



PONTIFICIA UNIVERSIDAD CATOLICA DE CHILE  
ESCUELA DE INGENIERIA

**IDENTIFICACIÓN DE ESTADOS  
FISIOLÓGICOS ORIENTADA A LA  
PREVENCIÓN DE ACCIDENTES  
LABORALES EN BASE A DATOS  
FISIOLÓGICOS NO INVASIVOS Y  
TÉCNICAS DE INTELIGENCIA  
ARTIFICIAL**

**FRANCISCO ANTONIO FOUERE ANDRADE**

Tesis para optar al grado de  
Magister en Ciencias de la Ingeniería

Profesores Supervisores:  
**JUAN CARLOS SALAS**  
**FELIPE NUÑEZ**

Santiago de Chile, Agosto, 2021

© 2021, Francisco Antonio Fouere Andrade



PONTIFICIA UNIVERSIDAD CATOLICA DE CHILE  
ESCUELA DE INGENIERIA

# IDENTIFICACIÓN DE ESTADOS FISIOLÓGICOS ORIENTADA A LA PREVENCIÓN DE ACCIDENTES LABORALES EN BASE A DATOS FISIOLÓGICOS NO INVASIVOS Y TÉCNICAS DE INTELIGENCIA ARTIFICIAL

**FRANCISCO ANTONIO FOUERE ANDRADE**

Tesis presentada a la Comisión integrada por los profesores:

**JUAN CARLOS SALAS**

**FELIPE NUÑEZ**

**MARÍA RODRIGUEZ**

**ALFONSO CRUZ**

**DAVID ANDRADE**

Para completar las exigencias del grado de  
Magister en Ciencias de la Ingeniería

Santiago de Chile, Agosto, 2021

*A mis Padres;*

*Jorge Fouere y Angela Andrade que  
me apoyan de forma incondicional.*

## **AGRADECIMIENTOS**

Agradezco al profesor Juan Carlos Salas que depositó su confianza en mí para llevar a cabo la investigación y me guió en esta etapa de aprendizaje.

También, a mis amigos Cristian Zuilt y Gonzalo Cáceres que me ayudaron en el desarrollo de la programación cuando mi mente no lograba descifrar los problemas matemáticos y analíticos a resolver.

Agradecimiento especial a Fernanda Castillo por su apoyo desinteresado en mi progreso académico, y personal.

## ÍNDICE GENERAL

	Pág.
DEDICATORIA.....	ii
AGRADECIMIENTOS .....	iii
ÍNDICE DE TABLAS.....	vi
ÍNDICE DE FIGURAS .....	vii
RESUMEN.....	xiv
ABSTRACT .....	xv
1. INTRODUCCIÓN.....	16
1.1 Motivación .....	16
1.2 Objetivos y Metodología.....	21
2. MODELO DE OCURRENCIA DE ACCIDENTES.....	23
2.1 Modelos de Ocurrencia de Accidentes.....	23
2.2 Modelo Cuadrado de Ocurrencia de Accidentes.....	28
2.3 Relación Bidireccional Entorno - Comportamiento.....	30
2.4 Relación Bidireccional Entorno - Fisiología.....	33
2.5 Vía Condición Insegura.....	36
2.6 Vía Acción Insegura Comportamiento.....	38
2.7 Vía Acción Insegura Fisiología.....	40
2.8 Ventajas del Modelo de Ocurrencia de Accidentes Propuesto .....	48
3. SISTEMA DE IDENTIFICACIÓN DE ESTADOS FISIOLÓGICOS .....	49
3.1 Estado del arte .....	49
3.2 Teoría del Sistema Propuesto .....	56
3.3 Modelo Inteligencia Artificial Propuesto .....	57
3.4 Propagación hacia atrás.....	58
3.5 Optimizador <i>Adaptive Moment Estimation</i> (Adam).....	65
3.6 Redes Recurrentes de Largo y Corto Plazo.....	68
3.7 Redes Convolucionales .....	71
3.8 Autoencoder Variacional.....	74
3.9 Mezcla de Gaussianas .....	80

4.	CASO DE ESTUDIO .....	83
4.1	Recolección y Análisis de Datos .....	83
4.2	Resultados de los Modelos de Inteligencia Artificial.....	94
4.3	Discusión sobre los Modelos de Inteligencia Artificial .....	108
4.4	Resultados de Clusterización Mezcla de Gaussianas .....	112
4.5	Discusión sobre la Clusterización Mezcla de Gaussianas.....	118
4.6	Resultados Repositorio de Datos Externos .....	122
4.7	Discusión sobre Repositorio de Datos Externos .....	125
5.	CONCLUSIONES Y TRABAJO FUTURO .....	127
5.1	Conclusiones .....	127
5.2	Limitaciones .....	129
5.3	Trabajo Futuro.....	130
	BIBLIOGRAFÍA.....	132
	ANEXO.....	138

## ÍNDICE DE TABLAS

	Pág.
Tabla 4-1: Valores función de pérdida de entrenamiento. ....	102
Tabla 4-2: Valores de medidas fisiológicas persona número 2.....	115
Tabla 7-1: Valores de medidas fisiológicas persona número 3.....	189
Tabla 7-2: Valores de medidas fisiológicas persona número 5.....	189
Tabla 7-3: Valores de medidas fisiológicas persona número 7.....	190
Tabla 7-4: Valores de medidas fisiológicas persona número 8.....	190
Tabla 7-5: Valores de medidas fisiológicas persona número 9.....	191

## ÍNDICE DE FIGURAS

	Pág.
Figura 1-1: Estimación de costos asociados a seguridad laboral (Colorado School of Mines, 2011).....	17
Figura 1-2: Tasa de Fatalidad de la minería en Chile. La tasa de fatalidad es el número de trabajadores fallecidos por cada millón de horas trabajadas (Sernageomin, Accidentabilidad Minera 2018).....	18
Figura 1-3: Tasa de Frecuencia de Accidentes de la minería en Chile. La tasa de frecuencia es el número de accidentes incapacitantes por cada millón de horas trabajadas (Sernageomin, Accidentabilidad Minera 2018). ....	19
Figura 2-1 Pirámide de Heinrich. ....	24
Figura 2-2: Modelo ocurrencia accidentes (Paul y Maiti, 2008).....	27
Figura 2-3: Modelo ocurrencia accidentes (Kowalski, 2003). ....	28
Figura 2-4: Modelo cuadrado de ocurrencia de accidentes. ....	30
Figura 2-5: Esquema sistema nervioso.....	42
Figura 2-6: Esquema neurona. ....	43
Figura 3-1: Arquitectura What Color. ....	58
Figura 3-2: Algoritmo del descenso del gradiente estocástico.....	60
Figura 3-3: Algoritmo de propagación hacia atrás.....	61
Figura 3-4: Algoritmo Adam.....	67
Figura 4-1: Ubicación electrodos. ....	84
Figura 4-2: Dispositivo Equivital Life Monitor. ....	84
Figura 4-3: Intervalos RR.....	86
Figura 4-4: Histograma intervalos RR de entrenamiento persona número 2. ....	87
Figura 4-5: Histograma pre procesado intervalos RR de entrenamiento persona número 2. ....	88
Figura 4-6: Histograma intervalos RR de validación persona número 2. ....	89
Figura 4-7: Histograma pre procesado intervalos RR de validación persona número 2. ....	89
Figura 4-8: Histograma frecuencia respiratoria de entrenamiento persona número 2. ....	91

Figura 4-9: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 2.....	92
Figura 4-10: Histograma frecuencia respiratoria de validación persona número 2. ....	93
Figura 4-11: Histograma pre procesado frecuencia respiratoria de validación persona número 2.....	93
Figura 4-12: Valores función de pérdida persona número 2.....	103
Figura 4-13: Reconstrucción intervalos RR acumulada normalizada persona 2. ....	104
Figura 4-14: Espacio latente vista 2D persona número 2.....	105
Figura 4-15: Espacio latente vista 3D persona número 2.....	105
Figura 4-16: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 2.....	106
Figura 4-17: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 2.....	107
Figura 4-18: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 2.....	107
Figura 4-19: Histograma RMSSD de la clusterización de la persona número 2.....	113
Figura 4-20: Histograma intervalos RR de la clusterización de la persona número 2. ....	113
Figura 4-21: Histograma ritmo cardiaco de la clusterización de la persona número 2. ....	114
Figura 4-22: Histograma frecuencia respiratoria de la clusterización de la persona número 2.....	114
Figura 4-23: Estado fisiológico minuto a minuto persona número 2.....	116
Figura 4-24: Ángulo de postura minuto a minuto persona número 2. ....	117
Figura 4-25: Señal representativa de cada clúster. ....	118
Figura 4-26: Gráfico estado fisiológico persona 1 repositorio de datos externos. ....	123
Figura 4-27: Gráfico estado fisiológico persona 2 repositorio de datos. ....	124
Figura 7-1: Histograma intervalos RR de entrenamiento persona número 3.....	139
Figura 7-2: Histograma pre procesado intervalos RR de entrenamiento persona número 3. ....	139
Figura 7-3: Histograma intervalos RR de validación persona número 3. ....	140
Figura 7-4: Histograma pre procesado intervalos RR de validación persona número 3...	140

Figura 7-5: Histograma frecuencia respiratoria de entrenamiento persona número 3. ....	141
Figura 7-6: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 3.....	141
Figura 7-7: Histograma frecuencia respiratoria de validación persona número 3. ....	142
Figura 7-8: Histograma pre procesado frecuencia respiratoria de validación persona número 3.....	142
Figura 7-9: Histograma intervalos RR de entrenamiento persona número 5.....	143
Figura 7-10: Histograma pre procesado intervalos RR de entrenamiento persona número 5. ....	143
Figura 7-11: Histograma intervalos RR de validación persona número 5. ....	144
Figura 7-12: Histograma pre procesado intervalos RR de validación persona número 5. ....	144
Figura 7-13: Histograma frecuencia respiratoria de entrenamiento persona número 5. ...	145
Figura 7-14: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 5.....	145
Figura 7-15: Histograma frecuencia respiratoria de validación persona número 5. ....	146
Figura 7-16: Histograma pre procesado frecuencia respiratoria de validación persona número 5.....	146
Figura 7-17: Histograma intervalos RR de entrenamiento persona número 7.....	147
Figura 7-18: Histograma pre procesado intervalos RR de entrenamiento persona número 7. ....	147
Figura 7-19: Histograma intervalos RR de validación persona número 7. ....	148
Figura 7-20: Histograma pre procesado intervalos RR de validación persona número 7. ....	148
Figura 7-21: Histograma frecuencia respiratoria de entrenamiento persona número 7. ...	149
Figura 7-22: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 7.....	149
Figura 7-23: Histograma frecuencia respiratoria de validación persona número 7. ....	150
Figura 7-24: Histograma pre procesado frecuencia respiratoria de validación persona número 7.....	150
Figura 7-25: Histograma intervalos RR de entrenamiento persona número 8.....	151

Figura 7-26: Histograma pre procesado intervalos RR de entrenamiento persona número 8. .....	151
Figura 7-27: Histograma intervalos RR de validación persona número 8. ....	152
Figura 7-28: Histograma pre procesado intervalos RR de validación persona número 8.	152
Figura 7-29: Histograma frecuencia respiratoria de entrenamiento persona número 8. ....	153
Figura 7-30: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 8.....	153
Figura 7-31: Histograma frecuencia respiratoria de validación persona número 8. ....	154
Figura 7-32: Histograma pre procesado frecuencia respiratoria de validación persona número 8.....	154
Figura 7-33: Histograma intervalos RR de entrenamiento persona número 9.....	155
Figura 7-34: Histograma pre procesado intervalos RR de entrenamiento persona número 9. .....	155
Figura 7-35: Histograma intervalos RR de validación persona número 9. ....	156
Figura 7-36: Histograma pre procesado intervalos RR de validación persona número 9.	156
Figura 7-37: Histograma frecuencia respiratoria de entrenamiento persona número 9. ....	157
Figura 7-38: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 9.....	157
Figura 7-39: Histograma frecuencia respiratoria de validación persona número 9. ....	158
Figura 7-40: Histograma pre procesado frecuencia respiratoria de validación persona número 9.....	158
Figura 7-41: Valores función de pérdida persona número 3.....	159
Figura 7-42: Reconstrucción intervalos RR acumulada normalizada persona 3. ....	159
Figura 7-43: Valores función de pérdida persona número 5.....	160
Figura 7-44: Reconstrucción intervalos RR acumulada normalizada persona 5. ....	160
Figura 7-45: Valores función de pérdida persona número 7.....	161
Figura 7-46: Reconstrucción intervalos RR acumulada normalizada persona 7. ....	161
Figura 7-47: Valores función de pérdida persona número 8.....	162
Figura 7-48: Reconstrucción intervalos RR acumulada normalizada persona 8. ....	162
Figura 7-49: Valores función de pérdida persona número 9.....	163

Figura 7-50: Reconstrucción intervalos RR acumulada normalizada persona 9. ....	163
Figura 7-51: Espacio latente vista 2D persona número 3.....	164
Figura 7-52: Espacio latente vista 3D persona número 3.....	164
Figura 7-53: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 3.....	165
Figura 7-54: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 3.....	165
Figura 7-55: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 3.....	166
Figura 7-56: Espacio latente vista 2D persona número 5.....	167
Figura 7-57: Espacio latente vista 3D persona número 5.....	167
Figura 7-58: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 5.....	168
Figura 7-59: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 5.....	168
Figura 7-60: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 5.....	169
Figura 7-61: Espacio latente vista 2D persona número 7.....	170
Figura 7-62: Espacio latente vista 3D persona número 7.....	170
Figura 7-63: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 7.....	171
Figura 7-64: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 7.....	171
Figura 7-65: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 7.....	172
Figura 7-66: Espacio latente vista 2D persona número 8.....	173
Figura 7-67: Espacio latente vista 3D persona número 8.....	173
Figura 7-68: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 8.....	174

Figura 7-69: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 8.....	174
Figura 7-70: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 8.....	175
Figura 7-71: Espacio latente vista 2D persona número 9.....	176
Figura 7-72: Espacio latente vista 3D persona número 9.....	176
Figura 7-73: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 9.....	177
Figura 7-74: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 9.....	177
Figura 7-75: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 9.....	178
Figura 7-76: Histograma RMSSD de la clusterización de la persona número 3.....	179
Figura 7-77: Histograma intervalos RR de la clusterización de la persona número 3.....	179
Figura 7-78: Histograma ritmo cardiaco de la clusterización de la persona número 3.....	180
Figura 7-79: Histograma frecuencia respiratoria de la clusterización de la persona número 3.....	180
Figura 7-80: Histograma RMSSD de la clusterización de la persona número 5.....	181
Figura 7-81: Histograma intervalos RR de la clusterización de la persona número 5.....	181
Figura 7-82: Histograma ritmo cardiaco de la clusterización de la persona número 5.....	182
Figura 7-83: Histograma frecuencia respiratoria de la clusterización de la persona número 5.....	182
Figura 7-84: Histograma RMSSD de la clusterización de la persona número 7.....	183
Figura 7-85: Histograma intervalos RR de la clusterización de la persona número 7.....	183
Figura 7-86: Histograma ritmo cardiaco de la clusterización de la persona número 7.....	184
Figura 7-87: Histograma frecuencia respiratoria de la clusterización de la persona número 7.....	184
Figura 7-88: Histograma RMSSD de la clusterización de la persona número 8.....	185
Figura 7-89: Histograma intervalos RR de la clusterización de la persona número 8.....	185
Figura 7-90: Histograma ritmo cardiaco de la clusterización de la persona número 8.....	186

Figura 7-91: Histograma frecuencia respiratoria de la clusterización de la persona número 8.....	186
Figura 7-92: Histograma RMSSD de la clusterización de la persona número 9.....	187
Figura 7-93: Histograma intervalos RR de la clusterización de la persona número 9.....	187
Figura 7-94: Histograma ritmo cardiaco de la clusterización de la persona número 9.....	188
Figura 7-95: Histograma frecuencia respiratoria de la clusterización de la persona número 9.....	188
Figura 7-96: Estado fisiológico minuto a minuto persona número 3.....	192
Figura 7-97: Ángulo de postura minuto a minuto persona número 3.....	192
Figura 7-98: Estado fisiológico minuto a minuto persona número 5.....	193
Figura 7-99: Ángulo de postura minuto a minuto persona número 5.....	193
Figura 7-100: Estado fisiológico minuto a minuto persona número 7.....	194
Figura 7-101: Ángulo de postura minuto a minuto persona número 7.....	194
Figura 7-102: Estado fisiológico minuto a minuto persona número 8.....	195
Figura 7-103: Ángulo de postura minuto a minuto persona número 8.....	195
Figura 7-104: Estado fisiológico minuto a minuto persona número 9.....	196
Figura 7-105: Ángulo de postura minuto a minuto persona número 9.....	196

## RESUMEN

Los estados fisiológicos alterados, como el estrés y la fatiga, muchas veces asociados al contexto laboral, afectan negativamente a las personas, promoviendo la aparición de enfermedades cardiovasculares, asma, trastornos del sueño, ansiedad, depresión, entre otros. Adicionalmente, los estados fisiológicos alterados afectan el rendimiento laboral de los trabajadores, disminuyendo los indicadores de productividad de las empresas, y transformándose en una causa de accidentes laborales.

En este trabajo, se desarrolló un sistema que apunta a identificar los estados fisiológicos en los cuales se encuentra cada trabajador minuto a minuto, mediante una recolección de datos cardio-respiratorios no invasiva, que representa una gran oportunidad para mitigar los perjuicios ya expuestos. Para ello se tomaron datos de electrocardiograma y frecuencia respiratoria de seis personas durante un periodo de una semana. Con estos datos se entrenaron una serie de modelos de aprendizaje profundo para clasificar en qué estado fisiológico se encuentra cada persona minuto a minuto.

El modelo con mejores resultados según una función de pérdida de entrenamiento que considera la divergencia de Kullback-Leibler y el error cuadrático medio, fue el modelo llamado “*What Color*”, que se compone de un autoencoder variacional con redes convolucionales al codificar y decodificar, arquitectura de la cual se toma el espacio latente para generar tres clústeres que corresponden a tres niveles de estados fisiológicos para cada persona, mediante la técnica de mezcla de gaussianas.

La significancia de cada clúster se justifica a partir de cinco análisis, la observación visual de las señales de intervalos RR que vive en cada uno de los clústeres, la relación entre el estado fisiológico, la postura de la persona y los periodos de sueño, los valores promedios y desviaciones estándar existentes de las variables relevantes de cada clúster, análisis del estado del arte sobre estados fisiológicos que surgen de forma espontánea en los resultados de la investigación, y finalmente, la aplicación del modelo a un repositorio externo de datos fisiológicos obteniendo resultados acordes a los esperados.

Palabras Claves: estado fisiológico, aprendizaje profundo, autoencoder variacional, mezcla de gaussianas, electrocardiograma, respiración.

## ABSTRACT

Altered physiological states, such as stress and fatigue, often associated with the work context, negatively affect people, by promoting the appearance of cardiovascular diseases, asthma, poor sleep quality, anxiety or depression, among others. Additionally, altered physiological states affect the work performance of workers, decreasing the productivity indicators of companies, and becoming a cause of occupational accidents.

In this work, a system is developed that aims to identify the physiological states in which each worker is minute by minute, through non-invasive cardio-respiratory data collection, which represents a great opportunity to mitigate the damages already exposed. To do this, electrocardiogram data and breathing frequency are taken from six people during a period of one week. With these data, a series of deep learning models are trained to classify the physiological state in which each person is minute by minute.

The model with the best results according to its training loss function, considering the divergence of Kullback-Leibler and the mean quadratic error, was the model called “What Color”, which is composed of a variational autoencoder with convolutional networks when encoding and decoding, architecture from which the latent space is taken to generate three clusters that correspond to three levels of physiological states for each person, using the Gaussian mixing technique.

The significance of each cluster is justified from five analyzes, the visual observation of the RR interval signals that live in each of the clusters, the relationship between the physiological state, the posture of the person and the periods of sleep, the existing average values and standard deviations of the relevant variables of each cluster, analysis of the state of the art on physiological states that arise spontaneously in the research results, and finally, the application of the model to an external repository of physiological data obtaining results according to those expected.

Keywords: physiological state, deep learning, variational autoencoder, gaussian mixture, electrocardiogram, respiration.

## 1. INTRODUCCIÓN

En este capítulo se abordan temas acerca del por qué se realiza este estudio, y el impacto que puede llegar a tener un sistema de monitoreo de estados fisiológicos en la industria minera actual. Además, indaga acerca de cómo se miden hoy en día ciertas variables relevantes al tema, y a grandes rasgos las mejoras que se podrían generar al implementar este tipo de tecnologías en el ámbito laboral, y de la calidad de vida de los trabajadores.

### 1.1 Motivación

La industria minera, es un sector industrial relevante que representa alrededor del 10% del PGB (Producto Geográfico Bruto) de la economía en Chile, que se caracteriza por ser un sector de explotación de recursos naturales no renovables de creciente complejidad, intensivo en capital y su producto es un *commodity*, cuyo precio está determinado por las fuerzas del mercado.

Los desafíos que enfrenta la industria minera actualmente son variados y multidimensionales. Sin embargo, la seguridad y salud ocupacional representa un desafío transversal a todas las faenas en operación.

En efecto, Codelco Chile declara: “La seguridad y la salud ocupacional constituyen uno de los ejes fundamentales de nuestra gestión corporativa. La protección de nuestros trabajadores, ya sean propios o de terceros, es un valor irrenunciable y principio central de nuestra Política de Seguridad, Salud en el Trabajo y Riesgos Operacionales” (Codelco, 2018).

Asimismo, Antofagasta Minerals, otra de las grandes empresas mineras chilenas, declara que “Seguridad y salud son un valor prioritario e intransable. Por ello buscamos

permanentemente mejorar nuestro desempeño en aspectos que puedan afectar a nuestros trabajadores, contratistas y comunidades” (Antofagasta Minerals, 2018).

De acuerdo con la Organización Internacional del Trabajo, en el mundo fallecen anualmente 2.7 millones de personas como consecuencia de accidentes de trabajo o de enfermedades profesionales, y estima que ello redunda en un impacto del 4% del PBI global por año (OIT, 2019).

El impacto que tienen los accidentes laborales y los incidentes en los costos de una faena es alto. Según estimaciones del Colorado School of Mines, los costos indirectos o escondidos que se derivan de dichos eventos son mayores al costo directo observado.

Una estimación de ello se muestra en la Figura 1-1.

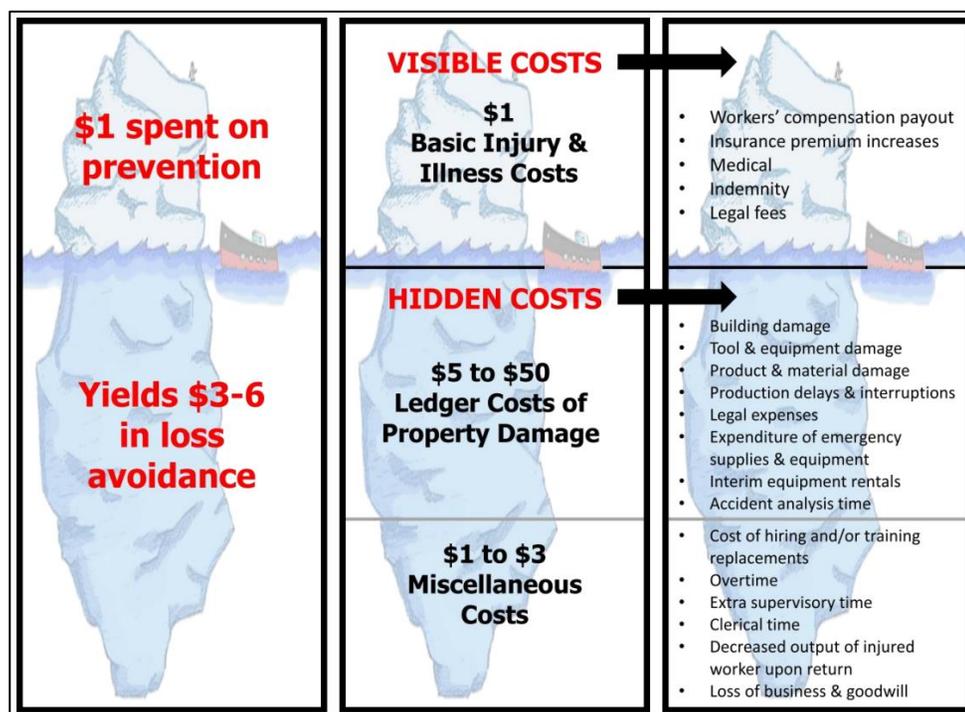


Figura 1-1: Estimación de costos asociados a seguridad laboral (Colorado School of Mines, 2011).

Consecuentemente, en las últimas décadas el sector minero se ha esforzado en reducir la accidentabilidad en sus faenas, lo que ha permitido reducir tanto la tasa de fatalidad como la tasa de accidentabilidad. Las Figuras 1-2 y 1-3 ilustran esta tendencia, donde se aprecia que el esfuerzo realizado por las compañías mineras en los últimos 30 años ha significado una reducción de los índices de accidentabilidad de más de un 92%.

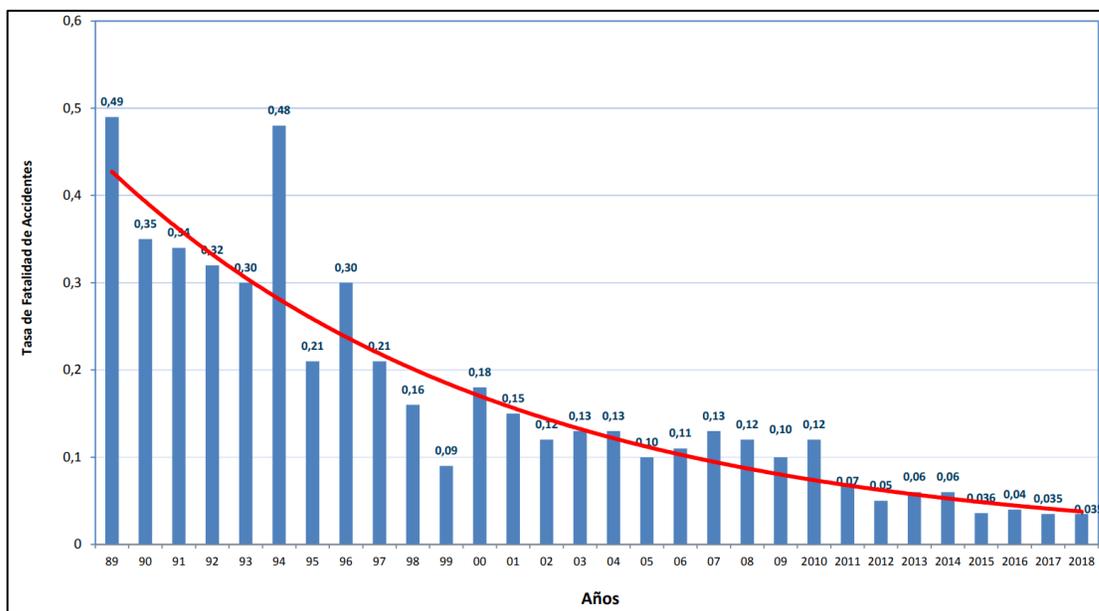


Figura 1-2: Tasa de Fatalidad de la minería en Chile. La tasa de fatalidad es el número de trabajadores fallecidos por cada millón de horas trabajadas (Sernageomin, Accidentabilidad Minera 2018).

