal disorders,” *Orthopedic Clinics of North America*, vol. 27, no. 4, pp. 679–709, 1996. [10](#)
- [26] S. Al-Tuwaijri, I. Fedotov, I. Feitshans, M. Gifford, D. Gold, S. Machida, M. Nahmias, S. Niu, and G. Sandi, “Introductory report: Beyond death and injuries: The ilo’s role in promoting safe and healthy jobs,” in *XVIII World Congress on Safety and Health at Work*, 06 2008. [11](#)
- [27] J. Takala, “Introductory report: Decent work – safe work,” in *XVIIth World Congress on Safety and Health at Work*, 05 2005. [11](#)
- [28] A. Badri, B. Boudreau-Trudel, and A. S. Souissi, “Occupational health and safety in the industry 4.0 era: A cause for major concern?,” *Safety Science*, vol. 109, pp. 403–411, 2018. [12](#)
- [29] J. Tilmanne and N. d’Alessandro, “Motion machine: A new framework for motion capture signal feature prototyping,” in *2015 23rd European Signal Processing Conference (EUSIPCO)*, pp. 2401–2405, 2015. [13](#), [18](#)
- [30] Y. Yu, H. Li, X. Yang, L. Kong, X. Luo, and A. Y. Wong, “An automatic and non-invasive physical fatigue assessment method for construction workers,” *Automation in Construction*, vol. 103, pp. 1–12, 2019. [13](#)
- [31] I. Dianat, J. Molenbroek, and H. I. Castellucci, “A review of the methodology and applications of anthropometry in ergonomics and product design,” *Ergonomics*, vol. 61, no. 12, pp. 1696–1720, 2018. PMID: 30022717. [13](#)
- [32] K. M. Robinette and J. T. McConville, “An alternative to percentile models,” *SAE Transactions*, vol. 90, pp. 938–946, 1981. [13](#), [15](#), [93](#)

- [33] S. Pheasant and C. Haslegrave, *Bodyspace: Anthropometry, Ergonomics and the Design of Work*. 3rd ed. ed., 2006. [13](#), [15](#)
- [34] P. M. Garneau CJ, “A survey of anthropometry and physical accommodation in ergonomics curricula,” *Ergonomics*, vol. 59, no. 1, pp. 143–154, 2016. [13](#), [15](#)
- [35] Y.-C. Lin, M.-J. J. Wang, and E. M. Wang, “The comparisons of anthropometric characteristics among four peoples in east asia,” *Applied Ergonomics*, vol. 35, no. 2, pp. 173–178, 2004. [15](#)
- [36] K. Young, S. Margerum, A. Barr, M. A. Ferrer, and S. Rajulu, “Derivation of boundary manikins: A principal component analysis,” in *SAE Technical Paper*, SAE International, 06 2008. [15](#), [16](#)
- [37] K. Jung, O. Kwon, and H. You, “Development of the boundary zone method for generation of representative human models,” *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 53, no. 19, pp. 1472–1476, 2009. [15](#)
- [38] E. Brolin, D. Högberg, L. Hanson, and R. Örtengren, “Generation and evaluation of distributed cases by clustering of diverse anthropometric data,” *International Journal of Human Factors Modelling and Simulation*, vol. 5, no. 3, pp. 210–229, 2016. [15](#), [17](#)
- [39] I. Epifanio, G. Vinué, and S. Alemany, “Archetypal analysis: Contributions for estimating boundary cases in multivariate accommodation problem,” *Computers and Industrial Engineering*, vol. 64, no. 3, pp. 757–765, 2013. [15](#), [94](#), [95](#)
- [40] A. Bittner, F. A. Glenn, R. M. Harris, H. P. Iavecchia, and R. J. Wherry, “Cadre: A family of manikins for workstation design,” in *Trends in ergonomics/human factors* (S. S. Ashfour, ed.), vol. IV, pp. 733–740, 1987. [16](#)
- [41] J. Alvah C. Bittner, “A-cadre: Advanced family of manikins for workstation design,” *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 44, no. 38, pp. 774–777, 2000. [16](#)
- [42] E. A, S. B. VK, G. T, B. A, and P. V., “Crane cabins’ interior space multivariate anthropometric modeling,” *Work*, vol. 54, no. 9, pp. 557–50, 2018. [16](#)
- [43] D. Y. Biswal P, “Principal component analysis: The path ahead for aircrew-aircraft compatibility at the institute of aerospace medicine,” *Indian J Aerosp Med*, vol. 63, no. 1, pp. 8–15, 2019. [16](#)
- [44] O. OF, “Hand anthropometry survey of rural farm workers in southeastern nigeria,” *Ergonomics*, vol. 59, no. 4, pp. 603–611, 2016. [16](#)

-
- [45] L. M. Shahriar MM, Parvez MS, “A survey of hand anthropometry of bangladeshi agricultural farmworkers,” *Int J Ind Ergon*, vol. 78, no. 4, p. 1, 2020. [16](#)
- [46] M. SJ, M. AH, M. M, D. MH, B. M, and M. S, “Anthropometric hand dimensions in a population of iranian male workers in 2012,” *Int J Occup Saf Ergon*, vol. 22, no. 1, pp. 125–130, 2016. [16](#)
- [47] O.-T. O, M. B. L, H. J, and E. J, “Hand anthropometric study in northern colombia,” *Int J Occup Saf Ergon*, vol. 23, no. 4, pp. 471–480, 2017. [16](#)
- [48] Y. M. Jee SC, “An anthropometric survey of korean hand and hand shape types,” *Int J Ind Ergon*, vol. 53, no. 10, p. 1, 2016. [17](#)
- [49] S. D. Swami S, Kumar T, “Correlation of handedness with hand anthropometric measurements in haryanvi brahmins,” *J Anat Soc India*, vol. 64, no. 1, pp. 24–30, 2015. [17](#)
- [50] S. Verwulgen, D. Lacko, J. Vleugels, K. Vaes, F. Danckaers, G. De Bruyne, and T. Huysmans, “A new data structure and workflow for using 3d anthropometry in the design of wearable products,” *International Journal of Industrial Ergonomics*, vol. 64, pp. 108–117, 2018. [17](#)
- [51] B. Suhardi, A. Khairina, and F. Fahma, “Designing size of batik shirt for male college student in surakarta using anthropometric data (case study: Male college student of industrial engineering major in surakarta),” in *2016 2nd International Conference of Industrial, Mechanical, Electrical, and Chemical Engineering (ICIMECE)*, pp. 192–195, 2016. [17](#)
- [52] J. Niu, Z. Li, and S. Xu, “Comparisons of 3d shape clustering with different face area definitions,” in *Digital Human Modeling* (V. G. Duffy, ed.), (Berlin, Heidelberg), pp. 55–63, Springer Berlin Heidelberg, 2009. [17](#)
- [53] Y.-C. Lee, W.-Y. Chao, and M.-J. Wang, “Developing a new foot shape and size system for taiwanese females,” in *The 19th International Conference on Industrial Engineering and Engineering Management* (E. Qi, J. Shen, and R. Dou, eds.), (Berlin, Heidelberg), pp. 959–968, Springer Berlin Heidelberg, 2013. [17](#)
- [54] N. Zakaria, Jamil Salleh Mohd, N. Taib, Yong Yuan Tan, and Yap Bee Wah, “Using data mining technique to explore anthropometric data towards the development of sizing system,” in *2008 International Symposium on Information Technology*, vol. 2, pp. 1–7, 2008. [17](#)
- [55] M. V. Rao, S. Kumar, and G. N. Brahmam, “A study of the geographical clustering of districts in uttar pradesh using nutritional anthropometric data of preschool children,” *The Indian journal of medical researc*, vol. 173, no. 1, pp. 73–81, 2013. [17](#)