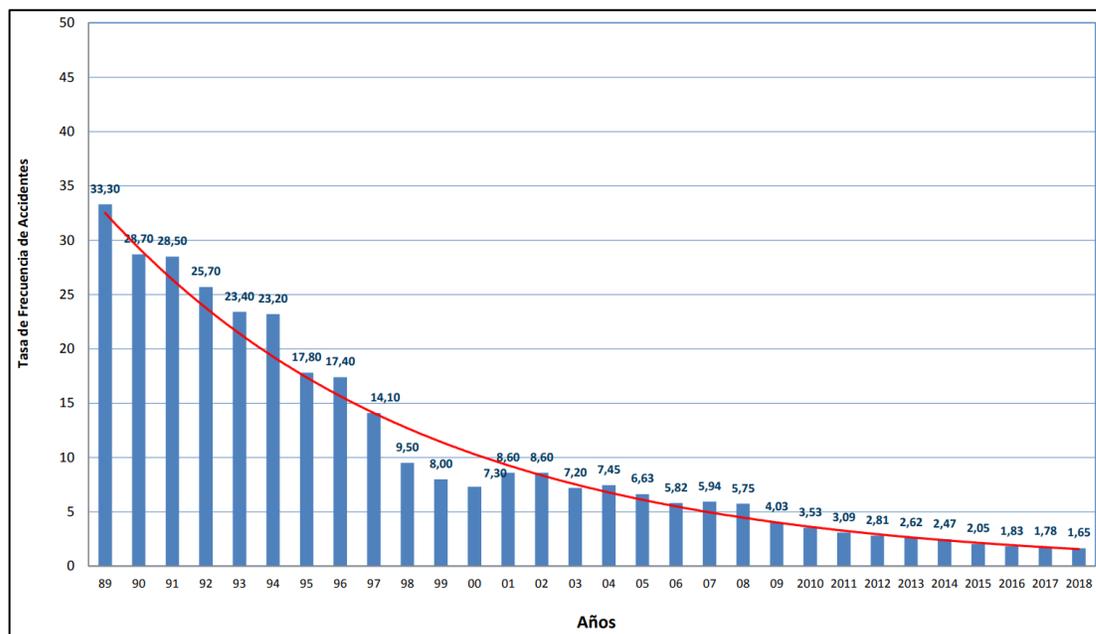


Figura 1-3: Tasa de Frecuencia de Accidentes de la minería en Chile. La tasa de frecuencia es el número de accidentes incapacitantes por cada millón de horas trabajadas (Sernageomin, Accidentabilidad Minera 2018).

Sin embargo, en los últimos años las pendientes de las curvas de las tasas de fatalidad y frecuencia de accidentes se han reducido considerablemente, sugiriendo que las metodologías adoptadas, focalizadas en entrenamiento de trabajadores y mejoramiento de instalaciones y procesos, están acercándose al límite de su desempeño. Por ende, para lograr el objetivo de continuar reduciendo la accidentabilidad, se hace necesario adoptar nuevas metodologías, que incorporen paradigmas no explorados actualmente. En este contexto, el uso de tecnologías emergentes basadas en sensorización y procesamiento de datos en tiempo real representan una alternativa atractiva para concebir una nueva generación de sistemas de gestión de seguridad y salud operacional (SGSSO).

Recientemente, se ha identificado a los estados fisiológicos alterados como una causa de los accidentes laborales. El estado fisiológico se define como la condición física-mental en la cual se encuentra un individuo, y se refleja en el funcionamiento del sistema nervioso de la persona. Además, los estados fisiológicos alterados, como el estrés y la fatiga, muchas veces asociados al contexto laboral, afectan negativamente a las personas promoviendo la aparición de enfermedades cardiovasculares, asma, mala calidad del sueño, ansiedad o depresión, entre otros (Barsevick et al., 2010; Slavich, 2016). Adicionalmente, los estados fisiológicos alterados afectan el rendimiento laboral de los trabajadores, disminuyendo los indicadores de productividad de las empresas (Katic et al., 2013; Mansour, 2016; Street et al., 2018), y como fue mencionado, transformándose en una causa de accidentes laborales (Paul y Maiti, 2008; Jacobé de Naurois et al., 2018).

Debido a lo anterior existe una oportunidad de mejora en la creación de un sistema que realice un monitoreo en tiempo real de los trabajadores para saber en qué estado fisiológico se encuentran minuto a minuto y atacar las consecuencias negativas que generan los estados fisiológicos alterados tanto para las empresas como para la vida diaria, seguridad y salud de las personas.

Bajo el contexto expuesto, donde las personas se ven afectadas negativamente en su vida por los estados fisiológicos alterados como el estrés y la fatiga, que además disminuyen los indicadores de productividad de las empresas y son una causa común de accidentes laborales, es clara la necesidad de encontrar sistemas que apunten a cambiar esa realidad.

Por ello, la tesis de la presente investigación fue identificar los estados fisiológicos en personas, mediante la recolección de datos fisiológicos no invasivos y técnicas de inteligencia artificial. La hipótesis propuesta es que, mediante el uso de datos cardio-respiratorios se puede obtener el estado fisiológico de una persona en tiempo real, mediante la utilización de algoritmos de aprendizaje profundo que procesan los datos minuto a minuto y sensores no invasivos que captan la información del individuo continuamente y que no invadan el actuar normal del usuario.

Algunas de las virtudes de la aplicación de este sistema a un contexto laboral, es que serviría para gestionar de mejor forma los turnos y periodos de descanso de los trabajadores, contribuyendo a mejorar la calidad de vida de la fuerza laboral, mitigar la baja productividad de las empresas y disminuir los accidentes laborales.

El resultado de la tesis a obtener es un sistema capaz de identificar cada minuto el estado fisiológico de las personas, a partir de un conjunto de datos fisiológicos no-invasivos, empaquetado en la forma de un script escrito en lenguaje Python. El sistema entrega un informe con gráficos donde se muestra la evolución minuto a minuto del estado fisiológico de la persona, con un reporte pre-procesado de las variables fisiológicas más importantes del monitoreo.

## **1.2 Objetivos y Metodología**

El objetivo general de la tesis es diseñar, implementar y validar preliminarmente un sistema que identifique en tiempo real, minuto a minuto, el estado fisiológico de una persona, en base a datos fisiológicos no invasivos y técnicas de inteligencia artificial.

Mientras que los objetivos específicos son tres. El primero es conseguir una base de datos fisiológicos no-invasivos. El segundo es desarrollar un clasificador de estados

fisiológicos en base a algoritmos de inteligencia artificial. El tercero y último es crear un mecanismo de reportería con las variables fisiológicas relevantes.

Para el cumplimiento de los objetivos, se plantea la siguiente metodología. Para el primer punto se indaga en la web las bases de datos existentes y repositorios de datos, que contengan datos fisiológicos no-invasivos, particularmente señales cardiacas y respiratorias de personas. Al mismo tiempo, se solicita la base de datos de otro estudio realizado en la misma casa de estudios, que, si bien apunta a otros tópicos, utiliza las variables fisiológicas buscadas.

Para el segundo punto, se estudia sobre metodologías, técnicas y algoritmos para identificar estados fisiológicos. Se analizan tales procedimientos y se programa en lenguaje Python una solución mediante el uso de algoritmos de inteligencia artificial, que permita identificar en tiempo real, minuto a minuto, el estado fisiológico de una persona. Se evalúa además los resultados de la identificación usando diferentes técnicas de inteligencia artificial, para sugerir la mejor opción según métricas de desempeño estándar.

Finalmente, para el último punto se programa en lenguaje Python, la creación de reportes de los resultados del modelo sugerido en la parte anterior, donde se entreguen métricas fisiológicas como lo son la variabilidad cardiaca, ritmo cardiaco, frecuencia respiratoria, entre otros.

## 2. MODELO DE OCURRENCIA DE ACCIDENTES

En este capítulo se ahonda en los sistemas de seguridad ocupacional existentes en el ámbito laboral, específicamente en el sector minero. Por otro lado, se muestran ciertas ineficiencias en los sistemas actuales y como se pueden mejorar con la implementación del sistema propuesto.

### 2.1 Modelos de Ocurrencia de Accidentes

Un SGSSO se desarrolla a partir de un modelo conceptual, el cual identifica fuentes causantes (riesgos) de la ocurrencia de accidentes ocupacionales y conceptualiza sobre causalidades y potenciales acciones de mitigación. El pionero en esta área fue W. H. Heinrich en el año 1931 con su libro llamado “*Industrial Accident Prevention: A Scientific Approach*”, donde establece la relación entre daños serios, daños menores y eventos sin daños, con la proporción de 300:29:1, que se muestra en la Figura 2-1. Su significado es que para que ocurra un daño serio, deben ocurrir 29 daños menores, y 300 eventos sin daños. Para lograr esto Heinrich analizó 75.000 accidentes reportados de una compañía de seguros y además analizó la causa de los incidentes (eventos sin daños). El 88% de los accidentes o incidentes fueron causados por acciones inseguras de las personas, 10% fue causado por condiciones inseguras y el 2% eran no prevenibles.

H. W. Heinrich también fue el creador del modelo de 5 dominós de causas de accidentes. Donde para llegar al accidente con daño grave deben ocurrir otros cuatro eventos de forma lineal, y se puede detener en cualquiera de esas piezas. Las piezas son ambiente social (creencias, tratos, etc.), falta de la persona (descuido o falta

personal), acto inseguro o peligro mecánico, accidente, daño (consecuencias del accidente).

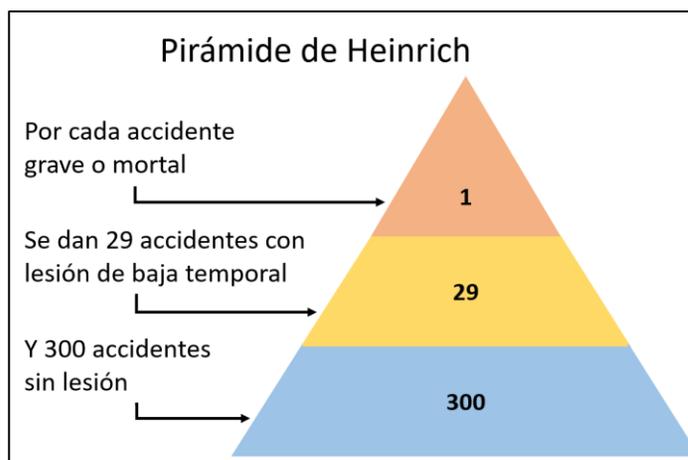


Figura 2-1 Pirámide de Heinrich.

Existen otros modelos de ocurrencia de accidentes, donde analizan sus causas y llegan a diferentes proporciones. En 1966 Frank Bird y George Germain publicaron su libro “Damage Control”, y propusieron otro triángulo con proporciones. El estudio se aplicó sobre 90.000 incidentes, y propusieron que para que ocurra un daño mayor, deben ocurrir 100 daños menores, y 500 eventos con daño a la propiedad.

En 1968 Frank Bird mejoró su análisis incluyendo 1.753,498 accidentes reportados por 297 compañías. El estudio resultó en la proporción de 1:10:30:600. Para que exista un daño mayor, deben ocurrir 10 daños menores, 30 daños a las propiedad y 600 eventos sin daños.

Frank Bird actualiza el modelo de dominós de Heinrich, y los nombra ausencia de gestión o control, causas básicas (ausencia de conocimiento o habilidad, estándares inadecuados de trabajo, etc.), causas inmediatas (síntomas del problema, practicas o

condiciones inseguras), accidente o incidente (es el punto de contacto, algunas contramedidas son protección personal, barreras de protección, etc.) y daño ya sea a personas (enfermedades, efectos mentales adversos, heridas físicas) o a la propiedad. Las limitaciones o críticas que han encontrado a estos modelos de ocurrencia triangulares o de pirámide es que las proporciones no son constantes para las industrias, y varían según los tipos de accidentes, trabajos, y tipo de personas. Los autores refutan las proporciones de dos maneras, primero desde la teoría con ejemplos como el siguiente, si se toman las proporciones de Heinrich o Bird y Germain, y se llevan a la industria de actividades bajo el agua, en la cima del triángulo se tendrán los accidentes fatales, y en la base del triángulo se tendrá las inmersiones accidentales, pero entre ellos casi no existirán accidentes de daños menores, ya que el accidente escala inmediatamente en fatalidad (Anderson y Denkl, 2010).

En segundo lugar, lo refutan desde los números empíricos, en el mismo estudio anterior, revisan las cifras de la industria del petróleo y gas y en los últimos 8 años han bajado significativamente los accidentes menores, sin embargo, el número de fatalidades se han mantenido constante (Anderson y Denkl, 2010).

La misma crítica se observa en un estudio realizado a varias empresas en Reino Unido donde se mostró una relación de una muerte por cada 207 daños graves, 1.402 daños que causaron 3 o más días con tiempo perdido, y 2.754 daños menores (HSE, 1999).

Llevando este argumento al contexto de la investigación, que apunta al sector minero, se observa en las Figuras 1-2 y 1-3, que tampoco se cumple ninguna proporción. Si bien ambas métricas han ido disminuyendo en los últimos años, no sigue una

proporción fija, ya que hay años en los que baja considerablemente la cantidad de accidentes, pero no así la cantidad de víctimas fatales.

Estas limitaciones sugieren que abordar los accidentes desde proporciones fijas, o generar proporciones considerando empresas de diferentes rubros no es adecuado, en el sentido que cada industria tiene sus propios contextos, y dentro de esos contextos los accidentes ocurren de diversas formas, y el unificar todo lo anterior en una proporción es difícilmente certero.

Existen modelos más actuales, como el creado por la Unión Europea, que incluye conceptos de cultura de prevención de riesgo psicosociales, como el dialogo social, mejores prácticas, legislación, y construcción de sociedades (Leka et al., 2011).

Otro modelo que indaga sobre la ocurrencia y las causas de los daños laborales es el mostrado en la Figura 2-2. En este modelo diferencian las variables en dos grandes grupos, los que provienen del trabajador, y los sociotécnicos que dependen más del contexto en cual se desenvuelve la persona (Paul y Maiti, 2008).

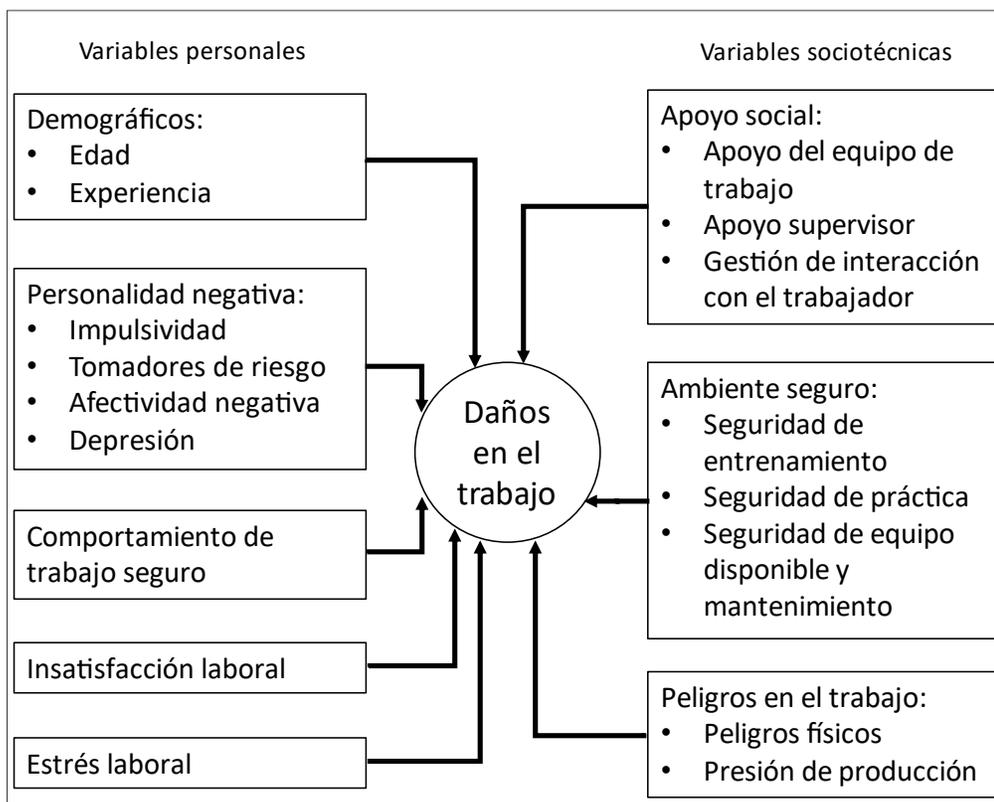


Figura 2-2: Modelo ocurrencia accidentes (Paul y Maiti, 2008).

Otro modelo que incluye conceptos psicológicos, fisiológicos y de comportamiento es el mostrado en la Figura 2-3. En este modelo se busca establecer las causas de las enfermedades laborales, y de los daños que se desea disminuir por parte de las empresas (Kowalski, 2003).

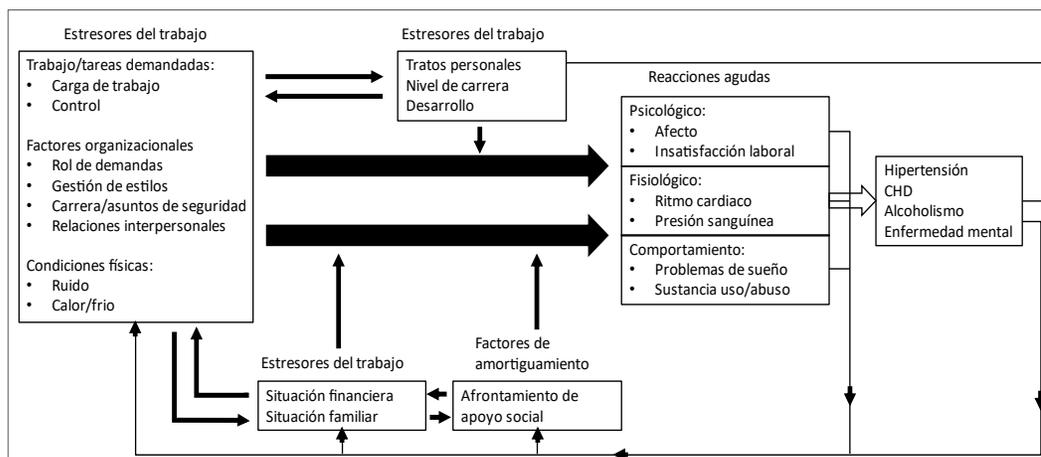


Figura 2-3: Modelo ocurrencia accidentes (Kowalski, 2003).

## 2.2 Modelo Cuadrado de Ocurrencia de Accidentes

Como parte de esta investigación, se propone un modelo de ocurrencia de accidentes, que hace uso explícito de la componente fisiológica. Como primer paso, se deben definir los siguientes conceptos:

- **Accidente:** suceso no planeado y no deseado de liberación de energía que provoca un daño, lesión u otra incidencia negativa sobre un sujeto.
- **Entorno:** variables externas al sujeto que pueden afectar al comportamiento de los procesos en ejecución.
- **Fisiología:** es el estudio científico de las funciones y mecanismos que funcionan dentro de un sistema vivo.
- **Comportamiento:** manera de comportarse una persona en una situación determinada o en general.
- **Acción insegura:** cualquier acción o falta de acción que puede ocasionar un accidente.

- Condición insegura: cualquier condición del ambiente o entorno laboral que puede contribuir a un accidente.

Se plantea en la investigación que los accidentes ocurren por dos motivos, el primero es debido a la vía de la condición insegura, donde la responsabilidad del accidente recae en el entorno, como puede ser el clima, contaminación, temperatura, entre otros, o como también pueden ser propios del lugar o empresa donde se trabaja, como normas inadecuadas, horarios no apropiados, sobrecarga de trabajo, desgaste de equipos y materiales, mal mantenimiento, entre otros. Estas variables se denominan variables de entorno.

El segundo motivo es debido a una acción insegura, donde la responsabilidad recae en la persona. Las acciones inseguras pueden estar asociadas a la vía de la condición fisiológicas y/o vía del comportamiento. La vía del comportamiento hace referencia a la falta de conocimiento o habilidad para emplear determinada tarea, o a actitudes indebidas de la persona para ahorrar tiempo, evitar esfuerzos, evitar incomodidades, entre otros. La vía fisiológica es la incapacidad física o mental, cuando la persona sufre de una condición desfavorable, que incapacita o dificulta realizar una tarea específica, como puede ser fatiga, estrés, cansancio, entre otras. Cabe notar que no toda situación de fatiga, estrés, u otra, genera un problema en la realización de tareas, pero según la revisión del estado del arte, queda claro que son un factor que a menudo aumenta las probabilidades de generar una acción insegura que derive en un probable accidente.

En la Figura 2-4 se muestra el modelo cuadrado de ocurrencia de accidentes. Cada una de sus componentes se irán desglosando con referencias en las próximas secciones del estudio.

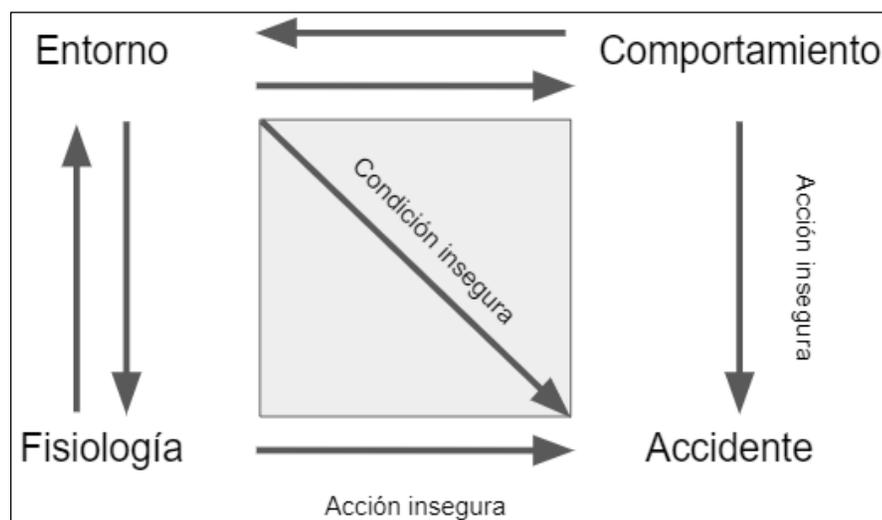


Figura 2-4: Modelo cuadrado de ocurrencia de accidentes.

### 2.3 Relación Bidireccional Entorno - Comportamiento

La primera dirección por abordar es como el entorno afecta al comportamiento del trabajador. Un estudio realizado en China aplicado a 320 accidentes ocurridos en minas de carbón, reflejó que las condiciones inseguras, provocadas por reglas y regulaciones laborales, generan un comportamiento inseguro del operador (Zhang et al., 2016).

La creación de una aplicación que monitorea el comportamiento de los trabajadores ayudó a disminuir su comportamiento inseguro. La aplicación mide mensualmente los comportamientos inseguros realizados por cada trabajador y le otorga una puntuación, y según los puntajes alcanzados, los trabajadores reciben cursos para entrenarse y volver al trabajo. También existe un castigo monetario según la cantidad de desobediencias generales o severas realizadas, siendo 50 Yuanes (5.500 pesos chilenos aproximadamente) por 3 generales y 200 Yuanes (22.000 pesos chilenos aproximadamente) por 3 severas (Qing-Gui et al., 2012).

Hoy en día, es impensado aplicar normativas que midan y castiguen acciones inseguras por medio de pagos monetarios, ya sea por altos costos de su implementación, falta de infraestructura tecnológica para monitorear o porque infringe códigos del trabajo chileno con respecto al trato a los trabajadores y su privacidad laboral.

Otra variable de entorno que afecta al comportamiento de los trabajadores es el comportamiento seguro de liderazgo. Es uno de los factores importantes en el funcionamiento de la empresa, y se considera una razón principal del número de accidentes en las minas. Una encuesta realizada a cerca de 800 trabajadores mineros en China, mostró que el comportamiento seguro de liderazgo es afectado principalmente por tres factores, el mecanismo de gestión de seguridad donde las autoridades gubernamentales toman medidas o políticas de seguridad, la práctica regulatoria de seguridad por parte de las autoridades de gobierno que regula y supervisa periódicamente a las empresas, y la idea de seguridad que se refiere a como las personas creen que es una producción segura en las minas (Zhang et al., 2017).

Un estudio destinado a identificar los factores cognitivos que afectan a la seguridad aplicó seis algoritmos de aprendizaje automático como árboles de decisiones, bosques aleatorios, máquina de vectores de soporte, k vecinos más cercanos, clasificador bayesiano, y redes neuronales a una base de datos compuesta por observaciones y respuestas de un cuestionario aplicado a 80 trabajadores. El mejor modelo fue el árbol de decisiones con un área bajo la curva (AUC) de la curva de característica operativa del receptor (ROC) de 0.976. Uno de los resultados a los que llegaron los autores es que existe una inconsistencia entre la intención y el comportamiento seguro, existe un 65% de probabilidades de que los trabajadores tengan la intención de comportarse de

forma segura, pero fue observado un trabajo inseguro debido a la débil creencia normativa del ambiente de trabajo (Goh et al., 2018). Se entiende por creencia normativa a como el individuo percibe y evalúa su entorno social.

Los últimos dos párrafos apuntan directamente a dilucidar lo importante que es tener líderes laborales que guíen y supervisen el trabajo de sus compañeros, como también el establecer normas claras de seguridad, que ayuden a los mismos, a concretar la intención de comportarse de forma segura fortaleciendo la creencia normativa.