-

- [56] O. Abdali, H. Viktor, E. Paquet, and M. Rioux, “Exploring anthropometric data through cluster analysis,” in *SAE Technical Paper*, SAE International, 06 2004. [17](#)
- [57] A. Golabchi, S. Han, A. R. Fayek, and S. AbouRizk, “Stochastic modeling for assessment of human perception and motion sensing errors in ergonomic analysis,” *Journal of Computing in Civil Engineering*, vol. 31, no. 4, p. 04017010, 2017. [18](#), [20](#), [25](#)
- [58] A. Kubota, T. Iqbal, J. Shah, and L. Riek, “Activity recognition in manufacturing: The roles of motion capture and semg+inertial wearables in detecting fine vs. gross motion,” in *In Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, pp. 6533–6539, 05 2019. [18](#), [26](#), [27](#)
- [59] N. Vignais, M. Miezal, G. Bleser, K. Mura, D. Gorecky, and F. Marin, “Innovative system for real-time ergonomic feedback in industrial manufacturing,” *Applied Ergonomics*, vol. 44, no. 4, pp. 566–574, 2013. [18](#), [20](#), [24](#)
- [60] M. Yahya, J. Shah, K. Kadir, Z. Yusof, S. Khan, and A. Warsi, “Motion capture sensing techniques used in human upper limb motion: a review,” *Sensor Review*, vol. 39, no. 4, pp. 504–511, 2019. [18](#), [19](#), [21](#), [22](#)
- [61] M. Field, D. Stirling, F. Naghdy, and Z. Pan, “Motion capture in robotics review,” in *2009 IEEE International Conference on Control and Automation*, pp. 1697–1702, 2009. [18](#), [19](#), [21](#), [22](#), [23](#)
- [62] J. Dul and W. P. Neumann, “Ergonomics contributions to company strategies,” *Appl. Ergon.*, vol. 40, no. 4, pp. 745–752, 2009. [20](#)
- [63] I. Halim, “Usability study of integrated rula-kinect tm system for,” vol. 10, no. 8, pp. 175–184, 2018. [20](#)
- [64] C. E. Mgbemena, J. Oyekan, W. Hutabarat, S. Fletcher, Y. Xu, , and A. Tiwari, “Optimum kinect setup for real-time ergonomic risk assessment on the shop floor,” *Contemp. Ergon. Hum. Factors*, pp. 265–272, 2017. [20](#)
- [65] A. Patrizi, E. Pennestrì, and P. P. Valentini, “Comparison between low-cost marker-less and high-end marker-based motion capture systems for the computer-aided assessment of working ergonomics,” *Ergonomics*, vol. 59, no. 1, pp. 155–162, 2016. [20](#)
- [66] J. A. Diego-Mas, R. Poveda-Bautista, and D. Garzon-Leal, “Using rgb-d sensors and evolutionary algorithms for the optimization,” *Appl. Ergon.*, vol. 65, pp. 530–540, 2017. [20](#), [24](#)

-
- [67] G. Colombo, D. Regazzoni, and e. Rizzi, Caterina”, “Markerless motion capture integrated with human modeling for virtual ergonomics,” in *Digital Human Modeling and Applications in Health, Safety, Ergonomics, and Risk Management. Human Body Modeling and Ergonomics*, (Berlin, Heidelberg), pp. 314–323, Springer Berlin Heidelberg, 2013. [20](#)
- [68] V. M. Manghisi, A. E. Uva, M. Fiorentino, V. Bevilacqua, G. F. Trotta, and G. Monno, “Real time rula assessment using kinect v2 sensor,” *Appl. Ergon.*, vol. 65, pp. 481–491, 2017. [20](#)
- [69] P. Plantard, H. P. H. Shum, A. S. L. Pierres, , and F. Multon, “Validation of an ergonomic assessment method using kinect data in real workplace conditions,” *Appl. Ergon.*, vol. 65, pp. 562–569, 2017. [20](#)
- [70] P. Plantard, A. Muller, C. Pontonnier, G. Dumont, H. P. H. Shum, and F. Multon, “Inverse dynamics based on occlusion-resistant kinect data: Is it usable for ergonomics?,” *Int. J. Ind. Ergon*, vol. 61, pp. 71–80, 2017. [20](#)
- [71] P. Plantard, E. Auvinet, A. S. L. Pierres, and F. Multon, “Pose estimation with a kinect for ergonomic studies: Evaluation of the accuracy using a virtual mannequin,” *Sensors (Switzerland)*, vol. 15, no. 1, pp. 185–1803, 2015. [20](#)
- [72] X. Xu, M. Robertson, K. B. Chen, J. hua Lin, and R. W. McGorry, “Using the microsoft kinecttm to assess 3-d shoulder kinematics during computer use,” *Appl. Ergon.*, vol. 65, pp. 418–423, 2017. [20](#)
- [73] S. Moon, Y. Park, D. W. Ko, and I. H. Suh, “Multiple kinect sensor fusion for human skeleton tracking using kalman filtering,” *Int. J. Adv. Robot. Syst*, vol. 13, no. 2, pp. 1–10, 2016. [20](#)
- [74] O. D. Lara and M. A. Labrador, “A survey on human activity recognition using wearable sensors,” *IEEE Communications Surveys Tutorials*, vol. 15, no. 3, pp. 1192–1209, 2013. [20](#), [26](#), [85](#)
- [75] S. O. and H. C. D. I. D. Mark C. Schall Jr., Nathan B. Fethke, “Accuracy and repeatability of an inertial measurement unit system for field-based occupational studies,” *Ergonomics*, vol. 59, no. 4, pp. 591–602, 2016. [21](#)
- [76] S. Kim and M. A. Nussbaum, “Performance evaluation of a wearable inertial motion capture system for capturing physical exposures during manual material handling tasks,” pp. 1–13, 2013. [21](#)
- [77] A. N. Ruchay, K. A. Dorofeev, and V. I. Kolpakov, “Fusion of information from multiple kinect sensors,” vol. 42, no. 5, pp. 898–903, 2018. [21](#)

- [78] T. R. Waters, V. Putz-Anderson, and A. Garg, “Applications manual for the revised niosh lifting equation,” pp. 91–110, 1994. [21](#), [33](#)
- [79] D. Battini, A. Persona, and F. Sgarbossa, “Innovative real-time system to integrate ergonomic evaluations into warehouse design and management,” *Comput. Ind. Eng.*, vol. 77, pp. 1–10, 2014. [21](#), [25](#)
- [80] N. Vignais, F. Bernard, G. Touvenot, and J. C. Sagot, “Physical risk factors identification based on body sensor network combined to videotaping,” *Appl. Ergon.*, vol. 65, pp. 410–41, 2017. [21](#), [24](#)
- [81] N. Jarque-Bou, V. Gracia-Ibáñez, J. Sancho-Bru, M. Vergara, A. Pérez-González, and F. Andrés, “Using kinematic reduction for studying grasping postures. an application to power and precision grasp of cylinders,” *Applied Ergonomics*, vol. 56, pp. 52–61, 2016. [24](#)
- [82] L. Peppoloni, A. Filippeschi, E. Ruffaldi, and C. Avizzano, “A novel wearable system for the online assessment of risk for biomechanical load in repetitive efforts,” *International Journal of Industrial Ergonomics*, vol. 52, pp. 1–11, 2016. New Approaches and Interventions to Prevent Work Related Musculoskeletal Disorders. [24](#)
- [83] Z. Sedighi Maman, M. A. Alamdar Yazdi, L. A. Cavuoto, and F. M. Megahed, “A data-driven approach to modeling physical fatigue in the workplace using wearable sensors,” *Applied Ergonomics*, vol. 65, pp. 515–529, 2017. [24](#)
- [84] C. S. D. S. V. R. O. L. S. L. P. N. Tammana A, McKay C, “Load-embedded inertial measurement unit reveals lifting performance.,” *Appl. Ergon.*, vol. Jul, no. 70, pp. 68–76, 2018. [25](#)