La segunda dirección por abordar es cómo el comportamiento de los trabajadores afecta a las variables de entorno. Un experimento aplicado a 15 trabajadores mineros donde a cada trabajador se le daba un incentivo si realizaba ciertas acciones pre y post labor, donde las acciones pre-labor eran revisar correctamente que tuviesen todo su equipo de protección personal (EPP) antes de comenzar su trabajo, y post labor si utilizaron su EPP correctamente, obtuvo como resultado un aumento de la realización de las acciones de autogestión llegando a un 34,8% y 40,1% en pre y post labor respectivamente, pero cuando dejaron de dar los incentivos, bajó a un 13,9% y 17,9% en pre y post labor respectivamente.

Las posibles razones para este fenómeno fueron dos. La primera razón, es que el tiempo fue muy poco para que los trabajadores internalicen el conocimiento, mientras que la segunda, es que el incentivo económico era tan fuerte que se transformó en su mayor motivación para cambiar su comportamiento (Hickman y Geller, 2003). La autogestión proveniente del conocimiento del trabajador puede cambiar el ambiente de trabajo a un entorno laboral seguro.

## 2.4 Relación Bidireccional Entorno - Fisiología

La primera dirección por abordar es cuando la fisiología del trabajador o de los trabajadores afecta a variables de entorno. Un estudio realizado en Australia indica que un 11,7% de la fuerza de trabajo está bajo los efectos de angustia, a la que denominan como *psychological distress*, siendo aún más grave cuando se lleva al entorno de la minería donde esta cifra aumenta a un 28% de las personas en las zonas del sur y oeste de Australia, y a un 12,7% en Queensland (Street et al., 2019).

En el mismo estudio, se afirma que aquellos trabajadores que informaron que están bajo los efectos del estrés laboral o *Stress Work*, son un 19% menos productivos que sus pares (Street et al., 2019), y por si esto fuese poco, el deterioro de trabajo del trabajador debido al estrés laboral es de un tercio del sueldo del trabajador, calculado en relación con los tiempos perdidos, ausentismo laboral, problemas de concentración y calidad de trabajo (Street et al., 2019). Basado en la pérdida de los tiempos de las minas situadas en los estados de Queensland y New South Wales se estima que el estrés psicológico tiene un costo económico anual de 153.8 millones de dólares para la industria de la minería de carbón, representando casi el 9% de las utilidades antes de impuestos (Street et al., 2019).

En línea con lo ya mencionado, los lugares de trabajo con altos niveles de estrés reducen el compromiso de los empleados. Los empleados se vuelven menos productivos y tienen mayores tasas de ausencia que los que operan en condiciones de menor estrés. Una encuesta laboral aplicada a diferentes empresas alrededor del mundo mostró que el 90% del personal estaba desconectado y con altos niveles de estrés y el 57% de ellos se sentía absolutamente desconectado de su empleador. El autor entiende

desconectado como la indiferencia, o la no prioridad de sus actos. Además, la encuesta evidenció un vínculo entre altos niveles de estrés y la reducción en la productividad (Mansour, 2016).

Una estimación de costos intangibles relacionados a las condiciones de trabajo basadas en los niveles de estrés de los trabajadores arrojó que los niveles de estrés de los empleados afectan la eficiencia de estos. Los altos niveles de estrés entre los empleados reducen dramáticamente su eficiencia. Usualmente, la relación entre el nivel de estrés y la eficiencia no son lineales, pero si poseen una relación inversa (Mansour, 2016).

En otras palabras, el estrés afecta a un gran porcentaje de los trabajadores, y aumenta aún más cuando el rubro de trabajo se centra en la minería. Los costos económicos que sufre una empresa o compañía asociados al estrés laboral que sufren sus trabajadores es enorme, llegando a perder la tercera parte del sueldo pagado al trabajador solo por pérdidas de productividad. Y sumado a lo anterior, se establece una relación inversa entre aquellos trabajadores con estrés y el compromiso de los mismos con la empresa en la cual se desempeñan.

Otra variable fisiológica que afecta al entorno es la fatiga del trabajador. La mayor causa de la fatiga es el sueño insuficiente o interrumpido, pero también puede resultar de la participación de largas tareas tales como la conducción en autopistas, monitoreo de equipamiento, o vuelos altamente automatizados. La fatiga degrada el rendimiento cognitivo de las personas (Caldwellet et al., 2018), pero además genera un peligro grave para la seguridad, que da como resultado numerosos accidentes y efectos adversos para la salud física y mental del individuo (Caldwellet et al., 2018).

La segunda dirección por abordar es cuando el entorno afecta las variables fisiológicas de los trabajadores. La fatiga puede ser causada por los horarios de trabajo, sus diseños, los requerimientos de tareas en el trabajo, y las condiciones del ambiente de trabajo. Los horarios de trabajo y diseño incluyen el número y patrones de horas trabajadas, hora del día, cambios de turno, y trabajo en turnos de noche. Las condiciones del ambiente de trabajo incluyen factores de ruido, temperaturas extremas, y ambiente psicosocial (Pelders y Nelson, 2019).

Siguiendo el párrafo anterior, se realizó una entrevista semi estructurada a trabajadores en escalafones, rangos o posiciones de trabajo representativos de una fábrica de fundición de platino en Sudáfrica. Los factores asociados a la fatiga de los trabajadores que esperaban obtener los autores eran las horas extraordinarias, el trabajo por turnos, el trabajo repetitivo y monótono, y el trabajo que requiere altos niveles de concentración fuesen los principales factores. No obstante, los resultados fueron que la edad, raza, situación de tenencia de la vivienda, salubridad de la dieta, trastornos del sueño, estrés, y satisfacción laboral eran los principales factores de la fatiga. Los mayores niveles de fatiga fueron encontrados en los trabajadores más jóvenes (Pelders y Nelson, 2019).

En línea con lo anterior, los resultados de un estudio en Gran Bretaña muestran que el 22% de los empleados de Gran Bretaña acusan que su situación financiera impacta en su productividad en su lugar de trabajo. El 82% dijo que una ayuda en la gestión de sus finanzas reduciría los niveles de estrés laboral (Mansour, 2016).

Según un estudio realizado en 5 diferentes mineras y a 30 trabajadores por minera, arrojó que los principales estresores laborales con una correlación positiva son el estrés

por el cargo, y el conflicto entre trabajo y familia, mientras que aquellos con correlación negativa son la autoeficacia, condiciones del trabajo, relaciones interpersonales, desarrollo ocupacional, mecánicas y estilo de la organización (Hongxia et al., 2014).

Se muestra así, que hay variables externas al trabajador que pueden incidir de forma destructiva en su actuar. Estas pueden ser independientes de la empresa, como lo son el clima, o el ruido de ciertos lugares, como también dependientes de la empresa como lo es la designación de horarios, tareas y turnos.

## **2.5 Vía Condición Insegura**

Varios autores han utilizado la vía de la condición insegura para aproximarse a la predicción de accidentes, desde contextos donde el individuo se encuentra conduciendo como también desempeñándose en rubros más específicos como en obras de construcción.

Ejemplo de esto es la predicción del riesgo de sufrir accidentes automovilísticos mediante variables espaciales como la población que existe en cierto cuadrante, variables temporales como el clima en el cual ocurrió el accidente, o espacio – temporales como la tasa de accidentes de determinada zona según la hora, día y mes en que ocurren, utilizando redes neuronales del tipo recurrente y convolucional, las cuales han logrado segmentar cuadrantes según el riesgo de sufrir un accidente (Bao et al., 2019).

Otro estudio que predice el cuándo y dónde ocurre un accidente automovilístico secundario, usa modelos de regresión lineal, redes neuronales y máquina de vectores de soporte para mínimos cuadrados, con optimización de enjambre de partículas para

obtener el tiempo y la distancia entre el primer accidente y el accidente secundario. Un accidente secundario es el que ocurre debido a la congestión generada por un accidente automovilístico previo. Los datos utilizados de entrada fueron las condiciones climáticas, calidad del suelo, volumen de tráfico, severidad del choque, entre otros (Wang et al., 2019).

En el ámbito industrial, en una planta de acero han utilizado otros enfoques de predicción de accidentes, algoritmos del tipo máquina de soporte de vectores optimizada mediante algoritmo genético y enjambre de partículas, junto con redes neuronales. Los datos utilizados son el lugar de accidente, temporalidad, tipo de lesión, condiciones de trabajo, tipo de contrato del trabajador, entre otros. Los resultados los clasificaron en lesión, cuasi accidente y daño a la propiedad, obteniendo un 90,67% de exactitud (Sarkar et al., 2019).

En el mundo de la construcción se han generado bases de datos a partir de procesamiento de lenguaje natural aplicado a reportes no estructurados de lesiones. Tales resultados se han usado para predecir lesiones en los trabajadores mediante algoritmos de bosques aleatorios y el gradiente estocástico de aumento de árboles, estimando el tipo de lesión, el tipo de energía que lo provocó y la parte del cuerpo involucrada. Los resultados obtenidos sugieren que los daños no ocurren de forma aleatoria, y que en la industria de la construcción debe ser estudiada con análisis más profundos, opiniones de expertos y gestiones reguladoras para evitar que ocurran (Tixier et al., 2016).

El estado del arte proveniente desde el vértice de la condición insegura para predecir accidentes sugiere que la aplicación de modelos de inteligencia artificial a grandes

cantidades de datos que recolectan información respecto a accidentes pasados son suficientes para estimar una probabilidad de que ocurra otro accidente en un futuro. No obstante, aún no alcanza un nivel de robustez suficiente para estimar el lugar o una temporalidad en la cual vaya a existir ese accidente, sino más bien, apuntan a establecer el tipo de accidente o lesión que sufrirá el trabajador.

Otra forma para establecer si la zona de trabajo es segura frente a accidentes, ha sido la utilizada en una mina de carbón con la aplicación PROTECTOR, que mide la cantidad de gas, vibración, iluminación, polvo en suspensión, entre otras, para ver si cumplen con las normas o tolerancias aceptadas (Lilić et al., 2010).

## **2.6 Vía Acción Insegura Comportamiento**

Las variables de comportamiento de los trabajadores están estrechamente relacionadas a las acciones inseguras por parte del trabajador, y por ello relacionadas con la probabilidad de sufrir un accidente.

En un estudio realizado a casi 70.000 accidentes ocupacionales y reporte de fatalidades en el sector minero de España, donde se utilizaron clasificadores bayesianos, árboles de decisión, reglas de asociación y otras técnicas de minería de datos, para encontrar aquellos factores que generan accidentes mostraron que la ausencia de entrenamiento de trabajadores con carga manual o bien la pobre mecanización y uso de equipamiento apropiado era un factor importante en la generación de accidentes (Sanmiguel et al., 2015).

Luego de una recopilación de información a dos mineras subterráneas de carbón de la India, con más de 1.000 trabajadores entre ambas, encontraron que las personas accidentadas están más insatisfechas de su trabajo, afectadas negativamente

(experiencias crónicas de estados de emoción negativas o ausencia de estabilidad emocional) y más tomadoras de riesgo que las no accidentadas. Las tres variables mencionadas influyen significativamente para predecir el incremento del número de daños laborales en las mineras. Además, afirman que aquellas personas que se ven afectadas negativamente e insatisfechas en el trabajo, se convierten en trabajadores más tomadores de riesgo y con comportamientos poco seguros (Paul y Maiti, 2007).

Una encuesta realizada a 1590 mineros, pertenecientes a siete minas de carbón ubicadas en China, mostró que la educación sobre seguridad y entrenamiento de los mineros pueden motivar el comportamiento seguro de los mineros. Además, las percepciones individuales de los trabajadores son de los factores más importantes para el comportamiento seguro de los trabajadores, y por ello un factor clave en la ocurrencia de accidentes. Para llegar a este análisis, usaron la técnica de componentes principales, regresión logística binaria y regresiones de Poisson a los resultados de la encuesta (Wang et al., 2019).

Los tres estudios mencionados dejan en claro la importancia que posee el conocimiento del trabajador a la hora de cumplir sus labores y ejecutar acciones seguras, no obstante, este último punto no solo se ve afectado por sus saberes previos, sino que también es impulsado por su actitud frente a la toma de decisiones, el cual a su vez se ve influenciado por su satisfacción laboral y por su estado de ánimo. Lo anterior sugiere que la empresa no solo debe encargarse de que los trabajadores aprendan a ejecutar de mejor manera su trabajo o adquieran mayores conocimientos, sino también, debe procurar una salud mental y una satisfacción laboral para sus trabajadores.

## **2.7 Vía Acción Insegura Fisiología**

Las dos variables más nombradas en el estado del arte investigado en este estudio que se correlacionan con una acción insegura por parte del trabajador, y con el aumento en la probabilidad de sufrir un accidente, son el estrés y la fatiga.

El estrés se define como la reacción de la persona a los cambios o exigencias de su vida. Existen dos tipos, el eustrés o estrés positivo, como es casarse, cambiar de empleo, etc., y su forma negativa que es distrés, como pérdida de empleo, acontecimientos negativos futuros, etc. Existen muchas variables que causan el estrés, y entre ellas se encuentran las finanzas, el trabajo y la familia como factores normales de estrés (Leukemia & Lymphoma Society, 2019).

Holly Blake, profesora asociada de Ciencias del Comportamiento de la Universidad de Nottingham, afirma que el estrés puede ser positivo, ya que es una respuesta natural de defensa de nuestro sistema nervioso, que ayuda al individuo a estar alertar, motivado o centrado en realizar cierta actividad, liberando hormonas de estrés como adrenalina y cortisol. El problema se genera cuando el estrés es frecuente, o se prolonga durante demasiado tiempo, o cuando las causas negativas que la generan son superiores a la capacidad que posee el individuo de soportar (Blake, 2017).

El estrés afecta el sistema respiratorio, cuesta más respirar y se hace más deprisa en un intento de llevar rápidamente sangre rica en oxígeno al cuerpo. En general, para la mayoría de las personas no supone ningún problema, pero si para aquellas que sufran de alguna condición previa como el asma. Además, genera estragos en el sistema inmunitario, ya que la liberación de cortisol inhibe el sistema inmunitario, volviéndonos más vulnerables a contraer infecciones. También, se ve afectado el

sistema endocrino, que juega un rol importante en la regulación del estado de ánimo y metabolismo, entendiendo por metabolismo el conjunto de reacciones químicas que tienen lugar en las células del cuerpo para convertir los alimentos en energía. Del mismo modo, el estrés tiene efectos gastrointestinales, ya que la capacidad del intestino de absorber los nutrientes se ve reducida, lo que puede desencadenar ardor estomacal, reflujo, dolor de estómago, hinchazón, o diarrea (Blake, 2017).

Análogamente, el estrés puede causar aumentos en la presión arterial, tensión o temblor muscular, problemas digestivos, insomnio, irritabilidad y depresión (Leukemia & Lymphoma Society, 2019). Los aumentos en la presión arterial se traducen en un aumento de la fuerza que ejerce la sangre contra las paredes de las arterias, problema que aumenta la probabilidad de sufrir ataques cardíacos, accidentes cerebrovasculares, entre otros.

Para entender como el estrés llega a afectar al cuerpo humano de esta manera, hay que definir ciertos conceptos previamente. El sistema nervioso está compuesto por 2 divisiones, conteniendo cada división miles de millones de neuronas. El primero es el sistema nervioso central que se compone del encéfalo y la médula espinal, mientras que la segunda división es el sistema nervioso periférico, que conecta la médula espinal con los músculos y los receptores de sensaciones. En la Figura 2-5, se muestra un esquema del sistema nervioso.

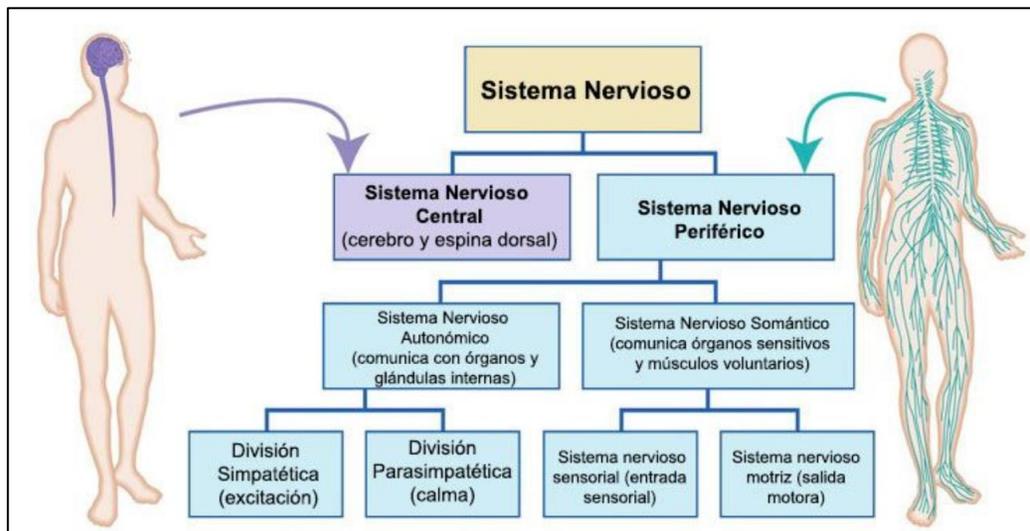


Figura 2-5: Esquema sistema nervioso.

El sistema nervioso periférico es el responsable de los reflejos y de la respuesta de huida o lucha cuando se enfrenta una situación de estrés o peligro. La neurona es la parte más básica de este sistema y se compone de tres partes, llamadas dendritas, axón y cuerpo celular como se observa en la Figura 2-6. Las dendritas son la estructura semejante a un árbol cuya función es recibir las señales de otras neuronas, el cuerpo celular es el contenedor de la información generativa en forma de ADN, y el axón es la parte que transmite las señales entre el cuerpo celular y las otras neuronas. Gran parte de las neuronas están aisladas mediante la vaina de mielina como método de defensa que las protege formando una capa alrededor del axón, permitiendo así la transmisión de los impulsos nerviosos en el axón.

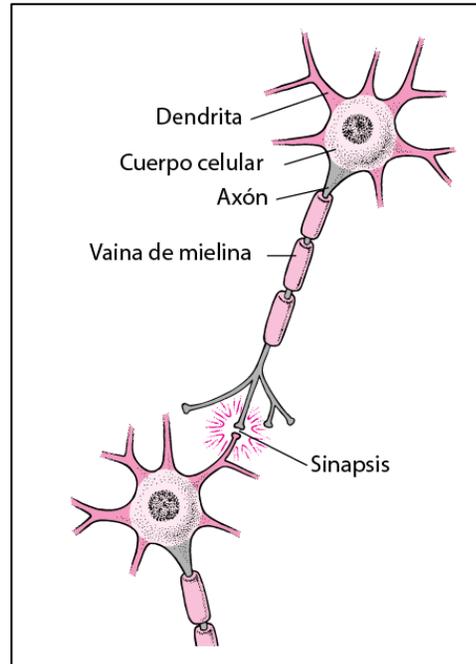


Figura 2-6: Esquema neurona.

Para que las señales eléctricas viajen entre las neuronas, es necesario que se conviertan en una señal química llamada neurotransmisor, que luego cruza un pequeño espacio llamado sinapsis que mide alrededor de una millonésima pulgada de ancho.

En resumen, el sistema nervioso periférico tiene como principal función conectar el sistema nervioso central con los órganos, las extremidades y la piel, lo cual realizan mediante el flujo de impulsos explicado, permitiendo así que el encéfalo y la médula espinal puedan enviar y recibir la información de las otras áreas del cuerpo y reaccionar a esos estímulos.

Los estímulos son captados mediante el sistema nervioso somático, que posee dos principales tipos de neuronas, que son las neuronas sensoriales o aferentes y las neuronas motoras o eferentes. Las primeras neuronas son las encargadas de recoger la información sensorial y de llevar esta información al sistema nervioso central, mientras

que las segundas transportan la información del sistema nervioso central a las fibras musculares de todo el cuerpo, permitiendo así tomar medidas físicas de respuesta.

En paralelo se encuentra el sistema nervioso autónomo, que es responsable de las funciones involuntarias, como flujo sanguíneo, latidos cardiacos, respiración, y digestión. Dentro de este sistema se encuentra el sistema nervioso simpático y el sistema nervioso parasimpático. El primero se encarga de regular las respuestas de lucha o huida, mueve el cuerpo en las situaciones de peligro, aumentando la frecuencia cardiaca y respiratoria, incrementando el flujo sanguíneo de los músculos, activando la secreción de sudor, dilatando pupilas, entre otras acciones. El segundo es el sistema nervioso parasimpático que ayuda a mantener las funciones normales del cuerpo, como la digestión, presión arterial, frecuencia cardiaca, entre otros, para volver a la actividad normal después de la situación de peligro.

El sistema parasimpático se compone de 12 nervios craneales y 31 nervios espinales, donde sus nombres derivan de que los nervios craneales salen directamente del encéfalo sin pasar por la médula espinal. Se destaca el nervio vago, décimo nervio craneal, que sale del bulbo raquídeo (una de las tres partes del tronco del encéfalo), y conecta nerviosamente a la faringe, esófago, laringe, tráquea, bronquios, corazón, estómago e hígado. Una de sus funciones principales es la transmisión de señales al sistema nervioso autónomo, ayudar a regular la activación y controlar los niveles de estrés, y enviar señales directamente al sistema nervioso simpático.

Por otro lado, el sistema nervioso central, consta de la médula espinal y del encéfalo, donde este último se compone de cuatro partes principales, llamadas tronco del encéfalo, cerebelo, cerebro y diencéfalo, donde nuevamente este último se divide en

dos partes principales, llamadas tálamo e hipotálamo. El hipotálamo consta de más de doce núcleos (masas de sustancia gris compuestas neuronas carentes de mielina) con funciones distintas, y controla muchas de las actividades corporales, siendo uno de los principales reguladores de la homeostasis (capacidad de los organismos de mantener una condición interna estable). Algunas de las principales funciones del hipotálamo son la regulación del sistema nervioso autónomo donde controla e integra acciones como la contracción cardíaca y secreción de glándulas, regulación de las emociones y el comportamiento, regulación del ritmo circadiano, entre muchas otras.

Una vez definido los conceptos anteriores, se puede ver lo multifactorial que es el proceso de estrés. Todo parte con el sistema nervioso somático, donde las neuronas sensoriales o aferentes, recolectan la información del entorno para ser transportada al sistema nervioso central mediante impulsos nerviosos, donde el hipotálamo juega un rol fundamental en la captación e interpretación de estas señales, donde en conjunto con otras partes del sistema nervioso central generan nuevas señales, que son enviadas al sistema nervioso autónomo. En esta parte el sistema nervioso simpático mueve el cuerpo ante la situación de peligro, incrementando entre muchas otras acciones, la frecuencia cardíaca y respiratoria. Acto seguido, luego de acabar la situación de peligro el sistema parasimpático se encarga de regularizar el estado fisiológico del individuo, donde destaca la actividad vagal, encargada de restringir o limitar la actividad simpática, regulando la activación y controlando los niveles de estrés.

Durante todo este proceso se involucran más sistemas que solo el sistema nervioso, ya sea digestivo, endocrino, respiratorio, entre otros, generando cada una dentro de sus funciones la generación de nuevos estímulos, señales y acciones fisiológicas, dando

como daño colateral los problemas que se plantean en el inicio del capítulo. El ejemplo más claro para esto es lo que mencionó la profesora Holly Blake sobre el cortisol que si bien se genera por respuesta natural del estrés, al mismo tiempo inhibe el sistema inmune del individuo.

En este punto, se puede diferenciar la vía de la condición insegura proveniente del comportamiento, en contraste de la proveniente de la fisiología. La vía fisiológica no depende del pensamiento consciente de la persona ya que se expresa en funciones autónomas, como la respiración o frecuencia cardiaca, a diferencia la vía del comportamiento donde la persona comete una acción insegura debido a una creencia errónea, un beneficio mayor de corto plazo, o falta de conocimiento.

Por otro lado, el término fatiga se utiliza para referirse a la sensación de cansancio tras un esfuerzo, que puede ser de diversa naturaleza y genera desmotivación para la continuación de ese esfuerzo, ya sea este intelectual, laboral o deportivo. Desgraciadamente, no existe una definición universalmente aceptada de la fatiga, lo que hace que su naturaleza se presente conceptualmente compleja y ambigua (Cárdenas et al., 2016).

La fatiga se divide en dos, la fatiga central y la fatiga periférica. La fatiga central se asocia a funciones que sufre el sistema nervioso central, afectando estructuras nerviosas que involucran la producción, mantenimiento y control de la contracción muscular, que pueden ser debidos a menor excitabilidad de motoneuronas, o inhibición de neuronas aferentes o sensoriales. La fatiga periférica se asocia a funciones del sistema nervioso periférico, y se ubica principalmente sobre el sistema muscular

existiendo mayor tensión muscular, un mayor tiempo para la relajación muscular y una menor capacidad de contracción muscular específica (Gore, 2018).

En términos coloquiales, la fatiga central se da principalmente en actividades de larga duración o por acumulación de cansancio, donde el cuerpo no alcanza a recuperarse, mientras que la fatiga periférica, se da en momentos cortos y de gran intensidad.

Otra diferencia que se identifica en la fatiga es la fatiga aguda y la fatiga crónica. La fatiga aguda se considera una consecuencia del trabajo mental o corporal, emocional, recuperación insuficiente o enfermedad temporal. Se considera una respuesta reguladora normal a condiciones adversas y afecta a personas sanas. Esta fatiga normalmente se contrarresta con un descanso de suficiente duración y calidad, sueño, dieta. La fatiga crónica, por otro lado, es normalmente causado por enfermedades graves (como diabetes) y tratamientos (por ejemplo, quimioterapia). Aunque los síntomas son similares a los observados en la fatiga aguda, los síntomas no residen después de un descanso, sueño, dieta y ejercicio adecuados; por eso ellos son, como indica el término, duraderas y difíciles de combatir. Cuando estos últimos síntomas duran más de 6 meses y causan un daño incapacitante, se diagnostica el síndrome de fatiga crónica (Gore, 2018).

El estado del arte revisado no profundiza sobre la fatiga en términos tan específicos al momento de identificarla, no obstante, dado el contexto al cual se desea apuntar, que es un entorno laboral minero, la fatiga que se buscaría prevenir, es la fatiga central y aguda.

## **2.8 Ventajas del Modelo de Ocurrencia de Accidentes Propuesto**

Las ventajas del cuadrado de ocurrencia de accidentes en relación con los otros modelos planteados con anterioridad, es que primeramente no es un modelo lineal. No clasifica a los accidentes o incidentes con causas secuenciales que deben ocurrir una tras otra. El modelo plantea que las causas de los accidentes o incidentes provienen por dos vías, la de la acción insegura o de la condición insegura, pero los factores que las causan interactúan entre sí de formas que van más allá de los alcances que una persona u organización pueda lograr entender y predecir.