- [85] F. GS, K. AS, K. I, C. CC, D. JT, and van Die.^{em} JH, “Continuous ambulatory hand force monitoring during manual materials handling using instrumented force shoes and an inertial motion capture suit,” *J Biomech.*, vol. 70, pp. 235–241, 2018. [25](#)
- [86] C. J, R. M, and R. DM, “Reproducibility analysis of upper limbs reachable workspace, and effects of acquisition protocol, sex and hand dominance.,” *J Biomech.*, vol. 68, pp. 58–64, 2018. [25](#)
- [87] G. Merino, L. da Silva, D. Mattos, B. Guimarães, and E. Merino, “Ergonomic evaluation of the musculoskeletal risks in a banana harvesting activity through qualitative and quantitative measures, with emphasis on motion capture (xsens) and emg,” *International Journal of Industrial Ergonomics*, vol. 69, pp. 80–89, 2019. [25](#)

-
- [88] T. K., Y. K., M. T., W. M., and K. H. Matsuda T., “Upper body position analysis of different experience level surgeons during laparoscopic suturing maneuvers using optical motion capture,” *The American Journal of Surgery*, vol. 217, no. 1, pp. 12–16, 2019. [25](#)
- [89] J. Wang, Y. Chen, S. Hao, X. Peng, and L. Hu, “Deep learning for sensor-based activity recognition: A survey,” *Pattern Recognition Letters*, vol. 119, pp. 3–11, 2019. Deep Learning for Pattern Recognition. [25](#)
- [90] H. F. Nweke, Y. W. Teh, M. A. Al-garadi, and U. R. Alo, “Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: State of the art and research challenges,” *Expert Systems with Applications*, vol. 105, pp. 233–261, 2018. [25](#)
- [91] Y. Xue, Z. Ju, K. Xiang, J. Chen, and H. Liu, “Multimodal human hand motion sensing and analysis—a review,” *IEEE Transactions on Cognitive and Developmental Systems*, vol. 11, no. 2, pp. 162–175, 2019. [26](#), [27](#)
- [92] R. Khusainov, D. Azzi, I. Achumba, and S. Bersch, “Real-time human ambulation, activity, and physiological monitoring: Taxonomy of issues, techniques, applications, challenges and limitations,” *Sensors (Basel, Switzerland)*, vol. 13, pp. 12852–902, 2013. [26](#), [40](#)
- [93] P. Koskimäki, Heli Siirtola, “Accelerometer vs. electromyogram in activity recognition,” *AD-CAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, vol. 5, no. 31, 2016. [26](#)
- [94] H. Junker, O. Amft, P. Lukowicz, and G. Tröster, “Gesture spotting with body-worn inertial sensors to detect user activities,” *Pattern Recognition*, vol. 41, no. 6, pp. 2010–2024, 2008. [27](#)
- [95] A. Moschetti, L. Fiorini, D. Esposito, P. Dario, and F. Cavallo, “Recognition of daily gestures with wearable inertial rings and bracelets,” *Sensors (Basel, Switzerland)*, vol. 16, no. 8, 2016. [27](#)
- [96] J. de Vries, A. van Ommeren, G. Prange-Lasonder, J. Rietman, and P. Veltink, “Detection of the intention to grasp during reach movements,” *Journal of Rehabilitation and Assistive Technologies Engineering*, 2018. [27](#)
- [97] M. J. Nathan DE, Johnson MJ, “Design and validation of low-cost assistive glove for hand assessment and therapy during activity of daily living-focused robotic stroke therapy,” *J Rehabil Res Dev*, vol. 46, no. 5, pp. 587–602, 2009. [27](#)
- [98] H. Chiu, S. Lin, F. Su, S. Wang, and H. Hsu, “The use of the motino analysis system for evaluation of loss of movement in the finger,” *The Journal of Hand Surgery: British European Volume*, vol. 25, no. 2, pp. 195–199, 2000. [27](#)
-

- [99] N. Oess, J. Wanek, and A. Curt, “Design and evaluation of a low-cost instrumented glove for hand function assessment,” *J NeuroEngineering Rehabil*, vol. 9, no. 2, 2012. [27](#)
- [100] P. Polygerinos, K. C. Galloway, E. Savage, M. Herman, K. O. Donnell, and C. J. Walsh, “Soft robotic glove for hand rehabilitation and task specific training,” *IEEE International Conference on Robotics and Automation (ICRA)*, Seattle, WA, pp. 2913–2919, 2015. [27](#)
- [101] B. Fang, F. Sun, H. Liu, and D. Guo, “A novel data glove using inertial and magnetic sensors for motion capture and robotic arm-hand teleoperation,” *Industrial Robot*, vol. 44, no. 2, pp. 155–165, 2017. [27](#)
- [102] Y. Choi and S. Yoo, K. and Kang, “Development of a low-cost wearable sensing glove with multiple inertial sensors and a light and fast orientation estimation algorithm,” *Supercomput*, vol. 74, pp. 3639–3652, 2018. [27](#), [33](#)
- [103] A. E. Frank, A. Kubota, and L. D. Riek, “Wearable activity recognition for robust human-robot teaming in safety-critical environments via hybrid neural networks,” in *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 449–454, 2019. [27](#), [40](#)
- [104] T. Feix, J. Romero, H. B. Schmiemayer, A. M. Dollar, and D. Kragic, “The grasp taxonomy of human grasp types,” *IEEE Transactions on Human-Machine Systems*, vol. 46, no. 1, pp. 66–77, 2016. [27](#), [32](#), [50](#)
- [105] A. Bulling, U. Blanke, and B. Schiele, “A tutorial on human activity recognition using body-worn inertial sensors,” *ACM Comput. Surv.*, vol. 46, Jan. 2014. [28](#), [29](#), [50](#)
- [106] D. Figo, P. Diniz, D. Ferreira, and J. M. P. Cardoso, “Preprocessing techniques for context recognition from accelerometer data,” *Pers Ubiquit Comput*, vol. 14, pp. 645–662, 2010. [29](#)
- [107] S. M, B. S, I. OD, S. H, and H. PJ, “Fusion of smartphone motion sensors for physical activity recognition,” *Sensors*, vol. 14, no. 6, pp. 10146–10176, 2014. [29](#), [30](#), [51](#)
- [108] H. Liu, “Exploring human hand capabilities into embedded multifingered object manipulation,” *IEEE Transactions on Industrial Informatics*, vol. 7, no. 3, pp. 389–398, 2011. [32](#)
- [109] J. B. G. S. Armstrong TJ, Foulke JA, “Investigation of cumulative trauma disorders in a poultry processing plant,” *Am Ind Hyg Assoc J*, vol. 43, no. 2, pp. 103–116, 1982. [33](#)
- [110] E. B. S. Martin-Brevet, N. Jarrassé, “Ttaxonomy based analysis of force exchanges during object grasping and manipulation,” *Plos One*, vol. 12, no. 5, pp. 1–23, 2017. [33](#)

-
- [111] H. G. Kortier and V. Sluiter, “Assessment of hand kinematics using inertial,” no. September, 2014. [33](#)
- [112] J. Domingo, M. V. Ibáñez, A. Simó, E. Dura, G. Ayala, and S. Alemany, “Expert systems with applications modeling of female human body shapes for apparel design based,” *Expert Syst. Appl.*, vol. 41, no. 14, pp. 6224–6234, 2014. [33](#)
- [113] N. O-larnnithipong and A. Barreto, “Gyroscope drift correction algorithm for inertial measurement unit used in hand motion tracking,” *2016 IEEE Sensors, Orlando, FL*, pp. 1–3, 2016. [38](#)