Otra fortaleza de este modelo es que entiende la máxima anterior, y no busca predecir accidentes según reglas. Sino más bien, toma las variables que influyen en el contexto laboral y las ubica en los vértices del modelo (comportamiento de las personas, o fisiología de las personas o en las condiciones del entorno), las cuales son medidas mediante sistemas de medición no invasivos. Luego estas mediciones son usadas en sistemas inteligentes de inferencia para predecir nuevos estados, que consideran las relaciones de esas variables existentes en cada uno de los vértices. Finalmente, estas predicciones son entradas en algoritmos de optimización que buscan minimizar la ocurrencia de los accidentes o incidentes, afectando positivamente a su paso a otras variables como la productividad, mejor calidad de vida de las personas, entre otras.

Debido a lo anterior, es que el modelo propuesto supera otra limitación de los modelos actuales, es que no establece proporciones constantes o variaciones para cierta industria, sino que trabaja sobre personas independiente del área en cual se desempeñan, y se comparan consigo mismas. El sistema de inferencia propuesto y que se desarrolla en este estudio se explica en el siguiente capítulo.

### 3. SISTEMA DE IDENTIFICACIÓN DE ESTADOS FISIOLÓGICOS

En el siguiente capítulo se ahonda sobre el estado del arte existente sobre la identificación de estado fisiológicos, la teoría del sistema propuesto, junto con la arquitectura neuronal que la compone. Además, se hace una explicación matemática de los modelos de aprendizaje automático utilizados durante la investigación.

#### 3.1 Estado del arte

En el entorno laboral, los estados fisiológicos se miden en gran medida con cuestionarios o entrevistas. Ejemplo de estas es la aplicada por *Mine Safety and Health Administration* (MSHA) a 154 investigadores de accidentes laborales, con 22 afirmaciones, donde se preguntan qué tan a menudo en una escala del 0 al 6 donde 0 significa nunca y 6 cada día, se sienten identificado con cada afirmación, como, por ejemplo, sentirse positivamente influenciado por el entorno de trabajo o si realiza su trabajo sin problemas y de forma calmada. El estudio que buscaba encontrar los efectos de esta labor en los trabajadores concluyó que las personas encuestadas poseen una tendencia a sentirse agotadas, además, de encontrar dos principales temas que contribuyen al estrés de los investigadores de accidentes que es el tener que tratar con las familias en duelo y cumplir con las demandas impuestas al investigador dentro de la organización. Al mismo tiempo no evidenciaron en las respuestas un fuerte sentido de logro personal e importancia en su trabajo (Kowalski, 2003).

Otro cuestionario aplicado en relación con el estrés ocupacional y el entorno seguro es el aplicado a 219 conductores de vehículos. El cuestionario es compuesto por 15 afirmaciones relacionadas a estrés ocupacional que se puntuaban de 1 a 5 donde 1 es nunca y 5 casi todo el tiempo, luego otras 35 afirmaciones sobre el clima seguro que

van de 1 a 7 con la misma explicación anterior sobre la puntuación, y finalmente 5 afirmaciones sobre comportamientos relacionado a la fatiga y auto cuidado con mediciones de 1 a 5 con igual explicación. El estudio concluye que el estrés ocupacional y el ambiente seguro son significativos predictores de la fatiga relacionada a cuasi accidentes, y los autores sugieren que las organizaciones pueden jugar un rol importante de mejora en lo que se refiere al comportamiento de las personas, que se relaciona directamente con el ambiente seguro (Strahan et al., 2008).

Otro cuestionario diseñado para estudiar el estrés laboral fue aplicado en cinco mineras diferentes a un total de 138 trabajadores. El cuestionario consiste en tres partes, la primera sobre directrices de trabajo, la segunda sobre información personal, la tercera sobre trabajo bajo presión. La medición se realiza eligiendo una opción del 1 a 5, donde 1 es muy en desacuerdo y 5 muy de acuerdo con la afirmación (Hongxia et al., 2014). En una empresa de fundición de Sudáfrica también se aplicó un cuestionario sumado con entrevistas de los trabajadores, para encontrar como afecta la fatiga en sus labores. El cuestionario constaba de preguntas que median los niveles de fatiga de 1 a 5, siendo 1 muy alerta y 5 completamente exhausto, según la afirmación que se les planteaba. Las entrevistas fueron llevadas a cabo en dos grupos de 11 y 13 personas, donde abordaban temas como sus experiencias con la fatiga en sus labores, y sobre recomendaciones para reducir la fatiga (Pelders y Nelson, 2019).

Todos los cuestionarios expuestos en el estado del arte utilizan la metodología de la escala de Likert, donde de forma subjetiva el encuestado intenta dar respuesta a una afirmación según niveles que pueden ir de 1 a 5 o de 1 a 7 según sean los casos, donde el 1 representa un extremo de la respuesta mientras que el otro valor extremo

representa lo opuesto. La principal limitación de esta estrategia es la subjetividad del criterio, el sesgo de los encuestados al generalizar sus respuestas, y la deseabilidad social (Strahan et al., 2008). La revisión del arte realizada sugiere que los esfuerzos en medir, cuantificar o identificar estados fisiológicos alterados como el estrés o la fatiga en el rubro minero, se limitan a entrevistas y cuestionarios que poseen grandes falencias en términos de objetividad, de las cuales sacan conclusiones acerca de las posibles causantes de esos estados o sugerencias para reducir la probabilidad de que los trabajadores experimenten esos estados fisiológicos.

Alternativamente, gracias a los avances en las tecnologías de adquisición, transmisión y procesamiento de datos, han aparecido dispositivos comerciales, como los relojes inteligentes, que prometen identificar el estrés del usuario mediante un seguimiento cardíaco y/o de conductancia de la piel.

Un caso de estudio donde utilizan los ya mencionados relojes inteligentes para medir el estrés en las personas registra la actividad cardíaca junto con la conductancia de la piel de 21 personas. Mediante algoritmos de aprendizaje automático supervisado como la máquina de vectores de soporte y bosques aleatorios buscan predecir cuando la persona se encuentra con alta sobrecarga cognitiva, en tiempos de relajación o realizando alguna prueba. El nivel de exactitud del mejor modelo para entrenamientos personalizados es de 97.92%, mientras que la aplicación de un modelo general es de 88.2% (Can et al., 2019).

En el mismo estudio, advierten las limitaciones de este tipo de metodología. Se utilizaron diferentes tipos de relojes inteligentes para registrar los datos de cada individuo, y los resultados de las mediciones entre cada uno de estos aparatos poseen

grandes variaciones. Los autores hacen un cálculo, removiendo los datos cardiacos de los intervalos RR que poseen un 10% o menos de diferencia entre su valor y un promedio local, para el dispositivo E4 se tiene que aproximadamente un 80% de los datos que se mantienen, mientras que para el Samsung Gear S S2 es de casi un 50%, y cuando la diferencia se aumenta hasta un 25% de diferencia el porcentaje de datos que se mantiene es de 95% y 75% respectivamente (Can et al., 2019).

La opción de utilizar *smartwatch* en el rubro minero sugiere una mejora en la objetividad, no obstante, aún no se garantiza que la data recolectada por estos dispositivos es fiable para generar conclusiones a partir de sus datos recolectados.

Dentro de los estudios de aprendizaje automático supervisado relacionados a estados fisiológicos, se encuentra la creación de un guante que reconoce los movimientos del conductor que es sometido a diferentes escenarios, como pistas urbanas, autopistas y rurales que simulan las condiciones de estrés experimentadas por cada conductor. El modelo de aprendizaje automático utilizado es la máquina de soporte de vectores, alcanzando un 94,76% de exactitud promedio (Lee y Chung, 2017).

También, existen estudios donde utilizan electrocardiogramas y mediciones respiratorias para lograr detectar el estrés en las personas. Se aplicó en 39 participantes, y mediante los algoritmos de bosques aleatorios y máquina de soporte de vectores alcanzaron una exactitud de 78% y 84% respectivamente para los tres estados. Los tres estados son altos niveles de estrés, moderado nivel de estrés y no poseer estrés. Para realizar lo anterior hacen aprendizaje supervisado donde someten a los participantes a situaciones de estrés, donde alto estrés es problemas aritméticos bajo cronometro más

trato social en la evaluación, nivel moderado de estrés es quitando el cronómetro, y no estrés es descansar (Han et al., 2017).

Estudios buscan identificar si conductores están relajados, estresados o fatigados mediante fotopletiografía, electromiografía y movimiento de la cabeza. Para ello utilizan un dispositivo que va detrás del cuello de los participantes, y se conecta al músculo trapecio. Someten a los participantes a 10 minutos donde son estimulados a diferentes estímulos previamente clasificados, y mediante el algoritmo de máquina de soporte de vectores alcanzan un 99,52% de exactitud (Lee et al., 2017).

Análogamente, estudios han apuntado a identificar si un conductor se encuentra en un estado normal, de estrés, fatiga o somnolencia mediante un sensor ubicado en la muñeca de cada participante. Fue aplicado en 28 personas, y el dispositivo cuenta con termómetro, acelerómetro, giroscopio, fotopletiograma, y respuesta galvánica de la piel. Los datos son procesados mediante el algoritmo de máquina de soporte de vectores para alcanzar un 68,31% de exactitud para los cuatro estados, y un 84,46% para los tres estados al unir somnolencia con fatiga (Choi et al., 2018).

Hay estudios que cuentan con más sensores, como el de una banda ubicada en la cabeza que posee espectroscopia infrarroja cercana, y fotopletiograma, además de contar en el pecho con electrocardiograma y seismocardiograma. El estudio fue aplicado a 16 personas y busca predecir cuando la persona se encuentra con estrés mental. Para ello, someten a las personas a problemas aritméticos, periodos de descanso, y a la actividad llamada N tareas atrás, donde se debe recordar patrones. Los datos fueron procesados mediante el algoritmo de bosques aleatorios para alcanzar una exactitud del 85% en la predicción de las tres actividades (Gurel et al., 2019).

Un estudio que se realizó a 14 personas, utilizando electroencefalograma y electrocardiograma, obtuvieron un 90% de exactitud mediante el algoritmo máquina soporte de vectores para predecir el estrés en las personas. Los participantes fueron sometidos a problemas aritméticos, periodos de descanso, y pruebas de *stroop color word*, donde les preguntan qué color leen, pero la palabra está pintada de otro color (Ahn et al., 2019).

El estado del arte supervisado ha abarcado una gran cantidad de medidas fisiológicas relacionadas con el corazón, la piel, la respiración, entre otras, como también han utilizado una variedad no menor de instrumentación para recolectar la información. No obstante, en gran parte de los estudios, su aplicación en la vida real es inviable, ya que solo se realizan en ambientes controlados y la instrumentación es invasiva, afectando así el actuar de los individuos a los cuales se les realice el monitoreo.

Alternativamente, la segunda corriente utiliza técnicas de aprendizaje automático no supervisadas. Dentro de esta área se han aplicado cuestionarios, como el cuestionario llamado cinco grandes rasgos de personalidad a 28 personas, junto con sensores que miden su ritmo cardiaco y acelerómetro en tiempo real, sumado a la información de que aplicación están usando en sus celulares, ya sean redes sociales, entretenimiento, noticias, negocio, bienestar, o cualquier otro, y cada 45 minutos desde 9 am a 9 pm deben evaluar en una escala de 1 a 7 que tan estresados se han sentido. Mediante el algoritmo de modelos ocultos de Markov alcanzaron un 75% de exactitud promedio al detectar periodos de estrés y normales (Vildjiounaite et al., 2017).

Objetivos similares se desearon al utilizar una cámara de bajo costo mediante la técnica de fotoplethismografía, de la cual calculan variables cardiacas como el promedio del

ritmo cardiaco, la raíz cuadrada de las diferencias sucesivas de latidos cardiacos, la variabilidad cardiaca, entre otras, buscando establecer periodos de estrés y relajó en una persona. Para ello someten a la persona a realizar la prueba de *stroop color*, y mediante los algoritmos de K promedios, mezcla de gaussianas, y mapa de autoorganización buscan identificar esos dos estados. El mejor modelo fue el K promedios, asumiendo periodos de estrés durante la realización de la prueba con un 86,95% de exactitud en la clasificación (Maaoui y Pruski, 2018).

Otro estudio que utiliza mezcla de gaussianas y mapa de autoorganización para detectar el estrés mental de las personas, logró un 79% de exactitud. Someten a los participantes a tres pruebas, *stroop color*, pruebas de matemáticas y charlas estresantes, con una duración total de 14 minutos. Registran los datos de los participantes con electrocardiogramas y conductancia de la piel (Huysmans et al., 2018).

Otro estudio aplicado a 100 bomberos en acción, donde utilizando variables de electrocardiograma, llegaron a establecer 2 clústeres, uno normal y otro con estrés mediante la técnica de autoencoder con capas convolucionales y recurrentes. La validez de los clústeres los contrasta con los valores del promedio del ritmo cardiaco, la raíz cuadrada de las diferencias sucesivas de latidos cardiacos, entre otros, y su relación con el sistema nervioso de las personas (Oskooei et al., 2019).

El estado del arte no supervisado recoge gran parte de las medidas fisiológicas utilizadas por el estado del supervisado, así que no representa una diferencia en este ámbito, del mismo modo, la instrumentación es semejante e incluso las metodologías de validación si una persona se encuentra en un estado fisiológico alterado o no. La

diferencia principal radica solamente en los algoritmos de inteligencia artificial utilizados como también, en ciertos criterios para confirmar la existencia de un estado fisiológico en los individuos.

### **3.2 Teoría del Sistema Propuesto**

Al igual que los trabajos expuestos en el capítulo anterior, esta tesis busca clasificar estados fisiológicos de personas según escalas de intensidad, sin embargo, captura la necesidad existente con un enfoque diferente y con una serie de beneficios.

Esto se realiza mediante la creación de un sistema de identificación de estados fisiológicos capaz de determinar de forma no invasiva y en tiempo real, minuto a minuto, los estados fisiológicos de las personas. Este sistema llevado al contexto laboral representa una oportunidad para mejorar los números financieros de las empresas, la toma de decisiones de su logística, y por sobre todo una posibilidad de salvar vidas disminuyendo la frecuencia de los accidentes laborales.

El sistema propuesto, se inspira en el modelo cuadrado de ocurrencia de accidentes, ya que este sistema de identificación de estados fisiológicos viene a medir la problemática establecida por la vía de la acción insegura proveniente desde la fisiología.

Por otro lado, los beneficios de tener este sistema, en comparación al estado del arte revisado, es que elimina el sesgo de las entrevistas o encuestas, ya que no necesita de un grupo determinado de personas dentro de un universo de personas para establecer las relaciones, ya que compara a la persona consigo misma minuto a minuto a lo largo de su semana.

Además, elimina la subjetividad existente al preguntarle a una determinada persona si se encuentra estresada, o fatigada, o si alguna experiencia pasada le genera algún

problema fisiológico ya que las mediciones se realizan mediante equipos tecnológicos externos que no se ven influenciados por las creencias del individuo que lo utiliza.

Otro punto, es que las empresas que realizan estos estudios intensivos en tiempo se ven beneficiadas con la utilización de recursos al cambiarse al sistema propuesto, ya que el sistema no requiere de expertos de ningún ámbito para ser usado, solamente implementarse y ver los resultados en línea.

Si este sistema se implementara en una compañía, se podría ver como semanalmente van mejorando o empeorando los índices de estados fisiológicos de sus trabajadores. Como también se podría observar y cuantificar el impacto de las medidas aplicadas por la compañía hacia sus trabajadores.

Otra de las virtudes del sistema es que sirve para gestionar de mejor forma los turnos y periodos de descanso de los trabajadores, contribuyendo a mejorar la calidad de vida de la fuerza laboral, mitigando así la baja productividad de las empresas y disminuyendo los accidentes laborales.

La idea final, es que este sistema se conecte a futuro a otros sistemas que trabajen sobre las otras vías, como lo son la acción insegura proveniente del vértice del comportamiento, y sobre la vía de la condición insegura, en un algoritmo que busque minimizar la ocurrencia de accidentes y completar así la teoría del cuadrado de ocurrencia de accidentes.

### **3.3 Modelo Inteligencia Artificial Propuesto**

El sistema de identificación de estados fisiológicos denominado de aquí en adelante como “*What Color*”, es una red neuronal del tipo autoencoder variacional que posee dos capas convolucionales, aplicadas a señales de intervalos RR consecutivos y datos

de respiraciones promedio dentro del intervalo de señal RR. Al espacio latente se le aplica la técnica de mezcla de gaussianas para obtener los clústeres de estados fisiológicos relajado, transición o activo. Un diagrama de la estructura se presenta en la Figura 3-1.

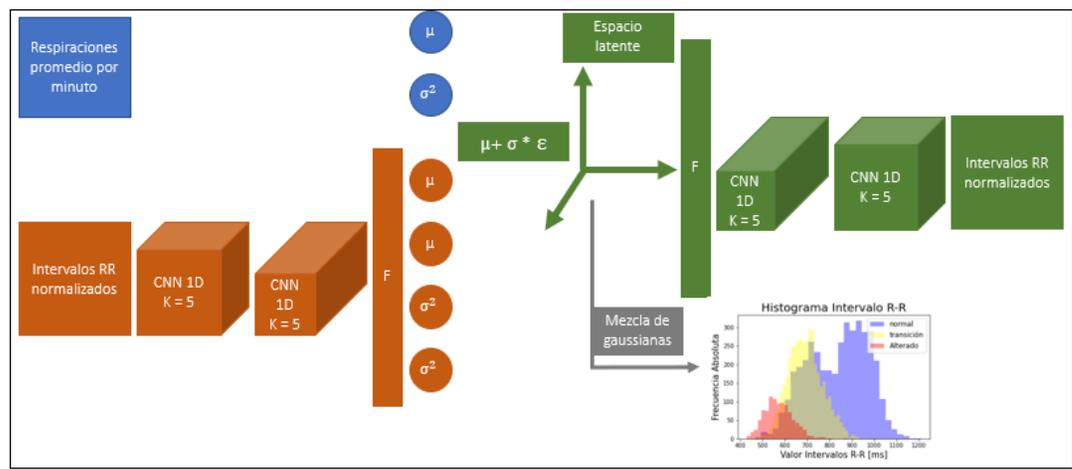


Figura 3-1: Arquitectura What Color.

La elección de esta estructura neuronal se debe a la investigación de algoritmos y a un gran número de variantes aplicadas al caso de estudio explicado en el siguiente capítulo. La información de cada componente utilizada en *What Color* y en las variantes aplicadas se encuentra a continuación.

### 3.4 Propagación hacia atrás

En esta sección se muestra cómo se aplica la heurística de búsqueda de pesos utilizando el algoritmo del descenso del gradiente estocástico (SGD) para las redes neuronales. A lo largo de esta sección se asume que  $\sigma$  es la función sigmoide,  $\sigma(a) = \frac{1}{1+e^{-a}}$  pero la

derivación se mantiene para cualquier función escalar diferenciable (Shalev-Shwartz y Ben-David, 2014).

Dado  $E$  como un conjunto finito de elementos de números enteros, y  $w$  un vector  $\in \mathbb{R}^{|E|}$ , que se traduce en los valores de aprendizaje que van cambiando durante el proceso de aprendizaje. Se asume además que la red tiene  $n$  neuronas de entrada y  $k$  neuronas de salida, y se denota por  $h_w : \mathbb{R}^n \rightarrow \mathbb{R}^k$  la función calculada por la red si la función de peso está definida por  $w$ . Se denota por  $\Delta(h_w(x), y)$  la pérdida de predicción de  $h_w(x)$ , cuando el objetivo es  $y \in Y$ . Para ser concretos, se toma  $\Delta$  para ser la pérdida cuadrática,  $\Delta(h_w(x), y) = \frac{1}{2} \|h_w(x) - y\|^2$ ; sin embargo, se puede obtener una derivación similar para cada función diferenciable. Por último, dada una distribución  $\mathcal{D} \in \mathbb{R}^n \times \mathbb{R}^k$ , se define  $L_{\mathcal{D}}(w)$  como el riesgo de la red (Shalev-Shwartz y Ben-David, 2014):

$$L_{\mathcal{D}}(w) = \mathbb{E}_{(x,y) \sim \mathcal{D}} [\Delta(h_w(x), y)] \quad (3.1)$$

Donde  $\mathbb{E}$  es la esperanza de una variable aleatoria, tal que,  $\mathbb{E}_{z \sim \mathcal{D}}[f(Z)]$ : esperanza de la variable aleatoria  $f: Z \rightarrow \mathbb{R}$ . El algoritmo SGD que minimiza la función de riesgo  $L_{\mathcal{D}}(w)$ , primero, se inicia  $w$  como un vector elegido al azar con valores cercanos a cero. Lo que se espera es que, si se repite el procedimiento SGD varias veces, donde cada vez se inicia el proceso con un nuevo vector aleatorio, una de las iteraciones dará lugar a un mejor mínimo local. Segundo, el tamaño de paso,  $\eta$ , se debe garantizar que sea lo suficientemente bueno para problemas convexos. El paso se define en la siguiente Figura 3-2. Debido a la no convexidad de la función de pérdida, la elección de la secuencia  $\eta_t$  es significativa, y es sintonizada en la práctica por una manera de

ensayo y error. Tercero, se elige como salida el mejor desempeño que se alcance en el set de validación. Además, a veces es útil añadir la regularización en los pesos, con el parámetro  $\lambda$ . Es decir, se trata de minimizar el  $L_{\mathcal{D}}(\mathbf{w}) + \frac{\lambda}{2} \|\mathbf{w}\|^2$ . Finalmente, el gradiente no tiene una solución de forma cerrada. En su lugar, se implementa utilizando el algoritmo de propagación hacia atrás, que se describe a continuación (Shalev-Shwartz y Ben-David, 2014).

**SGD for Neural Networks**

**parameters:**  
 number of iterations  $\tau$   
 step size sequence  $\eta_1, \eta_2, \dots, \eta_\tau$   
 regularization parameter  $\lambda > 0$

**input:**  
 layered graph  $(V, E)$   
 differentiable activation function  $\sigma : \mathbb{R} \rightarrow \mathbb{R}$

**initialize:**  
 choose  $\mathbf{w}^{(1)} \in \mathbb{R}^{|E|}$  at random  
 (from a distribution s.t.  $\mathbf{w}^{(1)}$  is close enough to  $\mathbf{0}$ )

**for**  $i = 1, 2, \dots, \tau$   
 sample  $(\mathbf{x}, \mathbf{y}) \sim \mathcal{D}$   
 calculate gradient  $\mathbf{v}_i = \text{backpropagation}(\mathbf{x}, \mathbf{y}, \mathbf{w}, (V, E), \sigma)$   
 update  $\mathbf{w}^{(i+1)} = \mathbf{w}^{(i)} - \eta_i(\mathbf{v}_i + \lambda \mathbf{w}^{(i)})$

**output:**  
 $\bar{\mathbf{w}}$  is the best performing  $\mathbf{w}^{(i)}$  on a validation set

Figura 3-2: Algoritmo del descenso del gradiente estocástico.

Backpropagation
<p><b>input:</b>  example <math>(x, y)</math>, weight vector <math>w</math>, layered graph <math>(V, E)</math>,  activation function <math>\sigma : \mathbb{R} \rightarrow \mathbb{R}</math></p> <p><b>initialize:</b>  denote layers of the graph <math>V_0, \dots, V_T</math> where <math>V_t = \{v_{t,1}, \dots, v_{t,k_t}\}</math>  define <math>W_{t,i,j}</math> as the weight of <math>(v_{t,j}, v_{t+1,i})</math>  (where we set <math>W_{t,i,j} = 0</math> if <math>(v_{t,j}, v_{t+1,i}) \notin E</math>)</p> <p><b>forward:</b>  set <math>o_0 = x</math>  for <math>t = 1, \dots, T</math>    for <math>i = 1, \dots, k_t</math>      set <math>a_{t,i} = \sum_{j=1}^{k_{t-1}} W_{t-1,i,j} o_{t-1,j}</math>      set <math>o_{t,i} = \sigma(a_{t,i})</math></p> <p><b>backward:</b>  set <math>\delta_T = o_T - y</math>  for <math>t = T-1, T-2, \dots, 1</math>    for <math>i = 1, \dots, k_t</math>      <math>\delta_{t,i} = \sum_{j=1}^{k_{t+1}} W_{t,j,i} \delta_{t+1,j} \sigma'(a_{t+1,j})</math></p> <p><b>output:</b>  foreach edge <math>(v_{t-1,j}, v_{t,i}) \in E</math>    set the partial derivative to <math>\delta_{t,i} \sigma'(a_{t,i}) o_{t-1,j}</math></p>

Figura 3-3: Algoritmo de propagación hacia atrás.

A continuación, se explica cómo el algoritmo de propagación hacia atrás calcula el gradiente de la función de pérdida en un ejemplo  $(x,y)$  con respecto al vector  $w$ . Pero antes, se muestran dos ejemplos de cálculos Jacobianos, que serán usados más tarde (Shalev-Shwartz y Ben-David, 2014):

- Si  $f(w) = Aw$  para  $A \in \mathbb{R}^{m,n}$ . Entonces  $J_w(f) = A$ .
- Para cada  $n$ , se usa la notación  $\sigma$  para denotar la función de  $\mathbb{R}^n$  a  $\mathbb{R}^n$  que aplica la función sigmoide en cuanto a elementos. Es decir,  $\alpha = \sigma(\theta)$  significa que para cada  $i$  tenemos  $\alpha_i = \sigma(\theta_i) = \frac{1}{1+\exp(-\theta_i)}$ . Es fácil verificar que  $J_\theta(\sigma)$  es una matriz diagonal cuya entrada  $(i, i)$  es  $\sigma'(\theta_i)$ , donde  $\sigma'$  es la función derivada de la función sigmoidea (escalar), es decir,  $\sigma'(\theta_i) =$

$\frac{1}{(1+\exp(\theta_i))(1+\exp(-\theta_i))}$ . También se usa la notación  $\text{diag}(\sigma'(\theta))$  para denotar esta matriz.

La regla de la cadena que toma la derivada de una composición de funciones se puede escribir en términos del Jacobiano. Dadas dos funciones  $f: \mathbb{R}^n \rightarrow \mathbb{R}^m$  y  $g: \mathbb{R}^k \rightarrow \mathbb{R}^n$ , se tiene que el Jacobiano de la función de composición,  $(f \circ g): \mathbb{R}^k \rightarrow \mathbb{R}^m$ , en  $w$  es (Shalev-Shwartz y Ben-David, 2014):

$$\mathbf{J}_w(\mathbf{f} \circ \mathbf{g}) = \mathbf{J}_{\mathbf{g}(w)}(\mathbf{f})\mathbf{J}_w(\mathbf{g}) \quad (3.2)$$

Por ejemplo, para  $g(w) = Aw$ , donde  $A \in \mathbb{R}^{n,k}$ , se tiene que (Shalev-Shwartz y Ben-David, 2014):

$$\mathbf{J}_w(\sigma \circ \mathbf{g}) = \mathbf{diag}(\sigma'(Aw))A \quad (3.3)$$

Para describir el algoritmo de propagación hacia atrás, primero se descompone  $V$  en las capas, donde  $V$  corresponde al grafo de capas, tal que,  $V = \cup_{t=0}^T V_t$ , siendo  $V_t$  la capa de neuronas en el tiempo  $t$ . Para cada  $t$ ,  $V_t = \{v_{t,1}, \dots, v_{t,k_t}\}$ , donde  $k_t = |V_t|$ . Además, para cada  $t$  denotar  $W_t \in \mathbb{R}^{k_{t+1},k_t}$  una matriz de pesos de cada capa entre  $V_t$  y  $V_{t+1}$ . Si el borde existe en  $E$ , definido previamente como el conjunto finito de elementos de números enteros, que determina la longitud de la función de pesos del vector  $w \in \mathbb{R}^{|E|}$ , entonces establecemos  $W_{t,i,j}$  para ser los pesos, según  $w$ , del borde  $(v_{t,j}, v_{t+1,i})$  (Shalev-Shwartz y Ben-David, 2014).

A continuación, se discute cómo calcular las derivadas parciales con respecto a las capas de los bordes de  $V_{t-1}$  a  $V_t$ , con respecto a los elementos en  $W_{t-1}$ . Puesto que fijamos todos los demás pesos de la red, se deduce que las salidas de todas las neuronas

en  $V_{t-1}$  son números fijos que no dependen de los pesos en  $W_{t-1}$ . Denotar el vector correspondiente por  $\mathbf{o}_{t-1}$ . Además, se denota por  $\ell_t : \mathbb{R}^{k_t} \rightarrow \mathbb{R}$  la función de pérdida de la subred definida por capas  $V_t, \dots, V_T$  como una función de las salidas de las neuronas en  $V_t$ . La entrada a las neuronas de  $V_t$  se puede escribir como  $\mathbf{a}_t = W_{t-1}\mathbf{o}_{t-1}$  y la salida de las neuronas de  $V_t$  es  $\mathbf{o}_t = \sigma(\mathbf{a}_t)$ . Es decir, por cada  $j$  que tenemos  $o_{t,j} = \sigma(a_{t,j})$ . Se obtiene que la pérdida, como una función de  $W_{t-1}$ , se puede escribir como (Shalev-Shwartz y Ben-David, 2014):

$$\mathbf{g}_t(W_{t-1}) = \ell_t(\mathbf{o}_t) = \ell_t(\sigma(\mathbf{a}_t)) = \ell_t(\sigma(W_{t-1}\mathbf{o}_{t-1})) \quad (3.4)$$

Es conveniente reescribir esto de la siguiente manera. Sea  $\mathbf{w}_{t-1} \in \mathbb{R}^{k_{t-1}k_t}$  el vector columna obtenido concatenando las filas de  $W_{t-1}$  y luego tomando la transposición del vector largo resultante. Se define la matriz como  $O_{t-1} \in \mathbb{R}^{k_t \times (k_{t-1}k_t)}$  (Shalev-Shwartz y Ben-David, 2014).

$$O_{t-1} = \begin{pmatrix} \mathbf{o}_{t-1}^\top & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{o}_{t-1}^\top & \vdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{o}_{t-1}^\top \end{pmatrix} \quad (3.5)$$

Entonces,  $W_{t-1}\mathbf{o}_{t-1} = O_{t-1}\mathbf{w}_{t-1}$ , así que también se puede escribir

$$\mathbf{g}_t(\mathbf{w}_{t-1}) = \ell_t(\sigma(O_{t-1}\mathbf{w}_{t-1})) \quad (3.6)$$

Por lo tanto, al aplicar la regla de la cadena, se obtiene que

$$\mathbf{J}_{\mathbf{w}_{t-1}}(\mathbf{g}_t) = \mathbf{J}_{\sigma(O_{t-1}\mathbf{w}_{t-1})}(\ell_t) \mathbf{diag}(\sigma'(O_{t-1}\mathbf{w}_{t-1})) \quad (3.7)$$

Usando la notación tenemos  $\mathbf{o}_t = \sigma(O_{t-1}\mathbf{w}_{t-1})$  y  $\mathbf{a}_t = O_{t-1}\mathbf{w}_{t-1}$ , que rinde

$$\mathbf{J}_{\mathbf{w}_{t-1}}(\mathbf{g}_t) = \mathbf{J}_{\mathbf{o}_t}(\boldsymbol{\ell}_t) \mathbf{diag}(\boldsymbol{\sigma}'(\mathbf{a}_t)) \mathbf{O}_{t-1} \quad (3.8)$$

Denotar también que  $\delta_t = \mathbf{J}_{\mathbf{o}_t}(\boldsymbol{\ell}_t)$ . Entonces, se puede reescribir lo anterior como (Shalev-Shwartz y Ben-David, 2014):

$$\mathbf{J}_{\mathbf{w}_{t-1}}(\mathbf{g}_t) = (\boldsymbol{\delta}_{t,1} \boldsymbol{\sigma}'(\mathbf{a}_{t,1}) \mathbf{o}_{t-1}^T, \boldsymbol{\delta}_{t,k} \mathbf{o}_{t-1}^T) \quad (3.9)$$

Esto deja calcular  $\delta_t = \mathbf{J}_{\mathbf{o}_t}(\boldsymbol{\ell}_t)$  para cada  $t$ . Este es el gradiente de  $\ell_t$  en  $\mathbf{o}_t$ . Se calcula de una manera recursiva. Primero observar que para la última capa se tiene que  $\ell_T(\mathbf{u}) = \Delta(\mathbf{u}, y)$ , donde  $\Delta$  es la función de pérdida. Puesto que asumimos que  $\Delta(\mathbf{u}, y) = \frac{1}{2} \|\mathbf{u} - y\|^2$  obtenemos que  $\mathbf{J}_{\mathbf{u}}(\ell_T) = (\mathbf{u} - y)$ . En particular,  $\delta_T = \mathbf{J}_{\mathbf{o}_T}(\boldsymbol{\ell}_T) = \mathbf{O}_T - y$ . Además, tener en cuenta que (Shalev-Shwartz y Ben-David, 2014):

$$\boldsymbol{\ell}_t(\mathbf{u}) = \boldsymbol{\ell}_{t+1}(\boldsymbol{\sigma}(\mathbf{W}_t \mathbf{u})) \quad (3.10)$$

Por lo tanto, por la regla de la cadena:

$$\mathbf{J}_{\mathbf{u}}(\boldsymbol{\ell}_T) = \mathbf{J}_{\boldsymbol{\sigma}(\mathbf{W}_t \mathbf{u})}(\boldsymbol{\ell}_{t+1}) \mathbf{diag}(\boldsymbol{\sigma}'(\mathbf{W}_t \mathbf{u})) \mathbf{W}_t \quad (3.11)$$

En particular,

$$\boldsymbol{\delta}_t = \mathbf{J}_{\mathbf{o}_t}(\boldsymbol{\ell}_t) = \mathbf{J}_{\boldsymbol{\sigma}(\mathbf{W}_t \mathbf{o}_t)}(\boldsymbol{\ell}_{t+1}) \mathbf{diag}(\boldsymbol{\sigma}'(\mathbf{W}_t \mathbf{o}_t)) \mathbf{W}_t \quad (3.12)$$

$$= \mathbf{J}_{\mathbf{o}_{t+1}}(\boldsymbol{\ell}_{t+1}) \mathbf{diag}(\boldsymbol{\sigma}'(\mathbf{a}_{t+1})) \mathbf{W}_t \quad (3.13)$$

$$= \boldsymbol{\delta}_{t+1} \mathbf{diag}(\boldsymbol{\sigma}'(\mathbf{a}_{t+1})) \mathbf{W}_t \quad (3.14)$$

En resumen, se puede calcular primero los vectores  $\{\mathbf{a}_t, \mathbf{o}_t\}$  desde la parte inferior de la red hasta su parte superior. Luego, calculamos los vectores  $\{\delta_t\}$  desde la parte

superior de la red hasta su parte inferior. Una vez que se tienen todos estos vectores, las derivadas parciales se obtienen fácilmente usando la ecuación 3.9 demostrando, así como funciona la propagación hacia atrás junto con el descenso del gradiente estocástico (Shalev-Shwartz y Ben-David, 2014).

A continuación, se muestra el funcionamiento del optimizador utilizado en el estudio para los modelos, el optimizador Adam.

### 3.5 Optimizador *Adaptive Moment Estimation* (Adam)

En el capítulo anterior se muestra cómo funciona el algoritmo de propagación hacia atrás junto con el optimizador del descenso del gradiente estocástico, debido a que es de los optimizadores clásicos en el área del aprendizaje automático, sin embargo, en el estudio se utilizó el optimizador *Adaptive Moment Estimation* (Adam), que se procederá a explicar sus ventajas y funcionamiento.

La optimización estocástica basada en gradientes es de fundamental importancia en muchos campos de la ciencia e ingeniería. Muchos de los problemas en estos campos pueden ser abordados mediante algunas funciones objetivos de parámetros escalares que requieren de maximización o minimización con respecto a sus parámetros. Si la función es diferenciable con respecto a sus parámetros, el descenso del gradiente es un método relativamente eficiente, ya que la computación de las derivadas de primer orden de todos los parámetros tiene la misma complejidad computacional que solo evaluar la función. A menudo, las funciones objetivo son estocásticas. Por ejemplo, muchas funciones objetivo se componen de una suma de subfunciones evaluadas en diferentes submuestras de datos, en este caso, la optimización puede hacerse más eficiente tomando pasos de gradiente de subfunciones individuales, mediante el

descenso gradiente estocástico (SGD). Sin embargo, en la optimización de funciones objetivos estocásticas con espacios de parámetros de alta dimensión, los métodos de optimización de orden superior no son adecuados, debido a su lentitud y complejidad computacional, naciendo de ahí los métodos de primer orden (Knigman y Ba, 2017).

El algoritmo de Adam, un método para la optimización estocástico eficiente que sólo requiere de gradientes de primer orden con poco requerimiento de memoria. El método calcula las tasas individuales de aprendizaje adaptativo para diferentes parámetros de las estimaciones de los primeros y segundos momentos de los gradientes; el nombre Adam se deriva de la estimación del momento adaptativo. Algunas de las ventajas de este optimizador son que las magnitudes de las actualizaciones de parámetros son invariantes al gradiente, el tamaño de los pasos está delimitado aproximadamente por un hiperparámetro, trabaja con gradientes dispersos, entre otros (Knigman y Ba, 2017). A continuación, se muestra cómo funciona el algoritmo Adam. Se ha demostrado que para conseguir buenos ajustes para los problemas de aprendizaje automático el valor de los hiperparámetros debe ser  $\alpha = 0.001$ ,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$  and  $\epsilon = 10^{-8}$ .

```

Require:  $\alpha$ : Stepsize
Require:  $\beta_1, \beta_2 \in [0, 1)$ : Exponential decay rates for the moment estimates
Require:  $f(\theta)$ : Stochastic objective function with parameters  $\theta$ 
Require:  $\theta_0$ : Initial parameter vector
 $m_0 \leftarrow 0$  (Initialize 1st moment vector)
 $v_0 \leftarrow 0$  (Initialize 2nd moment vector)
 $t \leftarrow 0$  (Initialize timestep)
while  $\theta_t$  not converged do
   $t \leftarrow t + 1$ 
   $g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1})$  (Get gradients w.r.t. stochastic objective at timestep  $t$ )
   $m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t$  (Update biased first moment estimate)
   $v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2$  (Update biased second raw moment estimate)
   $\hat{m}_t \leftarrow m_t / (1 - \beta_1^t)$  (Compute bias-corrected first moment estimate)
   $\hat{v}_t \leftarrow v_t / (1 - \beta_2^t)$  (Compute bias-corrected second raw moment estimate)
   $\theta_t \leftarrow \theta_{t-1} - \alpha \cdot \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon)$  (Update parameters)
end while
return  $\theta_t$  (Resulting parameters)

```

Figura 3-4: Algoritmo Adam.

Todas las operaciones en vectores son elemento a elemento. Además, se denota como

$\beta_1^t$  y  $\beta_2^t$  a  $\beta_1$  y  $\beta_2$  a la potencia  $t$  (Knigman y Ba, 2017).

Sea  $f(\theta)$  una función objetivo ruidosa: una función escalar estocástica que es diferenciable con respecto a parámetros  $\theta$ . Y se desea minimizar el valor esperado de esta función,  $\mathbb{E}[f(\theta)]$  con respecto a sus parámetros  $\theta$ . Con  $f_1(\theta), \dots, f_T(\theta)$  se denotan las realizaciones de la función estocástica en los pasos de tiempo  $1, \dots, T$ . Con  $g_t = \nabla_{\theta} f_t(\theta)$  denotamos el gradiente, o en otras palabras el vector de derivadas parciales de  $f_t$ , con respecto a  $\theta$  evaluado en el paso temporal  $t$  (Knigman y Ba, 2017).

El algoritmo actualiza promedios móviles exponenciales del gradiente ( $m_t$ ) y del gradiente cuadrado ( $v_t$ ) donde los hiperparámetros  $\beta_1, \beta_2 \in [0, 1)$  controlan las tasas de decaimiento exponencial de estos promedios móviles. Los propios promedios móviles son estimaciones del primer momento (la media) y del segundo momento (la varianza) del gradiente. Sin embargo, estos promedios móviles se inicializan como

vectores de ceros, dando lugar a estimaciones de momento que están sesgadas hacia cero, especialmente durante los pasos de tiempo iniciales. Este sesgo de inicialización puede ser fácilmente contrarrestado con las estimaciones corregidas de sesgo  $\hat{m}_t$  y  $\hat{u}_t$  (Knigam y Ba, 2017).

A continuación, se muestra cómo funciona el primer tipo de red neuronal utilizado en el estudio, las redes neuronales LSTM.

### 3.6 Redes Recurrentes de Largo y Corto Plazo

La arquitectura de memoria de largo y corto plazo (LSTM) consiste en un set de subredes recurrentes conectadas, conocidas como bloques de memoria y creadas por Hochreiter y Schmidhuber en el año 1997 (Hochreiter y Schmidhuber, 1997). Estos bloques pueden ser pensados como una versión diferenciable de los chips de memoria de los computadores digitales. Cada bloque contiene una o más celdas de memoria conectadas a sí mismo, y tres unidades multiplicativas (puerta de entrada, salida y olvido) que proporcionan continua escritura, lectura y reinicio de las operaciones de las celdas (Graves, 2012).

Las puertas multiplicativas permiten a las celdas de memoria LSTM almacenar y acceder a información durante grandes periodos de tiempo, además de mitigar el problema del desvanecimiento del gradiente. Por ejemplo, tan largo como la puerta de entrada permanezca cerrada, la activación de la celda no sobrescribirá nueva información de entrada a la red neuronal, y por ende la información almacenada puede estar disponible mucho más tiempo, hasta que se abra la puerta de salida (Graves, 2012).

Antes de entrar en las ecuaciones que rigen a las redes LSTM, se denota  $w_{ij}$  como los pesos de la conexión de la unidad  $i$  a la unidad  $j$ , la entrada de la red neuronal a la unidad  $j$  en el tiempo  $t$  es denotado como  $a_j^t$  y la activación de la unidad  $j$  en el tiempo  $t$  es  $b_j^t$ . Las ecuaciones dadas son solamente para un bloque de memoria. Para el cálculo de múltiples bloques los cálculos son simplemente repetir las ecuaciones para cada bloque. Los subíndices  $l$ ,  $\phi$ , y  $\omega$  se refieren respectivamente a la puerta de entrada, de olvida y salida del bloque. El subíndice  $c$  se refiere a uno de los  $C$  celdas de memoria. Los pesos de la celda  $c$  para la puerta de entrada, olvido y salida son denotados por  $w_{cl}$ ,  $w_{c\phi}$  y  $w_{c\omega}$  respectivamente.  $s_c^t$  es el estado de la celda  $c$  en el tiempo  $t$ .  $f$  es la función de activación de las puertas, y  $g$  y  $h$  son respectivamente las funciones de activación de la celda de entrada y salida (Graves, 2012).

Se deja  $I$  como número de entradas,  $K$  para el número de salidas y  $H$  para el número de celdas en la capa oculta. Notar que solamente la salida de la celda  $b_c^t$  son conectadas con los otros bloques de la capa. Las otras activaciones de la red LSTM, tales como los estados, las celdas de entrada o las activaciones de las puertas, son solamente visibles dentro del bloque. Se usa el índice  $h$  para referirse a las salidas de la celda de otro bloque en la capa oculta, exactamente como en las unidades ocultas estándar. Como con las redes recurrentes estándar, el avance es calculado por un largo de  $T$  secuencias de entrada  $x$  empezando con  $t = 1$  y recursivamente aplicando la actualización de las ecuaciones mientras incrementa  $t$  (Graves, 2012).

Al igual que con las redes recurrentes estándar, todos los estados y activaciones son iniciados con ceros en  $t = 0$ .

Las ecuaciones que rigen a las redes LSTM son (Graves, 2012):

- Puerta de entrada:

$$\mathbf{a}_l^t = \sum_{i=1}^I \mathbf{w}_{il} \mathbf{x}_i^t + \sum_{h=1}^H \mathbf{w}_{hl} \mathbf{b}_h^{t-1} + \sum_{c=1}^C \mathbf{w}_{cl} \mathbf{s}_c^{t-1} \quad (3.15)$$

$$\mathbf{b}_l^t = f(\mathbf{a}_l^t) \quad (3.16)$$

- Puerta de olvido:

$$\mathbf{a}_\phi^t = \sum_{i=1}^I \mathbf{w}_{i\phi} \mathbf{x}_i^t + \sum_{h=1}^H \mathbf{w}_{h\phi} \mathbf{b}_h^{t-1} + \sum_{c=1}^C \mathbf{w}_{c\phi} \mathbf{s}_c^{t-1} \quad (3.17)$$

$$\mathbf{b}_\phi^t = f(\mathbf{a}_\phi^t) \quad (3.18)$$

- Celda:

$$\mathbf{a}_c^t = \sum_{i=1}^I \mathbf{w}_{ic} \mathbf{x}_i^t + \sum_{h=1}^H \mathbf{w}_{hc} \mathbf{b}_h^{t-1} \quad (3.19)$$

$$\mathbf{s}_c^t = \mathbf{b}_\phi^t \mathbf{s}_c^{t-1} + \mathbf{b}_l^t \mathbf{g}(\mathbf{a}_c^t) \quad (3.20)$$

- Puerta de salida:

$$\mathbf{a}_\omega^t = \sum_{i=1}^I \mathbf{w}_{i\omega} \mathbf{x}_i^t + \sum_{h=1}^H \mathbf{w}_{h\omega} \mathbf{b}_h^{t-1} + \sum_{c=1}^C \mathbf{w}_{c\omega} \mathbf{s}_c^t \quad (3.21)$$

$$\mathbf{b}_\omega^t = f(\mathbf{a}_\omega^t) \quad (3.22)$$

- Celda de salida:

$$\mathbf{b}_c^t = \mathbf{b}_\omega^t \mathbf{h}(\mathbf{s}_c^t) \quad (3.23)$$

A continuación, se muestra explicada la matemática detrás del segundo modelo de redes utilizada en el estudio, las redes convolucionales.

### 3.7 Redes Convolucionales

Se puede describir las acciones de una capa genérica de una red convolucional (CNN) como un mapa dependiente de parámetros que toma como entrada un tensor de canales  $m_1$ , donde cada canal es una matriz de tamaño  $n_1 \times \ell_1$ , y produce un tensor de canales  $m_2$ , donde cada canal es una matriz de tamaño  $n_2 \times \ell_2$ . Los parámetros que se deben aprender a través del descenso de gradiente son un conjunto de filtros  $m_2$ , cada uno de tamaño  $p \times q$ . Para representar la entrada, se usa un punto  $x \in \mathbb{R}^{n_1 \times \ell_1} \otimes \mathbb{R}^{m_1}$ , y se representa los parámetros como  $W \in \mathbb{R}^{p \times q} \otimes \mathbb{R}^{m_2}$ . Tener en cuenta que, en la aplicación, casi siempre se da el caso que los filtros  $p \ll n_1$  and  $q \ll \ell_1$  son mucho más pequeños que las entradas. Si se usa  $\{e_j\}_{j=1}^{m_1}$  para denotar una base ortonormal para  $\mathbb{R}^{m_1}$ , y  $\{\bar{e}_j\}_{j=1}^{m_2}$  para denotar una base ortonormal para  $\mathbb{R}^{m_2}$ , se puede escribir  $x$  y  $W$  como sigue (Caterini, 2017):

$$x = \sum_{j=1}^{m_1} x_j \otimes e_j, \quad W = \sum_{j=1}^{m_2} W_j \otimes \bar{e}_j \quad (3.24)$$

donde se refiere a cada  $x_j \in \mathbb{R}^{n_1 \times \ell_1}$  como un mapa de características, y cada  $W_j \in \mathbb{R}^{p \times q}$  como un filtro utilizado en la convolución. Entonces, se puede escribir la función genérica por cada como  $f : (\mathbb{R}^{n_1 \times \ell_1} \otimes \mathbb{R}^{m_1}) \times (\mathbb{R}^{p \times q} \otimes \mathbb{R}^{m_2}) \rightarrow \mathbb{R}^{n_2 \times \ell_2} \otimes \mathbb{R}^{m_2}$  (Caterini, 2017):

$$f(x; W) \in \mathbb{R}^{n_2 \times \ell_2} \otimes \mathbb{R}^{m_2} \quad (3.25)$$

para todas las  $x$  y  $W$  como se describió anteriormente.

Tener en cuenta que, a lo largo de esta sección, se va a utilizar  $\{E_{j,k}\}_{j,k=1}^{n_1, \ell_1}$  para denotar una base ortonormal para  $\mathbb{R}^{n_1 \times \ell_1}$ ,  $\{\tilde{E}_{j,k}\}_{j,k=1}^{p,q}$ , denotar una base ortonormal para  $\mathbb{R}^{p \times q}$ ,  $\{\bar{E}_{j,k}\}_{j,k=1}^{n_2, \ell_2}$  para denotar una base ortonormal para  $\mathbb{R}^{n_2 \times \ell_2}$ , y  $\{\hat{E}_{j,k}\}_{j,k=1}^{\hat{n}_1, \hat{\ell}_1}$  para denotar una base ortonormal para el espacio  $\mathbb{R}^{\hat{n}_1 \times \hat{\ell}_1}$  (intermedio y aún no definido). Se necesita desarrollar la notación de la operación de *cropping* antes de poder expresar las acciones de convolución. Se puede definir el operador *cropping* por los índices  $(k, l)$ ,  $K_{k,l} \in \mathcal{L}(\mathbb{R}^{n_1 \times \ell_1} \otimes \mathbb{R}^{m_1}; \mathbb{R}^{p \times q})$ , como (Caterini, 2017):

$$K_{k,l} \left( \sum_{j=1}^{m_1} x_j \otimes e_j \right) \equiv \sum_{j=1}^{m_1} k_{k,l}(x_j) \quad (3.26)$$

donde se define  $K_{k,l} \in \mathcal{L}(\mathbb{R}^{n_1 \times \ell_1}; \mathbb{R}^{p \times q})$  como:

$$k_{k,l}(x_j) \equiv \sum_{s=1}^p \sum_{t=1}^q \langle x_j, E_{k+s-1, l+t-1} \rangle \tilde{E}_{s,t} \quad (3.27)$$

para cualquier  $k \in [n_1 - p + 1]$  y  $l \in [l_1 - q + 1]$ . Cuando  $\{E_{j,k}\}_{j,k}$  y  $\{\tilde{E}_{s,t}\}_{s,t}$  son bases estándar de sus respectivos espacios,  $k_{k,l}(x_j)$  es la  $p \times q$  submatriz de  $x_j$ , que contiene los elementos  $(k, l)$  a  $(k + p - 1, l + q - 1)$  de  $x_j$ , inclusive.

Para llegar a lo anterior, primero se define el operador de *embedding* en el índice  $(k, l)$ ,  $\mathbf{Em}_{k,l} \in \mathcal{L}(\mathbb{R}^{p \times q}; \mathbb{R}^{n_1 \times \ell_1})$ , como (Caterini, 2017):

$$\mathbf{Em}_{k,l}(\mathcal{Y}) \equiv \sum_{s=1}^p \sum_{t=1}^q \langle \mathcal{Y}, \tilde{E}_{s,t} \rangle E_{k+s-1, l+t-1} \quad (3.28)$$

para cualquier  $\mathcal{Y} \in \mathbb{R}^{p \times q}$ ,  $k \in [n_1 - p + 1]$ , y  $l \in [l_1 - q + 1]$ , que corresponda al *embedding* de  $\mathcal{Y}$  en la matriz cuando  $\{E_{j,k}\}_{j,k}$  es la base estándar (Caterini, 2017).

Ahora se usa el operador *cropping*  $K_{k,l}$  para definir la acción de la convolución. El operador de convolución, que se denota por  $C$ , es un mapa que convoluciona los filtros con los mapas de características. Más formalmente, se puede escribir el operador de convolución  $C \in \mathcal{L}(\mathbb{R}^{p \times q} \otimes \mathbb{R}^{m_2}, \mathbb{R}^{n_1 \times \ell_1} \otimes \mathbb{R}^{m_1}; \mathbb{R}^{\hat{n}_1 \times \hat{\ell}_1} \otimes \mathbb{R}^{m_2})$  cómo (Caterini, 2017):

$$C(W, x) = \sum_{j=1}^{m_2} c_j(W, x) \otimes \bar{e}_j \quad (3.29)$$

donde  $c_j \in \mathcal{L}(\mathbb{R}^{p \times q} \otimes \mathbb{R}^{m_2}, \mathbb{R}^{n_1 \times \ell_1} \otimes \mathbb{R}^{m_1}; \mathbb{R}^{\hat{n}_1 \times \hat{\ell}_1} \otimes \mathbb{R}^{m_2})$  es un operador que define la mecánica de la convolución. Se puede escribir explícitamente  $c_j$  para toda  $j \in [m_2]$  usando el operador *cropping* (Caterini, 2017):

$$c_j(W, x) = \sum_{k=1}^{\hat{m}_1} \sum_{\ell=1}^{\hat{\ell}_1} \langle W_j, k_{\gamma(k,l,\Delta)}(x) \rangle \hat{E}_{k,l} \quad (3.30)$$

Donde  $W = \sum_{j=1}^{m_2} W_j \otimes \bar{e}_j$ ,

$$\gamma(k, l, \Delta) = (\mathbf{1} + (k - 1)\Delta, \mathbf{1} + (l - 1)\Delta) \quad (3.31)$$

es la abreviatura de los índices del operador *cropping*,  $\Delta \in \mathbb{Z}_{>0}$  define el paso de la convolución.