- [114] K. Papafotis and P. Sotiriadis, “Accelerometer and magnetometer joint calibration and axes alignment,” *Technologies*, vol. 8, no. 11, 2020. [38](#)
- [115] W. Sousa, E. Souto, J. Rodrigues, P. Sadarc, R. Jalali, and K. El-Khatib, “A comparative analysis of the impact of features on human activity recognition with smartphone sensors,” in *Proceedings of the 23rd Brazillian Symposium on Multimedia and the Web, WebMedia '17*, (New York, NY, USA), p. 397–404, Association for Computing Machinery, 2017. [40](#), [85](#)
- [116] *Evaluation of Job Demands*, ch. 2, pp. 99–190. John Wiley and Sons, Ltd, 2003. [60](#)
- [117] G. C. R. Douglas C. Montgomery, *Applied statistics and probability for engineers*. John Wiley and Sons, 2013. [63](#)
- [118] H. Hsiao, “Anthropometric procedures for protective equipment sizing and design,” *Human Factors*, vol. 55, no. 1, pp. 6–35, 2013. [93](#)
- [119] I. T. Jolliffe, *Principal Component Analysis*, vol. 30, ch. V, pp. 78–108. Springer-Verlag New York, Inc., 2nd. ed. ed., 2002. [93](#), [117](#), [119](#)
- [120] C. C. Gordon, T. Churchill, C. E. Clauser, B. Bradtmiller, J. T. McConville, I. Tebbetts, , and R. A. Walker, “Anthropometric survey of u.s. army personnel: Summary statistics, interim report for 1988,” tech. rep., OH: Anthropology Research Project Inc, Yellow Springs, 1989. [16](#), [93](#)
- [121] A. Cutler and L. Breiman, “Archetypal analysis,” *Technometrics*, vol. 36, no. 4, pp. 338–347, 1994. [94](#)
- [122] C. Yuan and H. Yang, “Research on k-value selection method of k-means clustering algorithm,” *J*, vol. 2, no. 2, pp. 226–235, 2019. [96](#)
- [123] X.-D. Zhang, *Machine Learning*, pp. 223–440. Singapore: Springer Singapore, 2020. [97](#), [98](#), [113](#), [117](#)

- [124] G. Bonaccorso, *Machine Learning Algorithms: A Reference Guide to Popular Algorithms for Data Science and Machine Learning*. Packt Publishing, 2017. [97](#), [98](#)
- [125] T. Mitchell, *Machine learning*. Frankfurt: McGraw-Hill, 1997. [97](#)
- [126] C. Cortes and V. Vapnik, “Support-vector networks,” *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995. [99](#)
- [127] Y. Bazi and F. Melgani, “Toward an optimal svm classification system for hyperspectral remote sensing images,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, no. 11, pp. 3374–3385, 2006. [99](#)
- [128] S. Rogers, “Support vector machines for classification and imputation,” 2012. [99](#)
- [129] N. Cristianini and B. Schölkopf, “Support vector machines and kernel methods, the new generation of learning machines,” *AI Magazine*, v.23, 31-41 (2002), vol. 23, 09 2002. [99](#)
- [130] A. Mathur and G. M. Foody, “Multiclass and binary svm classification: Implications for training and classification users,” *IEEE Geoscience and Remote Sensing Letters*, vol. 5, no. 2, pp. 241–245, 2008. [99](#)
- [131] V. Vapnik, *The Nature of Statistical Learning Theory*, vol. 8, pp. 1–15. Springer, 01 2000. [99](#)
- [132] D. J. Mashao, “Comparing svm and gmm on parametric feature-sets,” in *Proceedings of the 14th Annual Symposium of the Pattern Recognition Association of South Africa*, pp. 27–28, 2003. [99](#)
- [133] A. Gidudu, G. Hulley, and T. Marwala, “Image classification using svms: One-against-one vs one-against-all,” *CoRR*, vol. abs/0711.2914, 11 2007. [100](#), [101](#)
- [134] M. Loog, “Chapter 5 - supervised classification: Quite a brief overview,” in *Machine Learning Techniques for Space Weather* (E. Camporeale, S. Wing, and J. R. Johnson, eds.), pp. 113–145, Elsevier, 2018. [101](#)
- [135] A. Baldominos, A. Cervantes, Y. Sáez, and P. Isasi, “A comparison of machine learning and deep learning techniques for activity recognition using mobile devices,” *Sensors*, vol. 19, p. 521, 01 2019. [101](#), [103](#)
- [136] D. Kroese, Z. Botev, T. Taimre, and R. Vaisman, *Data Science and Machine Learning: Mathematical and Statistical Methods*. CRC Boca Ratón: Chapman and Hall, 2020. [101](#), [102](#), [103](#), [117](#)
- [137] P. Flach, *Machine Learning: The Art and Science of Algorithms That Make Sense of Data*. USA: Cambridge University Press, 2012. [106](#), [107](#), [108](#)

- [138] A. K. Jain, “Data clustering: 50 years beyond k-means,” *Pattern Recognition Letters*, vol. 31, no. 8, pp. 651–666, 2010. Award winning papers from the 19th International Conference on Pattern Recognition (ICPR). [114](#), [115](#), [116](#)
- [139] S. Saitta, B. Raphael, and I. Smith, “A comprehensive validity index for clustering,” *Intelligent Data Analysis*, vol. 6, no. 12, pp. 529–548, 2008. [114](#), [115](#), [116](#), [118](#), [119](#)
- [140] P. Berkhin, “A survey of clustering data mining techniques,” in *Grouping Multidimensional Data: Recent Advances in Clustering* (J. Kogan, C. Nicholas, and M. Teboulle, eds.), pp. 25–71, Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. [114](#), [115](#)
- [141] A. Saxena, M. Prasad, A. Gupta, N. Bharill, O. P. Patel, A. Tiwari, M. J. Er, W. Ding, and C.-T. Lin, “A review of clustering techniques and developments,” *Neurocomputing*, vol. 267, pp. 664–681, 2017. [115](#)
- [142] F. Murtagh and P. Legendre, “Ward’s hierarchical agglomerative clustering method: Which algorithms implement ward’s criterion?,” *J Classif*, vol. 31, pp. 274–295, 2014. [116](#)
- [143] J. H. W. Jr., “Hierarchical grouping to optimize an objective function,” *Journal of the American Statistical Association*, vol. 58, no. 301, pp. 236–244, 1963. [116](#), [117](#)
- [144] L. Deborah, R. Baskaran, and A. Kannan, “A survey on internal validity measure for cluster validation,” *International Journal of Computer Science and Engineering Survey*, vol. 1, pp. 85–102, 2010. [118](#)
- [145] D. L. Davies and D. W. Bouldin, “A cluster separation measure,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-1, no. 2, pp. 224–227, 1979. [118](#)
- [146] T. Caliński and J. Harabasz, “A dendrite method for cluster analysis,” *Communications in Statistics*, vol. 3, no. 1, pp. 1–27, 1974. [118](#)
- [147] P. J. Rousseeuw, “Silhouettes: A graphical aid to the interpretation and validation of cluster analysis,” *Journal of Computational and Applied Mathematics*, vol. 20, pp. 53–65, 1987. [118](#), [119](#)
- [148] O. Arbelaitz, I. Gurrutxaga, J. Muguerza, J. M. Pérez, and I. Perona, “An extensive comparative study of cluster validity indices,” *Pattern Recognition*, vol. 46, no. 1, pp. 243–256, 2013. [118](#), [119](#)
- [149] C. M. Bishop, “Variational principal components,” 1999. [119](#)