Tener en cuenta que  $c_j(W, x)$  produce un nuevo mapa de características para cada  $j \in [m_2]$  post-convolución, lo que significa que podemos ver a  $C(W, x)$  como una pila de  $m_2$  mapas de características, o como un tensor de  $m_2$  canales. Como resumen, se puede describir el operador de convolución de la siguiente manera: primero el operador *cropping* funciona sobre los mapas de características de entrada, se convoluciona los

mapas recortados con el filtro  $W_j$ , y luego se suman las contribuciones al mapa de características para cada  $k \in [\hat{n}_1]$  y  $l \in [\hat{\ell}_1]$  (Caterini, 2017).

A continuación, se muestra la explicación teórica y matemática del autoencoder variacional, partiendo desde la definición de un autoencoder, donde van incorporados los dos modelos de redes neuronales explicadas previamente.

### 3.8 Autoencoder Variacional

El autoencoder variacional (VAE) es un modelo generativo y para entenderlo es necesario primero entender que es un autoencoder. Un autoencoder consiste en una red neuronal de codificación  $F$  que mapea un set de datos  $X \subset \mathbb{R}^n$  a  $\mathbb{R}^d$ , donde  $d$  es típicamente mucho menor que  $n$ , junto con una red neuronal de decodificación  $H$  que decodifica los elementos de  $\mathbb{R}^d$  a  $\mathbb{R}^n$ . En otras palabras, un autoencoder codifica las  $n$ -dimensiones de variables del set de datos a  $d$ -dimensiones latentes, para luego convertir las variables latentes de nuevo a las variables originales. Los autoencoder pueden ser vistos como compresores de datos que comprimen un set de datos de una alta cantidad de dimensiones, en un set de datos con una cantidad menor de dimensiones sin perder mucha información en el proceso. Por ejemplo, el set de datos MNIST consiste en imágenes de  $28 \times 28$  donde  $\mathbb{R}^{784}$ . Un autoencoder puede fácilmente comprimir ese set de datos a un set de datos de  $\mathbb{R}^{10}$  usando solamente 10 variables latentes sin perder mucha información (Wang, 2020).

La función de pérdida para el entrenamiento de un autoencoder es típicamente el promedio del error cuadrático (MSE).

$$L_{AE} = \frac{1}{N} \sum_{x \in X} \|H(F(x)) - x\|^2 \quad (3.32)$$

Donde  $N$  es el tamaño de  $X$ .

Los VAEs son redes neuronales con similar estructura que los autoencoder, pero incorpora estocacidad dentro de la red neuronal. Los autoencoders son redes neuronales determinísticas en el sentido que la salida es completamente determinada por la entrada. Para hacer modelos generativos los autoencoders necesitan añadir aleatoriedad a su espacio latente. En los autoencoder, los datos de entrada  $x$  son codificados en variables latentes  $z = F(x) \in \mathbb{R}^d$ , donde son decodificados a  $\hat{x} = H(F(z))$ . La diferencia entre un VAE y un autoencoder es que la entrada  $x$  es codificada en una variable aleatoria Gaussiana  $z = z(x)$  en  $\mathbb{R}^d$  con una media  $\mu(x)$  y varianza  $\sigma^2(x)$ . Donde  $\sigma^2(x) = [\sigma_1^2(x), \dots, \sigma_d^2(x)]^T \in \mathbb{R}^d$ . Otra forma de verlo es que en un autoencoder existe un codificador  $F$ , mientras que en un VAE existen dos codificadores  $\mu$  y  $\sigma^2$  siendo la media y varianza de la variable latente  $z$ . Pero al igual que un autoencoder, ambos tienen un decodificador  $H$  (Wang, 2020).

Existen algunas restricciones para  $\mu(x)$  y  $\sigma^2(x)$ . El VAE sigue las siguientes heurísticas para el entrenamiento.

- El decodificador  $H$  decodifica las variables aleatorias latentes  $z(x)$  a  $\hat{x}$  para que sea lo más cercano a  $x$ .
- La variable aleatoria  $Z = z(x)$  con  $x$  una muestra de  $X$  es cercana a una distribución normal estándar  $N(0,1)$ .

Las heurísticas se realizan mediante la función de pérdida que consiste en dos componentes. La primera es el error cuadrático medio entre  $\hat{x}$  y  $x$ , y la segunda la divergencia de Kullback-Leibler entre  $Z$  y  $N(0, I_d)$  (Wang, 2020).

La divergencia de Kullback-Leibler es una medida teórica de la proximidad entre dos distribuciones y se define de la siguiente manera (Blei et al. 2017):

$$\mathbf{q}(\mathbf{z})^* = \mathit{argmin}_{\mathbf{q}(\mathbf{z}) \in \mathcal{Q}} KL(\mathbf{q}(\mathbf{z}) || \mathbf{p}(\mathbf{z}|\mathbf{x})) \quad (3.33)$$

Donde  $\mathbf{X} = x_{1:n}$  es el set de variables observadas y  $\mathbf{Z} = z_{1:m}$  es el set de variables latentes,  $\mathcal{Q}$  es una familia de distribuciones normales,  $\mathbf{p}(\mathbf{z}|\mathbf{x})$  es la distribución condicional de las variables latentes dado las variables observadas, y  $\mathbf{q}(\mathbf{z})$  es una distribución perteneciente a  $\mathcal{Q}$ .

La divergencia de Kullback-Leibler es por definición (Blei et al. 2017):

$$KL(\mathbf{q}(\mathbf{z}) || \mathbf{p}(\mathbf{z}|\mathbf{x})) = E(\log(\mathbf{q}(\mathbf{z}))) - E(\log(\mathbf{p}(\mathbf{z}|\mathbf{x}))) \quad (3.34)$$

La ecuación 3.34 no se puede resolver, por el simple hecho que la distribución  $\mathbf{p}(\mathbf{z}|\mathbf{x})$  es desconocida.

Antes de seguir se introduce el Teorema de Bayes (Blei et al. 2017):

$$\mathbf{p}(\mathbf{z}|\mathbf{x}) = \frac{\mathbf{p}(\mathbf{z}, \mathbf{x})}{\mathbf{p}(\mathbf{x})} = \frac{\mathbf{p}(\mathbf{x}|\mathbf{z})\mathbf{p}(\mathbf{z})}{\mathbf{p}(\mathbf{x})} \quad (3.35)$$

Entonces utilizando la ecuación 3.35, para reemplazar el término de la derecha de la ecuación 3.34, quedando:

$$KL(q(z)||p(z|x)) = E(\log(q(z)) - E(\log(p(z, x)))) + E(\log(p(x))) \quad (3.36)$$

La cual depende de la distribución  $p(x)$  que requiere de tiempos exponenciales para ser resuelta. Debido a eso se busca una forma alternativa y se introduce un nuevo término llamado evidencia del límite inferior (ELBO) (Blei et al. 2017):

$$ELBO(q) = E(\log(p(z, x))) - E(\log(q(z))) \quad (3.37)$$

El ELBO es equivalente a los dos primeros términos de la ecuación 3.36 pero multiplicados por -1, por lo que la ecuación 3.36 se puede reescribir de la siguiente forma:

$$KL(q(z)||p(z|x)) = -ELBO(q) + E(\log(p(x))) \quad (3.38)$$

Reordenando los términos queda:

$$KL(q(z)||p(z|x)) + ELBO(q) = E(\log(p(x))) \quad (3.39)$$

Llegado este punto, se reitera que lo que se busca realizar es disminuir lo máximo posible la divergencia de Kullback-Leibler, y para lograrlo se debe maximizar el  $ELBO(q)$ . Sacando la divergencia de Kullback-Leibler en la ecuación 3.39, se obtiene la siguiente desigualdad (Blei et al. 2017).

$$ELBO(q) \leq E(\log(p(x))) \quad (3.40)$$

Es decir, en el mejor de los casos el  $ELBO(q)$  llega a ser la distribución desconocida, pero siempre el  $ELBO(q)$  es un límite por debajo de la distribución desconocida, y de ahí su nombre evidencia del límite inferior o ELBO por las iniciales de su nombre en inglés. Para maximizar el  $ELBO(q)$ , se toma la ecuación 3.37 donde se define el

ELBO(q) y se le aplica el teorema de bayes de la ecuación 3.35 al primer término del ELBO(q) (Blei et al. 2017).

$$ELBO(q) = E(\log(p(x|z))) + E(\log(p(z))) - E(\log(q(z))) \quad (3.41)$$

Los dos términos de la derecha forman una nueva divergencia de Kullback-Leibler, quedando:

$$ELBO(q) = E(\log(p(x|z))) - KL(q(z)||p(z)) \quad (3.42)$$

Como el primer término de la ecuación 3.42 es una constante, ya que es una función de  $p(x|z)$ , y se busca optimizar el ELBO de la distribución  $q$ , la acción de maximizar el ELBO(q) se reduce a minimizar la nueva divergencia de Kullback-Leibler que ahora si depende de funciones conocidas, ya que  $q(z)$  proviene de una familia de distribuciones  $Q$ , y  $p(z)$  es la distribución del espacio latente (Blei et al. 2017).

Asumiendo que la familia  $Q$  son distribuciones normales  $(\mu, \sigma^2)$ , y el espacio latente es una distribución  $N(0,1)$ , el desarrollo de la nueva divergencia de Kullback-Leibler es (Kingma y Welling, 2014):

$$- \left( E(\log(q(z))) - E(\log(p(z))) \right) \quad (3.43)$$

$$E(\log(p(z))) - E(\log(q(z))) \quad (3.44)$$

$$\int q(z) \log(p(z)) dz - \int q(z) \log(q(z)) dz \quad (3.45)$$

$$\begin{aligned} & \int_1^J N(z; \mu_j, \sigma_j^2) \log(N(z; \mathbf{0}, \mathbf{1})) dz - \\ & \int_1^J N(z; \mu_j, \sigma_j^2) \log(N(z; \mu_j, \sigma_j^2)) dz \end{aligned} \quad (3.46)$$

Se reemplaza cada distribución normal por su función de densidad y se resuelven las integrales (Kingma y Welling, 2014).

$$\begin{aligned} & -\frac{J}{2} \log(2\pi) - \frac{1}{2} \sum_{i=1}^J (\mu_j^2 + \sigma_j^2) - \left( \frac{J}{2} \log(2\pi) - \right. \\ & \left. \frac{1}{2} \sum_{i=1}^J (1 + \log(\sigma_j^2)) \right) \end{aligned} \quad (3.47)$$

$$\frac{1}{2} \sum_{i=1}^J (1 + \log(\sigma_j^2) - \mu_j^2 - \sigma_j^2) \quad (3.48)$$

En palabras, se busca que cada dimensión  $j$  del espacio latente que proviene de una distribución normal  $(\mu, \sigma^2)$ , sumado con las otras  $J - 1$  dimensiones, formen una normal  $(0,1)$  en el espacio latente, para cada dato de entrada  $x \in X$  (Kingma y Welling, 2014).

En el estudio se utilizaron ambas funciones de pérdida, el error cuadrático de la ecuación 3.32, más la divergencia de Kullback-Leibler de la ecuación 3.48.

Otro aspecto importante dentro del autoencoder variacional, es el uso del truco de la reparametrización. Este truco consiste en incorporar una variable auxiliar por la cual se pueda seguir propagando el error dentro de la red neuronal al momento de realizar la propagación hacia atrás. En caso de no existir esta variable auxiliar la propagación

hacia atrás de detiene al llegar a la capa donde se realiza el muestreo proveniente de los parámetros ya definidos  $\mu$  y  $\sigma$ , debido a que la ecuación del muestreo es simplemente no diferenciable. Cabe notar que la ecuación de muestreo no diferenciable es igual a la ecuación 3.49 sin el parámetro  $\varepsilon$ . En el caso del autoencoder variacional el término auxiliar que se incorpora es  $\varepsilon$ , donde  $\varepsilon \sim N(0,1)$ , el cual asegura que la ecuación 3.49 sea siempre diferenciable, quedando la reparametrización como (Kingma y Welling, 2014):

$$\mathbf{z} = \boldsymbol{\mu} + \boldsymbol{\varepsilon} * \boldsymbol{\sigma} \quad (3.49)$$

En el siguiente capítulo se muestra la explicación matemática del modelo de clusterización utilizado en el estudio, la Mezcla de Gaussianas.

### 3.9 Mezcla de Gaussianas

La distribución Gaussiana es la distribución de probabilidades más estudiada para variables aleatorias continuas. Para una variable aleatoria univariada la distribución Gaussiana tiene una función de densidad de probabilidad dada por (Deisenroth et al. 2020):

$$N(X|\boldsymbol{\mu}, \boldsymbol{\sigma}) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (3.50)$$

Donde  $X$  es una variable aleatoria  $\in \mathbb{R}^1$ , y los términos  $\mu$  y  $\sigma$  corresponden a los valores de media y desviación estándar de la distribución normal respectivamente.

La distribución de probabilidades normal multivariante, que es la generalización de la distribución de probabilidad normal para un conjunto de distribuciones gaussianas, tiene una función de densidad de probabilidad dada por (Deisenroth et al. 2020):

$$N(\mathbf{X}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\sqrt{2\pi}^n \sqrt{|\boldsymbol{\Sigma}|}} e^{(-\frac{1}{2}(\mathbf{X}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{X}-\boldsymbol{\mu}))} \quad (3.51)$$

Donde  $\mathbf{X}$  corresponde al vector de la variable aleatoria  $\in \mathbb{R}^n$ ,  $\boldsymbol{\mu} = [\mu_1, \dots, \mu_n]^T$  vector de medias  $\in \mathbb{R}^n$ , y  $\boldsymbol{\Sigma}$  matriz de covarianzas  $\in \mathbb{R}^{n \times n}$ .

Una vez expuestas las distribuciones anteriores, el modelo de mezcla de gaussianas (GMM) es un modelo de función de densidad de probabilidad que combina una cantidad finita de  $K$  distribuciones Gaussianas  $N(\mathbf{X}|\mu_k, \Sigma_k)$  que pueden ser descritas como múltiples clústeres tal que (Deisenroth et al. 2020):

$$P(\mathbf{x}|\boldsymbol{\theta}) = \sum_{k=1}^K \pi_k N(\mathbf{x}_n|\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \quad (3.52)$$

$$\sum_{k=1}^K \pi_k = \mathbf{1} \quad (3.53)$$

$$\mathbf{0} \leq \boldsymbol{\pi}_k \leq \mathbf{1} \quad (3.54)$$

Donde  $k = 1, \dots, K$  número de distribuciones Gaussianas a mezclar,  $\mathbf{X}$  vector de datos dados con  $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ , con  $n = 1, \dots, N$ , número de variables aleatorias de la distribución desconocida  $p(\mathbf{x})$ . Los parámetros del GMM son  $\boldsymbol{\mu}_k = [\mu_1, \dots, \mu_K]^T$  vector de medias  $\in \mathbb{R}^K$ ,  $\boldsymbol{\Sigma}_k$  matriz de covarianzas  $\in \mathbb{R}^{K \times K}$  y  $\boldsymbol{\pi}_k = [\pi_1, \dots, \pi_K]^T$  vector de pesos  $\in \mathbb{R}^K$ . Además,  $\boldsymbol{\theta} := \{\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k, \boldsymbol{\pi}_k : k = 1, \dots, K\}$  como la colección de parámetros del modelo.

El objetivo es encontrar una buena aproximación de la distribución desconocida  $p(\mathbf{x})$  mediante la mezcla de Gaussianas. Para ello se utiliza la técnica de optimizadores de máxima verosimilitud, donde se maximiza la siguiente función (Deisenroth et al. 2020):

$$L = \sum_{n=1}^N \log \sum_{k=1}^K \pi_k N(x_n | \mu_k, \Sigma_k) \quad (3.55)$$

Se apunta a encontrar los parámetros  $\theta$  que maximizan la función  $L$ .

El siguiente paso es reemplazar la distribución  $N(x_n | \mu_k, \Sigma_k)$  que se encuentra dentro de la función  $L$ , por la función de densidad de probabilidad de la distribución normal multivariada, luego, derivar por cada uno de los parámetros  $\theta$  e igualar a 0, y obtener los siguientes resultados (Deisenroth et al. 2020):

$$\mu_k = \frac{\sum_{n=1}^N \gamma_{nk} x_n}{\sum_{n=1}^N \gamma_{nk}} \quad (3.56)$$

$$\Sigma_k = \frac{\sum_{n=1}^N \gamma_{nk} (x_n - \mu_k)(x_n - \mu_k)^T}{\sum_{n=1}^N \gamma_{nk}} \quad (3.57)$$

$$\pi_k = \frac{1}{N} \sum_{n=1}^N \gamma_{nk} \quad (3.58)$$

Donde:

$$\gamma_{nk}(X) = \frac{\pi_k N(x_n | \mu_k, \Sigma_k)}{\sum_{k=1}^K \pi_k N(x_n | \mu_j, \Sigma_j)} \quad (3.59)$$

Notar que  $\gamma_n := [\gamma_{n1}, \dots, \gamma_{nK}]^T \in \mathbb{R}^K$  es un vector de probabilidad normalizado.

El proceso parte con valores aleatorios de los parámetros  $\theta$ . Se usan esos parámetros aleatorios  $\theta$  para resolver las ecuaciones descritas anteriormente obteniendo así nuevos valores de parámetros  $\theta$ . Se repite este procedimiento hasta que la diferencia entre cada iteración converja (Deisenroth et al. 2020).

#### **4. CASO DE ESTUDIO**

Una vez explicado las bases matemáticas de los modelos, se abordan dos casos de estudio del sistema propuesto de identificación de estados fisiológico, el primero sobre 6 personas que fueron monitoreadas durante una semana, y el segundo caso aplicado a un repositorio de datos externos de personas que realizan actividad física por periodos más cortos. Además, se explicita un análisis de los rendimientos de los modelos para cada caso.

##### **4.1 Recolección y Análisis de Datos**

La recolección de datos para el primer caso de estudio fue tomada entre enero y julio del año 2019, en el Instituto de Ingeniería Biológica y Médica de la Pontificia Universidad Católica de Chile (Suárez et al. 2021). Los criterios de inclusión y exclusión de los participantes, era que fueran personas hombres entre 18 y 35 años que no posean problemas de sueño, un consumo de menos de tres unidades de alcohol por semana, menos de tres tazas de café por día, y no tengan cambios de turno de trabajo o viajes a otras zonas horarias durante el estudio o durante el mes anterior al estudio. Los participantes fueron monitoreados durante una semana, mediante el dispositivo Equivital Life Monitor (manufacturados en Reino Unido). Este dispositivo posee un sistema de monitoreo fisiológico que graba la fecha, hora (hasta milisegundo), frecuencia respiratoria, la temperatura corporal, electrocardiograma mediante tres electrodos, y la posición del cuerpo. Cabe notar que un electrocardiograma puede tener 12 derivaciones, que hacen referencia al punto de vista que se tiene del mismo estímulo eléctrico, y en este caso, los electrodos no están ubicados en los lugares convencionales definidos por el triángulo de Einthoven, por lo que no se puede comparar con las derivaciones clásicas. En la Figura 4-1, se muestran la ubicación de los electrodos.

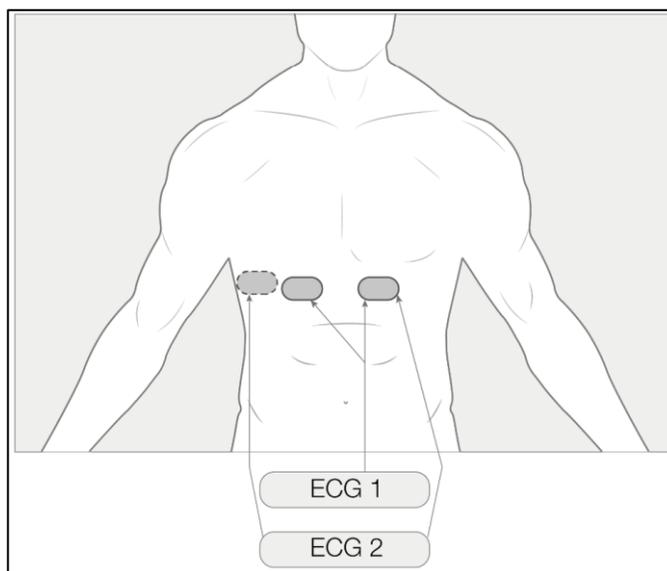


Figura 4-1: Ubicación electrodos.

El muestreo del electrocardiograma se realiza con una frecuencia de 256 Hz, y 0.25Hz para las otras variables fisiológicas. No obstante, la frecuencia respiratoria es calculada por el dispositivo como una media móvil de 60 segundos y reportada cada 15 segundos. Una imagen del dispositivo Equivital Life Monitor se muestra en la Figura 4-2, sacada de su página oficial.



Figura 4-2: Dispositivo Equivital Life Monitor.

La cantidad de datos que existen de cada variable fisiológica es de 107 millones, 153 millones, 132 millones, 146 millones, 143 millones y 152 millones de datos para las personas número 2, 3, 4, 7, 8 y 9 respectivamente. El número hace referencia al número que tiene en la base de datos ese participante. Cabe notar que la base de datos contiene más que los datos de estas 6 personas, pero se seleccionaron estos debido a la buena calidad de los datos registrados, y a su cantidad de datos registrados.

A continuación, se explica el preprocesamiento que se le aplica a las variables fisiológicas.

El primer paso, es cargar una serie de documentos Excel desde una carpeta a la plataforma Jupyter desde un entorno creado en Anaconda mediante un script escrito en lenguaje Python. Aquí se une todos los Excel en un solo dataframe mediante la librería Pandas. Cabe notar que este proceso se realiza sobre los datos de cada persona por separado, debido a que la memoria RAM necesaria para cargar todos los documentos en un mismo script sobrepasa la capacidad computacional del equipo usado en el estudio.

El paso dos, es dividir los datos en dos grupos en la proporción 9:1 donde la mayor parte corresponde a la parte de entrenamiento, y la parte menor a la parte de validación. La diferencia entre ambas es que la segunda parte no se usa para entrenar, sino para comparar los resultados y comprobar que el modelo no se sobre ajusta a los datos de entrenamiento y por ende rindiera mal en aquellos datos que no vio en el entrenamiento.

El paso tres, es calcular los intervalos RR utilizando los datos de electrocardiograma.

El intervalo RR es el tiempo que transcurre entre cada latido del corazón. En la Figura 4-3 se muestra una imagen de los intervalos RR.

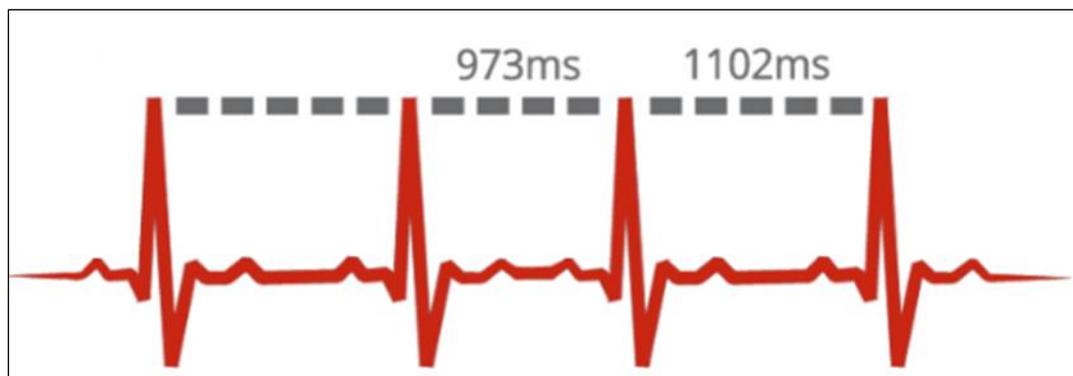


Figura 4-3: Intervalos RR.

El algoritmo creado que automatiza la creación de los intervalos RR es una función que recorre los datos del electrocardiograma del dataframe de cada persona, y cuando encuentra un valor que supere los 0,3 milivoltios guarda esa posición de la fila del dataframe, luego recorre 50 datos más buscando otro valor que supere los 0,3 milivoltios. En caso de que encuentre un valor superior reemplaza la posición anterior por esta nueva posición, y realiza nuevamente la búsqueda. En caso contrario, se guarda esa posición como un latido.

Cabe notar que la señal de electrocardiograma, cuando es registrada y tomada por el algoritmo que se describió recién, previamente ya ha pasado por un filtro existente dentro del dispositivo Equival Life Monitor. Este filtro es llamado, filtrado ambulatorio que busca optimizar la confiabilidad de la detección de la onda R bajo alta actividad (por ejemplo, correr) y elimina cantidades significativas de los elementos de baja frecuencia de la forma de onda del electrocardiograma que no son necesarios.

Una vez que se encuentran todos los latidos, se restan las horas asociadas a esos latidos, obteniendo como resultado el tiempo que transcurre entre cada latido, siendo este valor el intervalo RR.

Esos intervalos RR se llaman en este estudio, intervalos RR crudos, ya que aún no han sido ajustados. Los intervalos RR crudos de entrenamiento generados con los datos de la persona número 2 se muestran en el histograma de la Figura 4-4. Se muestran los histogramas de intervalos RR de entrenamiento de las otras 5 personas en los anexos.

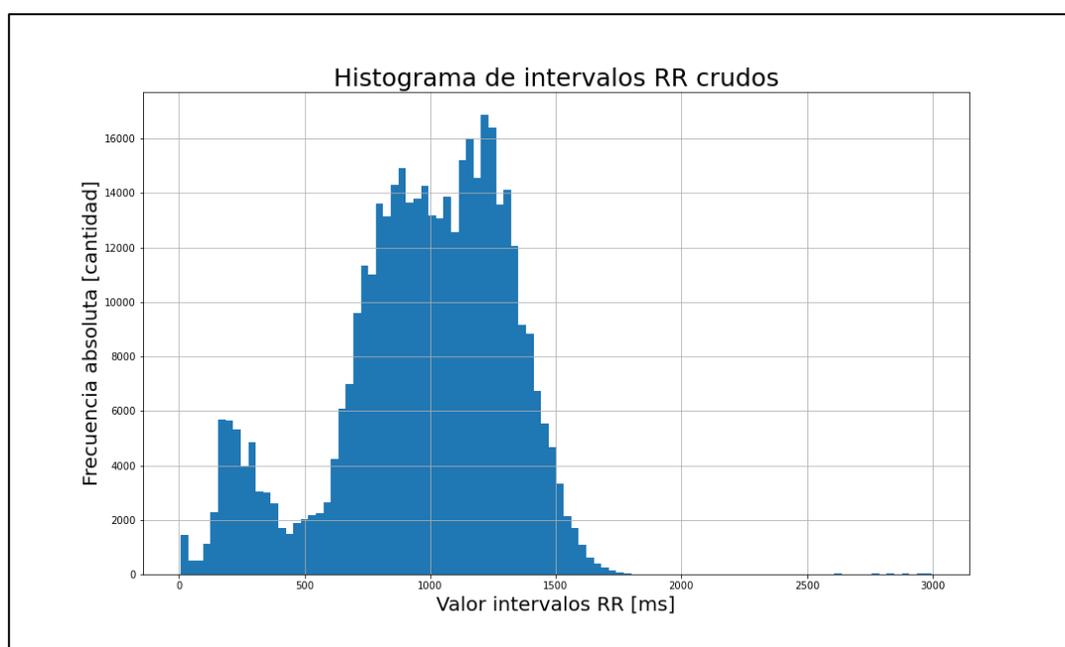


Figura 4-4: Histograma intervalos RR de entrenamiento persona número 2.

Los intervalos RR llamados intervalos RR buenos, a diferencia de los intervalos RR crudos, son aquellos donde los datos que posean intervalos RR anómalos son eliminados. Según la *American Heart Association*, en su página oficial publica que las personas que poseen el mismo rango etario de los participantes de este estudio deberían tener hasta 157 latidos por minuto durante una actividad de exigencia moderada hasta

intensa, y en un entorno normal los adultos deberían oscilar entre 60 y 100 latidos por minuto (AHA, 2021). Según esa información se eliminan los intervalos RR que posean un valor superior a 1750 milisegundos y aquellos inferiores a 400 milisegundos, que corresponden a 34 y 150 latidos por minutos respectivamente, que para efectos de este estudio se consideran *outliers*. En la Figura 4-5 se muestra un histograma con los valores de los intervalos RR buenos de entrenamiento de la persona 2. En anexos se muestran los histogramas de intervalos RR de entrenamiento de las otras 5 personas.

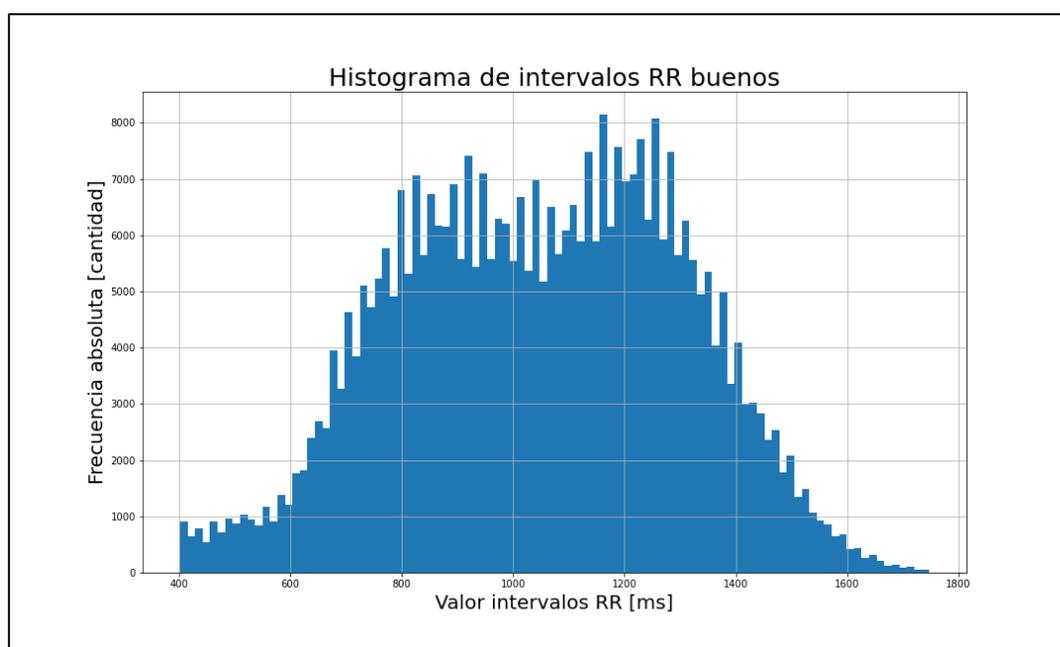


Figura 4-5: Histograma pre procesado intervalos RR de entrenamiento persona número 2.

Los intervalos RR crudos y buenos de validación de muestran en las Figuras 4-6 y 4-7 respectivamente. Los histogramas de intervalos RR crudos y buenos de validación de las otras 5 personas se muestran en los anexos.

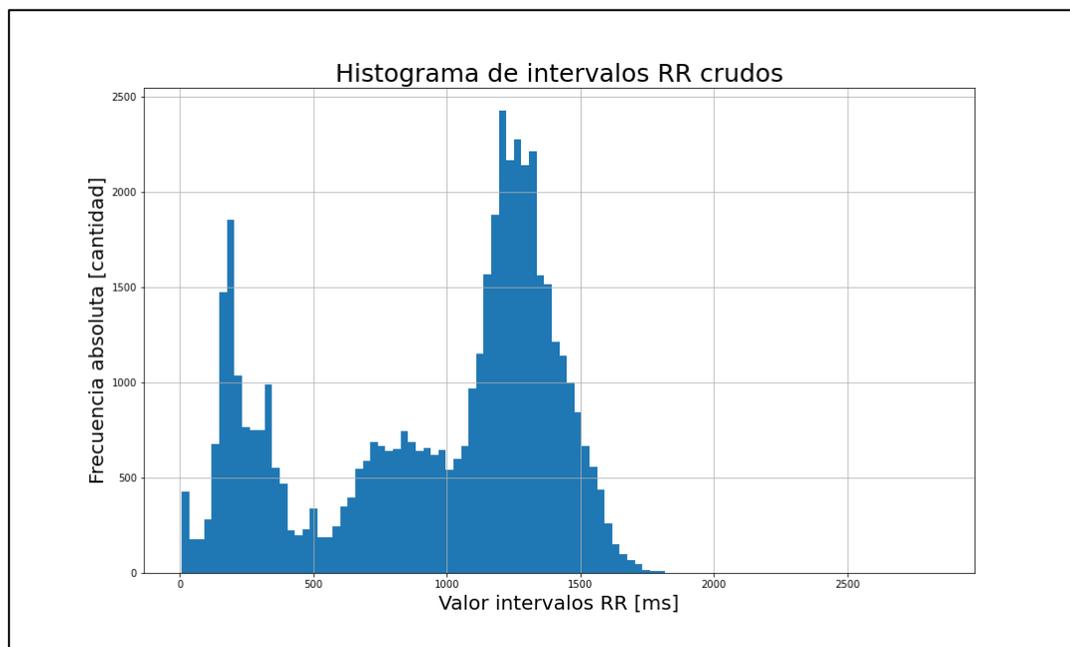


Figura 4-6: Histograma intervalos RR de validación persona número 2.

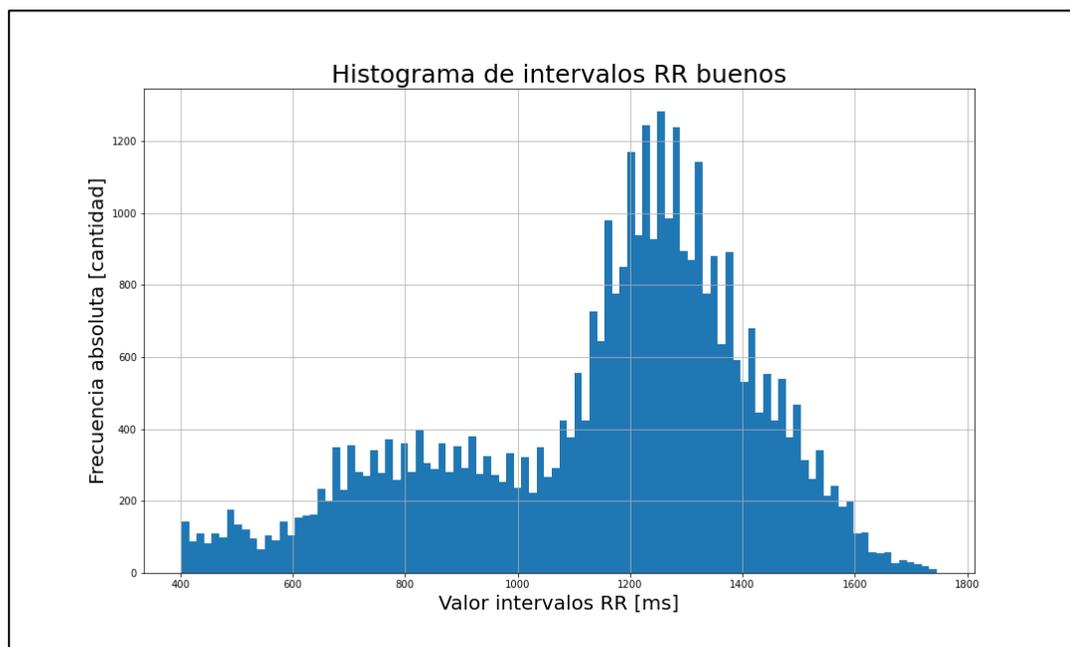


Figura 4-7: Histograma pre procesado intervalos RR de validación persona número 2.

El paso cuatro, es generar los intervalos RR acumulados, donde se toma ambos dataframes de intervalos RR (crudos y buenos por separado) y se suman sucesivamente los intervalos RR hasta una posición múltiplo de 60, donde vuelve a comenzar la suma hasta el próximo múltiplo. Se siguen utilizando los intervalos RR crudos, para los análisis y gráficos de los capítulos posteriores, ya que ejemplifican una situación real de monitoreo.

El quinto paso, es normalizar los valores acumulados de intervalos RR, y cortar el dataframe cada 60 valores, generando así señales de largo 60, siendo cada paso temporal un valor normalizado de los intervalos RR acumulados sucesivo en tiempo.

Por otro lado, para las respiraciones de cada persona, se realiza un proceso similar. Se cargan los datos mediante los excels, igual que el paso uno de los intervalos RR y se divide la data en entrenamiento y validación, al mismo tiempo que se realiza en los intervalos RR. Además, se eliminan los valores nulos de la base de datos (debido a que la frecuencia de recolección de datos del electrocardiograma es mucho mayor, y hay valores nulos para algunas filas para las otras variables fisiológicas). En la Figura 4-8, se muestra un histograma de los datos de frecuencia respiratoria cruda de entrenamiento de la persona 2. En los anexos se muestran los histogramas de frecuencia respiratoria cruda de entrenamiento de las otras 5 personas.

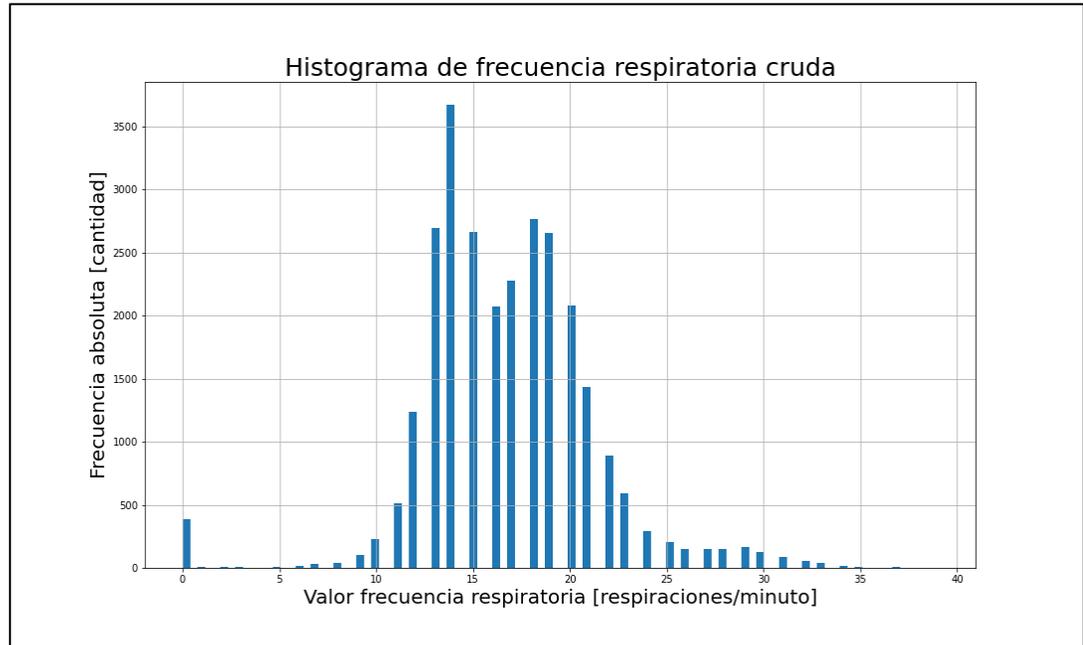


Figura 4-8: Histograma frecuencia respiratoria de entrenamiento persona número 2.

Al igual que en el caso de los intervalos RR, se eliminan aquellos valores *outliers*, que para el caso de la frecuencia respiratoria se consideran bajo 6 respiraciones por minuto.

En la Figura 4-9, se muestra un histograma de la frecuencia respiratoria buena de entrenamiento de la persona 2. En los anexos se muestran los histogramas de frecuencia respiratoria buena preprocesada de las otras 5 personas.

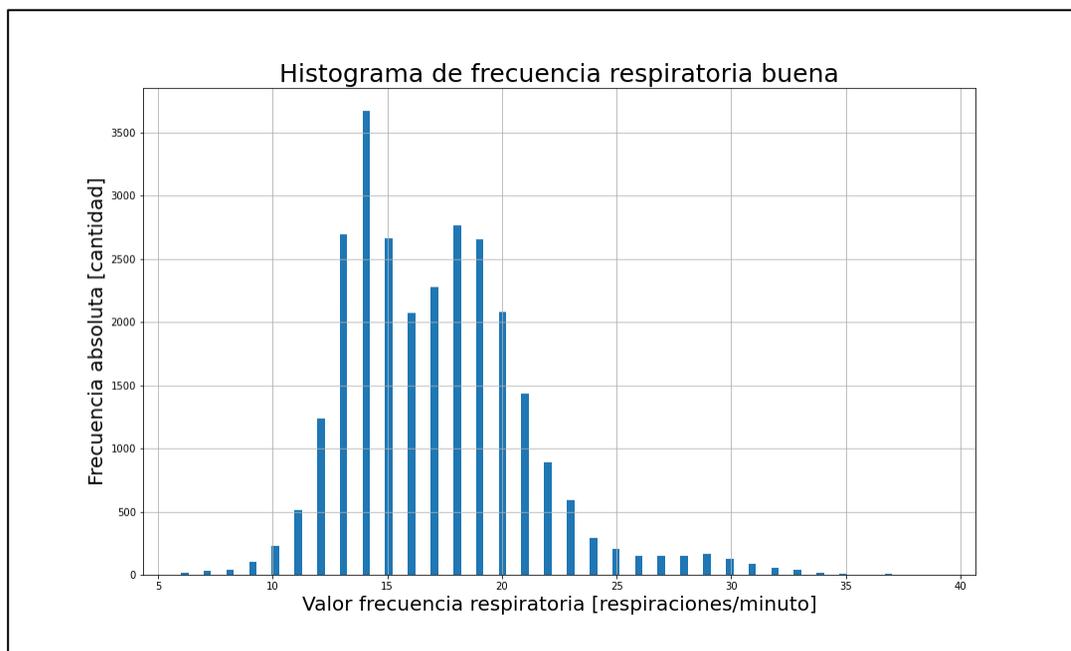


Figura 4-9: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 2.

En las Figuras 4-10 y 4-11, se muestran los histogramas de validación crudos y buenos de frecuencia respiratoria de la persona 2. En los anexos se muestran los histogramas de validación crudos y buenos de frecuencia respiratoria de las otras 5 personas.

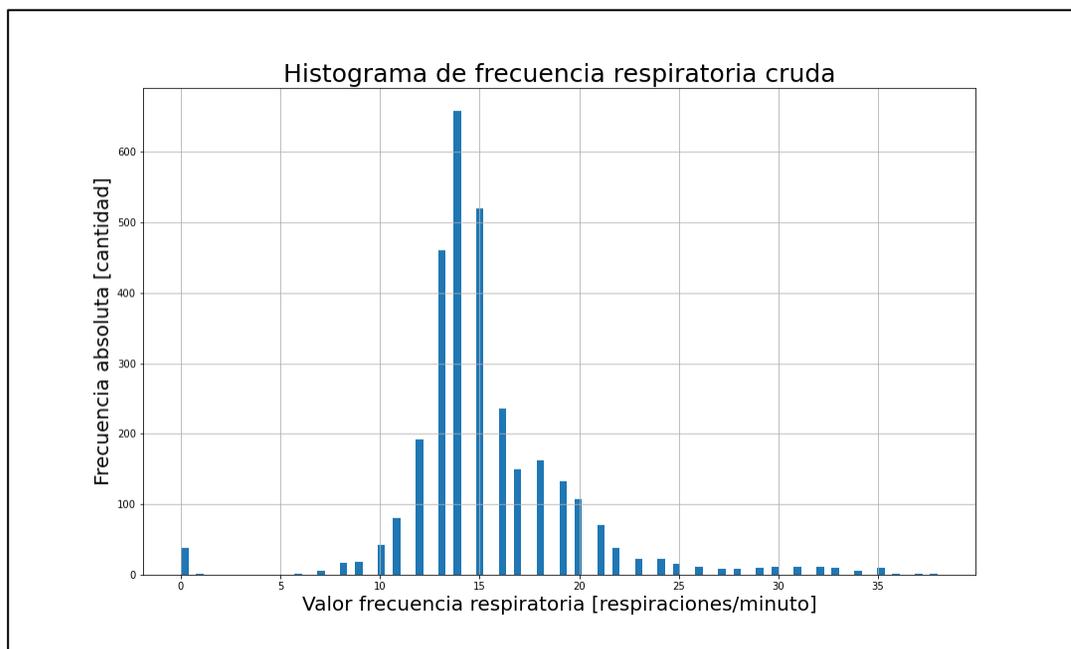


Figura 4-10: Histograma frecuencia respiratoria de validación persona número 2.

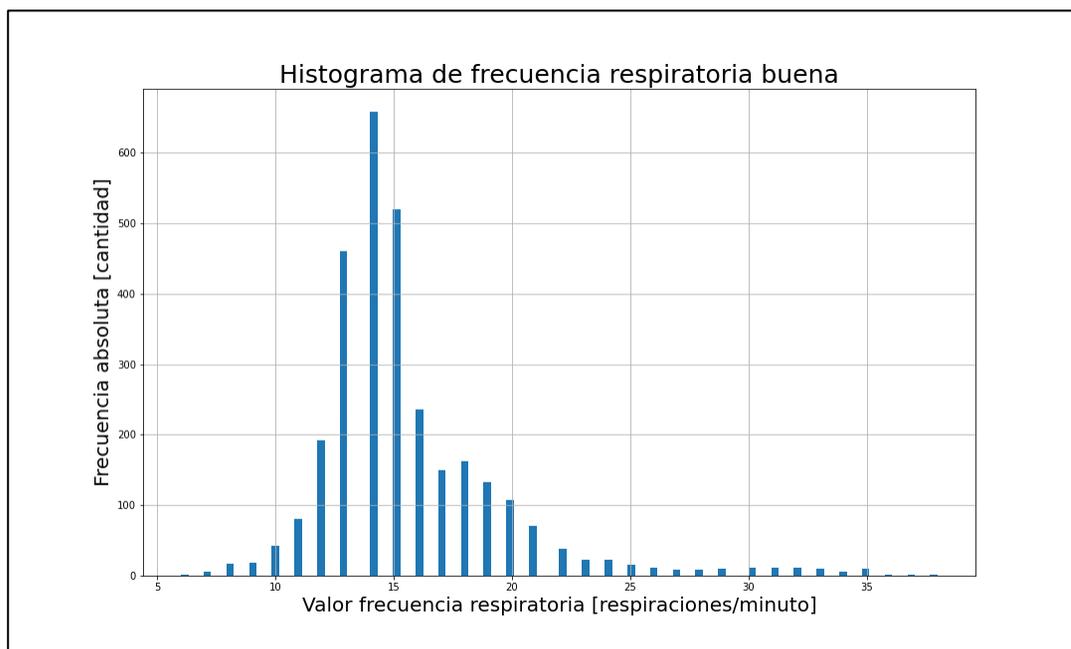


Figura 4-11: Histograma pre procesado frecuencia respiratoria de validación persona número 2.

Luego, la lista de valores de respiraciones por minuto se normaliza, obteniendo así un valor normalizado de respiración por minuto para cada señal de los intervalos RR acumulados y normalizados sucesivos en tiempo

#### **4.2 Resultados de los Modelos de Inteligencia Artificial**

Una vez obtenida la señal normalizada de 60 valores de intervalos RR consecutivos, y el valor de respiraciones por minuto normalizado que se ubican dentro del tiempo de la señal de intervalos RR, se procede a probar diferentes tipos de arquitecturas de aprendizaje profundo no supervisado.

La razón de la elección de utilizar aprendizaje no supervisado es debido a que hoy en día no existe un consenso de lo que es un estado fisiológico estresado o fatigado, como fue explicado en los capítulos anteriores, es subjetivo y no estandarizado. Al elegir un aprendizaje supervisado el autor deja a su propio criterio qué se considera un estado fisiológico y qué no. Este estudio supera esa problemática y deja que los propios datos hablen a través de los resultados de los modelos de aprendizaje profundo mediante algoritmos de clusterización.

Lo que se busca con estos algoritmos, es que sean capaces de generar clústeres donde la diferencia semántica de cada uno de ellos sea diferentes niveles de estados fisiológicos. Las métricas que miden el por qué esos clústeres se diferencian según niveles de estados fisiológicos se muestran en el siguiente capítulo.

En este estudio se experimentó con más de 20 diferentes tipos de modelos matemáticos, de los cuales se presentarán los mejores 11. Los modelos son los siguientes:

- VAE RNN: Autoencoder variacional, de codificación dos capas recurrentes, con 20 y 10 salidas respectivamente, luego la red se divide en dos partes, siendo

cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. La decodificación parte del muestreo de dimensión dos para pasar a dos capas recurrentes con 10 y 20 salidas respectivamente. La entrada del modelo son señales de 60 intervalos RR normalizados. Se entrena hasta las 500 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $9 \times 10^{-3}$ . La cantidad de parámetros entrenables son 5.642.

- VAE RNN A: Autoencoder variacional, de codificación dos capas recurrentes, con 20 y 10 salidas respectivamente, luego la red se divide en dos partes, siendo cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. La decodificación parte del muestreo de dimensión dos para pasar a dos capas recurrentes con 10 y 20 salidas respectivamente. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $1,44 \times 10^{-4}$ . La cantidad de parámetros entrenables son 5.642.
- VAE CNN A: Autoencoder variacional, de codificación dos capas convolucionales 1D, ambos de *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco (dimensión del *kernel*) más uno respectivamente, luego se aplica un *flatten* que estira los parámetros de la convolución, para luego dividirse en dos partes, siendo cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. La decodificación parte del muestreo de dimensión

dos para pasar a dos capas deconvolucionales con las mismas características anteriores, con *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco, más uno. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $4,47 \times 10^{-5}$ . La cantidad de parámetros entrenables son 47.713.

- VAE CNN MAX A: Autoencoder variacional, de codificación dos capas convolucionales 1D, ambos de *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco (dimensión del *kernel*) más uno respectivamente, y entre las dos capas convoluciones existe un *max pooling* de dimensión igual a dos y *stride* de uno, que ayuda a reducir la capacidad computacional necesaria para el entrenamiento. Luego se aplica un *flatten* que estira los parámetros de la convolución, para luego dividirse en dos partes, siendo cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. La decodificación parte del muestreo de dimensión dos para pasar a dos capas deconvolucionales con las mismas características anteriores, con *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco, más uno, y entre estas capas un *up sampling* que equivale al proceso inverso del *max pooling*, de dimensión dos y *stride* de uno, que duplica la información existente. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados. Se entrena hasta las 300 épocas obteniendo en su mejor

desempeño para el set de validación un valor de  $8,38 \times 10^{-5}$ . La cantidad de parámetros entrenables son 37.521.

- VAE CNN RNN A: Autoencoder variacional, de codificación dos capas convolucionales 1D, ambos de *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco (dimensión del *kernel*) más uno respectivamente, luego se aplica un *flatten* que estira los parámetros de la convolución, para luego dividirse en dos partes, siendo cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. La decodificación parte del muestreo de dimensión dos para pasar a dos capas recurrentes con 10 y 20 salidas respectivamente. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $4,63 \times 10^{-5}$ . La cantidad de parámetros entrenables son 28.366.
- VAE RNN A R: Autoencoder variacional, de codificación dos capas recurrentes, con 30 y 15 salidas respectivamente, luego la red se divide en dos partes, siendo cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. En paralelo entra una neurona densa por la cual se procesa los datos de respiración por minuto, que se concatena al muestreo de dos dimensiones. La decodificación parte del muestreo de tres dimensiones concatenadas para pasar a dos capas recurrentes con 15 y 30 salidas respectivamente. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados, y las respiraciones por minuto

normalizadas. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $6 \times 10^{-5}$ . La cantidad de parámetros entrenables son 12.372.

- VAE CNN A R: Autoencoder variacional, de codificación dos capas convolucionales 1D, ambos de *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco (dimensión del *kernel*) más uno respectivamente, luego se aplica un *flatten* que estira los parámetros de la convolución, para luego dividirse en dos partes, siendo cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. En paralelo entra una neurona densa por la cual se procesa los datos de respiración por minuto, que se concatena al muestreo de dos dimensiones. La decodificación parte del muestreo de tres dimensiones concatenadas para pasar a dos capas deconvolucionales con las mismas características anteriores, con *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco, más uno. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados, y las respiraciones por minuto normalizadas. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $4,36 \times 10^{-5}$ . La cantidad de parámetros entrenables son 50.417.
- VAE CNN RNN A R: Autoencoder variacional, de codificación dos capas convolucionales 1D, ambos de *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco (dimensión del *kernel*) más uno respectivamente, luego se aplica un *flatten* que estira los

parámetros de la convolución, para luego dividirse en dos partes, siendo cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. En paralelo entra una neurona densa por la cual se procesa los datos de respiración por minuto, que se concatena al muestreo de dos dimensiones. La decodificación parte del muestreo de tres dimensiones concatenadas para pasar a dos capas recurrentes con 10 y 20 salidas respectivamente. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados, y las respiraciones por minuto normalizadas. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $1,39 \times 10^{-4}$ . La cantidad de parámetros entrenables son 28.376.

- VAE RNN A R 5: Autoencoder variacional, de codificación dos capas recurrentes, con 30 y 15 salidas respectivamente, luego la red se divide en dos partes, siendo cada una compuesta por cinco neuronas densas, que posteriormente generan un muestreo de dimensión cinco. En paralelo entra una neurona densa por la cual se procesa los datos de respiración por minuto, que se concatena al muestreo de cinco dimensiones. La decodificación parte del muestreo de seis dimensiones concatenadas para pasar a dos capas recurrentes con 15 y 30 salidas respectivamente. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados, y las respiraciones por minuto normalizadas. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $5,11 \times 10^{-5}$ . La cantidad de parámetros entrenables son 12.513.

- VAE RNN A RR: Autoencoder variacional, de codificación dos capas recurrentes, con 30 y 15 salidas respectivamente, luego la red se divide en dos partes, siendo cada una compuesta por dos neuronas densas, que posteriormente generan un muestreo de dimensión dos. En paralelo entran dos neuronas densas, donde la primera neurona densa procesa los datos de respiración por minuto, mientras que la segunda neurona densa procesa la variable RMSSD que corresponde a la raíz cuadrada del valor medio de la suma de las diferencias al cuadrado de todos los intervalos RR sucesivos. Estas dos últimas neuronas densas se concatenan al muestreo de dos dimensiones. La decodificación parte del muestreo de cuatro dimensiones concatenadas para pasar a dos capas recurrentes con 15 y 30 salidas respectivamente. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados, las respiraciones por minuto normalizadas, y el valor normalizado de la variable RMSSD de la señal. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $6,3 \times 10^{-5}$ . La cantidad de parámetros entrenables son 12.387.
- VAE CNN A R 3D o *What Color*: Autoencoder variacional, de codificación dos capas convolucionales 1D, ambos de *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco (dimensión del *kernel*) más uno respectivamente, luego se aplica un *flatten* que estira los parámetros de la convolución, para luego dividirse en dos partes, siendo cada una compuesta por dos neuronas densas. En paralelo entra una neurona densa por la cual se procesa los datos de respiración por minuto, que

se concatena a las dos neuronas densas anteriores, y a partir de estas tres neuronas densas se genera un muestreo de dimensión tres. La decodificación parte del muestreo de tres dimensiones concatenadas para pasar a dos capas deconvolucionales con las mismas características anteriores, con *kernel* igual a cinco, y filtros iguales al número de pasos temporales de la señal de la capa anterior, menos cinco, más uno. La entrada del modelo son señales de 60 intervalos RR normalizados acumulados, y las respiraciones por minuto normalizadas. Se entrena hasta las 300 épocas obteniendo en su mejor desempeño para el set de validación un valor de  $3,69 \times 10^{-5}$ . La cantidad de parámetros entrenables son 50.421.

En la siguiente tabla se muestra un resumen de los resultados de la función de pérdida de entrenamiento de los modelos según el set de datos de validación. Cabe notar que todos fueron utilizando los mismos datos provenientes de una única persona para poder realizar comparaciones entre sus rendimientos.

Tabla 4-1: Valores función de pérdida de entrenamiento.

<b>Modelo</b>	<b>Entrada</b>	<b>Pérdida</b>
VAE RNN	Intervalos RR	$9,0 \times 10^{-3}$
VAE RNN A	Intervalos RR	$1,4 \times 10^{-4}$
VAE CNN A	Intervalos RR	$4,4 \times 10^{-5}$
VAE CNN MAX A	Intervalos RR	$8,3 \times 10^{-5}$
VAE CNN RNN A	Intervalos RR	$4,6 \times 10^{-5}$
VAE RNN A R	Intervalos RR + respiración	$6,0 \times 10^{-5}$
VAE CNN A R	Intervalos RR + respiración	$4,3 \times 10^{-5}$
VAE CNN RNN A R	Intervalos RR + respiración	$1,3 \times 10^{-4}$
VAE RNN A R 5	Intervalos RR + respiración	$5,1 \times 10^{-5}$
VAE RNN A RR	Intervalos RR + respiración + RMSSD	$6,3 \times 10^{-5}$
VAE CNN A R 3D	Intervalos RR + respiración	$3,6 \times 10^{-5}$

Se muestra en la Figura 4-12 el avance de la función de pérdida en cada iteración para el modelo 11 de la persona número 2. En los anexos se muestran las funciones de pérdida de las otras 5 personas para el modelo VAE CNN A R 3D o *What Color*.

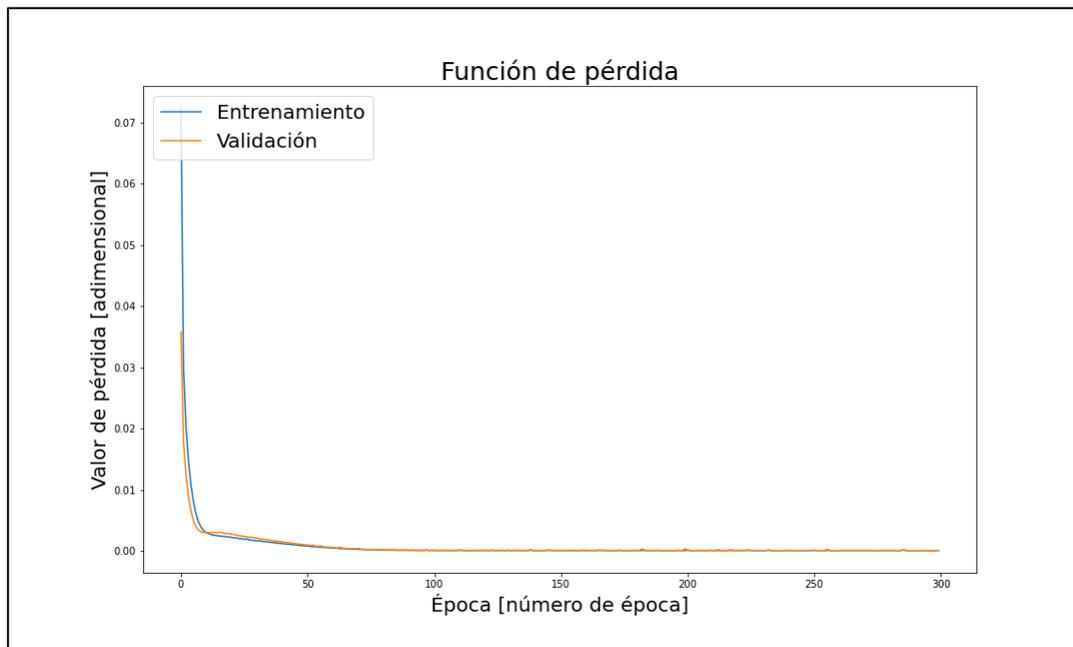


Figura 4-12: Valores función de pérdida persona número 2.

En la Figura 4-13 se muestra la reconstrucción de una señal acumulada de los intervalos RR normalizados del modelo 11 para la persona número 2. En los anexos se muestran reconstrucciones de la señal para cada una de las otras 5 personas.

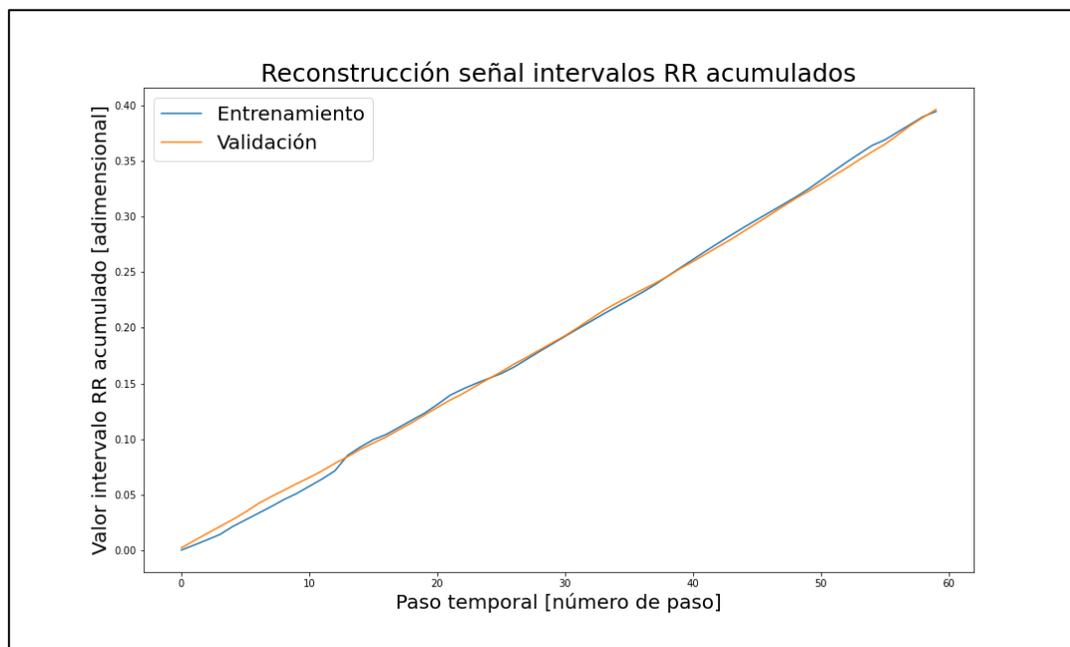


Figura 4-13: Reconstrucción intervalos RR acumulada normalizada persona 2.

Las siguientes dos Figuras 4-14 y 4-15 son el espacio latente del modelo 11 de la persona número 2. En los anexos se muestra el espacio latente para cada una de las otras 5 personas.

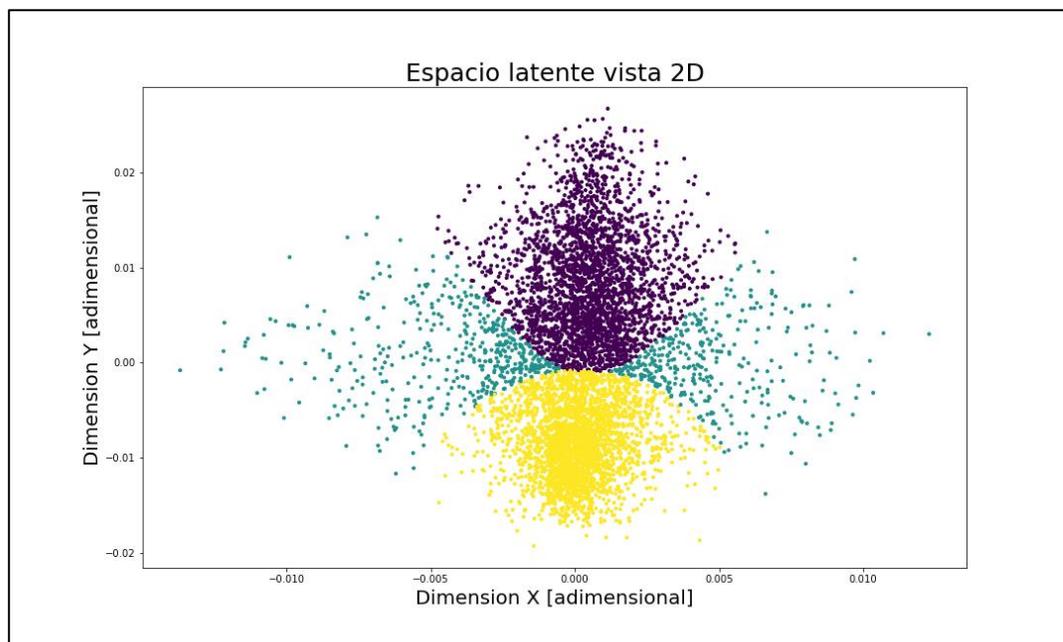


Figura 4-14: Espacio latente vista 2D persona número 2.

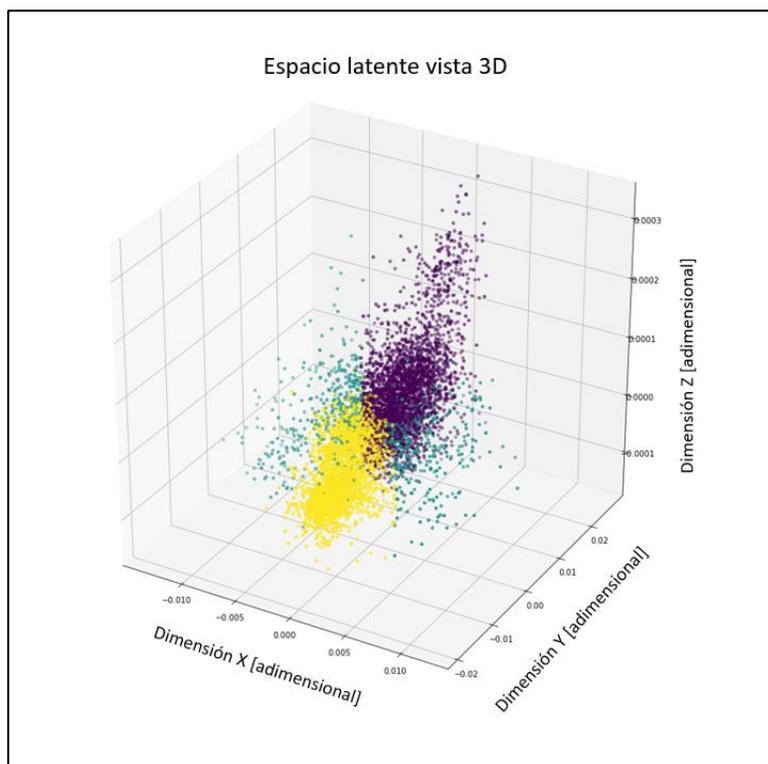


Figura 4-15: Espacio latente vista 3D persona número 2.

En las siguientes figuras 4-16, 4-17, 4-18, se muestran los histogramas de las tres distribuciones formadas en el espacio latente del modelo VAE CNN A R 3D o *What Color*, para la persona 2. En los anexos se muestran los histogramas del espacio latente para las otras cinco personas.

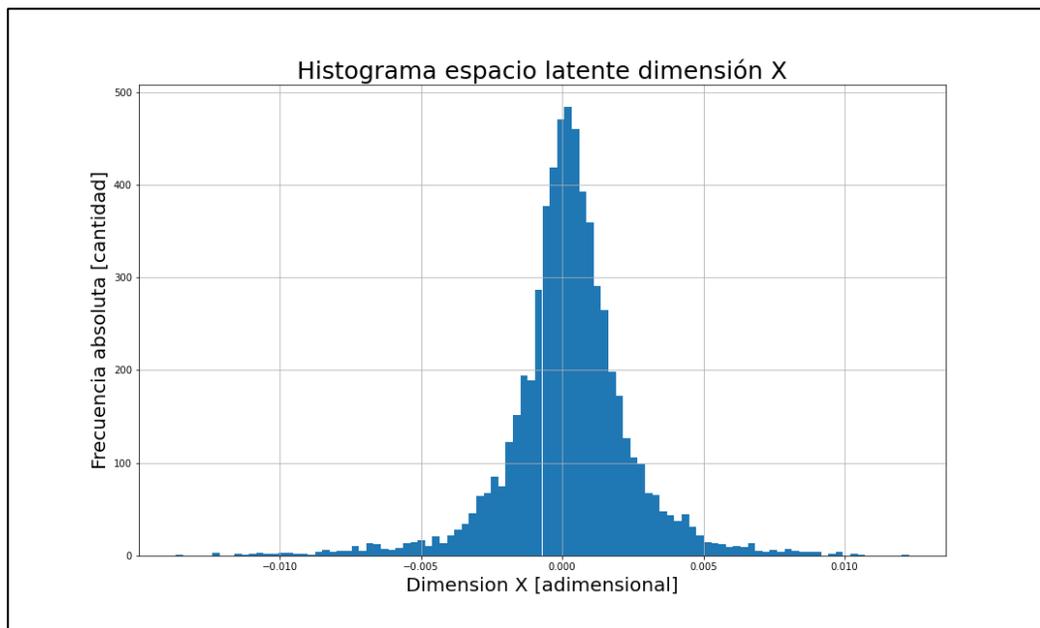


Figura 4-16: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 2.

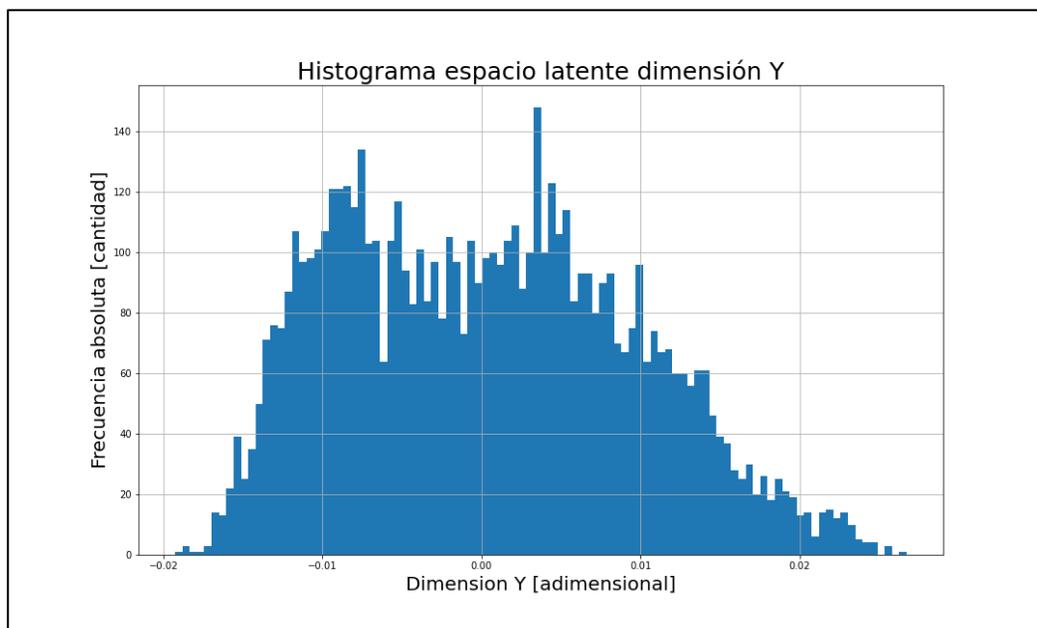


Figura 4-17: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 2.

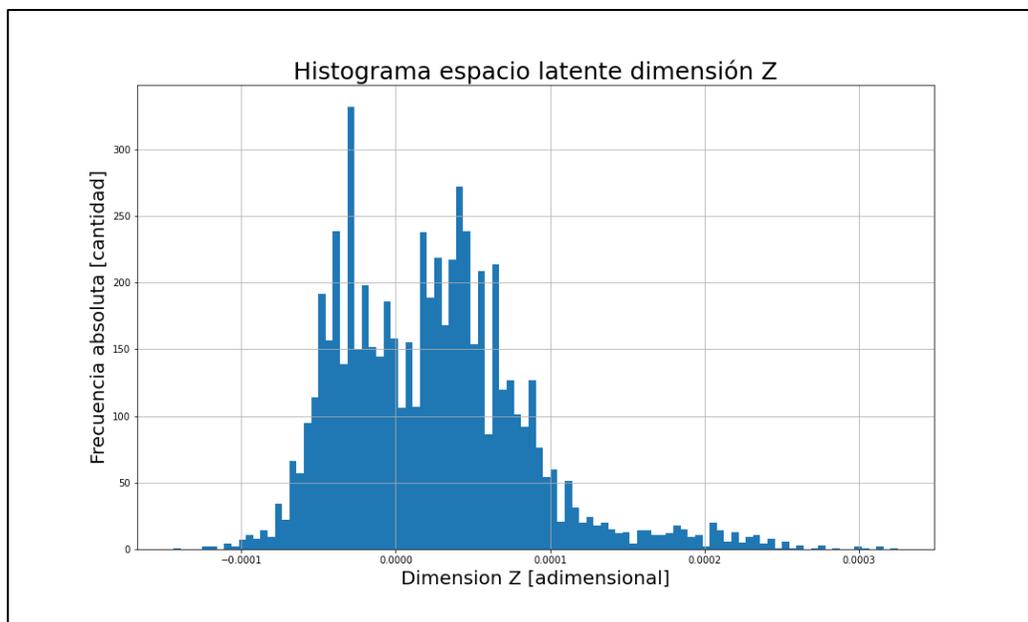


Figura 4-18: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 2.

### 4.3 Discusión sobre los Modelos de Inteligencia Artificial

El valor de la función de pérdida aplicada a los datos de validación es una métrica de cuan bien el algoritmo está reconstruyendo la señal a partir del espacio latente, y al mismo tiempo que tan formada se encuentra la distribución normal  $(0,1)$  proveniente de la suma de las dimensiones del espacio latente. A modo de recuerdo, la función de pérdida utilizada es la divergencia de Kullback-Leibler más el error cuadrático. Por ende, aquel modelo que posee un valor de función de pérdida menor significa que se desempeña mejor en la suma de los dos ámbitos anteriores.

Se ve una mejora considerable en términos de la función de pérdida cuando el modelo pasa datos de intervalos RR a datos de intervalos RR acumulados. Se ve claramente esa diferencia entre el modelo VAE RNN en comparación con los modelos VAE RNN A, VAE CNN A, VAE CNN MAX A y VAE CNN RNN A, que disminuyen en uno o hasta dos órdenes de magnitud. La explicación de este fenómeno se debe a que la inteligencia artificial ya no debe tomar decisiones de si el siguiente dato debe subir o bajar de valor, ya que como es acumulado, solo puede subir y en el peor de los casos el valor acumulado es casi igual al valor anterior.

Luego la diferencia entre el modelo VAE CNN A y VAE CNN MAX A, es que ambos usan capas convolucionales pero el modelo VAE CNN MAX A posee un *max pooling* entre sus capas. El resultado de la aplicación del *max pooling* solo empeora la función de pérdida. La hipótesis que podría explicar esto, es que si bien el entrenamiento del modelo con *max pooling* es más rápido porque calcula menos parámetros, se pierde mucha información que utilizan las neuronas para reconstruir la señal de entrada.

El análisis sobre los modelos VAE RNN A, VAE CNN A y VAE CNN RNN A, es que el modelo con solo capas convolucionales VAE CNN A tiene un valor de pérdida menor que los modelos puramente recurrentes o aquellos que codifican con capas convolucionales y decodifican con capas recurrentes.

Luego con la incorporación de la variable respiratoria en los modelos VAE RNN A R, VAE CNN A R y VAE CNN RNN A R, el modelo con capas convolucionales VAE CNN A R logra una función de pérdida menor a todos los anteriores modelos mencionados en este capítulo.

Además, a modo de análisis el modelo VAE RNN A R 5 es igual al modelo VAE RNN A R, con la diferencia que uno posee un espacio latente de tres dimensiones, mientras que el otro posee un espacio latente de seis dimensiones. Como era de prever, el modelo con una mayor cantidad de dimensiones posee una función de pérdida menor, no obstante, es casi marginal su mejora en comparación al aumento de tres dimensiones en su espacio latente. Es contraproducente aumentar el espacio latente para este tipo de metodologías, porque si bien disminuye la función de pérdida, luego la clusterización es más compleja ya que debe encontrar patrones de similitud en un espacio con más variables.

El modelo VAE RNN A RR se creó para intentar la misma lógica de agregar la respiración para aumentar el conocimiento experto y disminuir la función de pérdida, pero ahora incorporando también la medida de la RMSSD. Los resultados muestran que la función de pérdida no mejoró, de hecho, aumentó, demostrando así, que el modelo mira más allá que solo la variabilidad de ritmo cardiaco para autoorganizar el espacio latente.

Finalmente, el modelo VAE CNN A R 3D surge de un cambio leve en la arquitectura al mejor modelo obtenido hasta ese momento que es el modelo VAE CNN A R. La diferencia yace en la concatenación de las neuronas densas antes del muestreo del espacio latente, versus los modelos anteriores que concatenan la variable respiratoria al muestreo del espacio latente ya generado. El valor de función de pérdida mejoró con esta modificación, siendo este modelo el elegido para pasar a la etapa de clusterización que se explica en el siguiente capítulo.

Otro análisis, es acerca de la cantidad de parámetros necesarios a entrenar para cada uno de los modelos de inteligencia artificial utilizados. Se muestra en general que aquellos modelos que poseen más parámetros a ser entrenados son también aquellos que poseen la función de pérdida más baja, como lo son el modelo VAE CNN A R 3D y VAE CNN A R, que poseen más de 50.000 parámetros cada uno, y obtienen los mejores desempeños. Lo anterior se debe, a que en general los algoritmos de redes convolucionales respondieron de mejor forma a la reconstrucción de las señales, y justamente esas estructuras neuronales poseen más parámetros que las redes recurrentes.

Con lo anterior, no se afirma que mientras más parámetros a entrenar tenga un modelo neuronal, mejor será su desempeño, sino más bien, solo se afirma que los modelos de redes convolucionales se desempeñaron mejor en la reconstrucción de las señales de entrada, en comparación con las redes recurrentes.

La cantidad de datos disponibles para realizar los entrenamientos cumplen con la cantidad necesaria para generar análisis dentro del lapsus de una semana, no obstante, se debería apuntar a un monitoreo aún más largo para lograr la comparación entre

semanas. Del mismo modo, no se puede concluir con esta información que el intervalo de una semana es el óptimo y suficiente para lograr capturar todos los cambios fisiológicos que una persona pasa en su vida para poseer un entrenamiento completo de la persona. Se deben establecer nuevas directrices en estudios futuros que establezcan un intervalo de tiempo representativo en el cual se alcance un estado de régimen, donde los entrenamientos ya podrían considerar gran parte de los estados fisiológicos de la persona, y llevar esos entrenamientos a una extrapolación para nuevas personas.

Por otro lado, los avances del valor de la función de pérdida mostrados en la Figura 4-5 del capítulo anterior, baja drásticamente entre las primeras 20 a 30 iteraciones, luego sigue bajando con un pendiente más leve hasta aproximadamente la iteración 100. A partir de esta iteración continúa bajando, pero los valores son tan pequeños que en el gráfico pareciese que no continuase progresando, pero no es más que un problema visual ya que los valores comienzan a estar elevados a menos cuatro o menos cinco lo que dificulta su visualización de avance.

Una condición que se debe evitar en los entrenamientos de algoritmos de inteligencia artificial es el sobreajuste. En este caso, ninguno de los modelos se sobre ajustó, lo cual se puede ver reflejado en la Figura 4.12, donde si bien baja el valor de la función de pérdida del set de datos de entrenamiento, también lo hace el set de validación. De hecho, la comparación de rendimientos entre los modelos se hizo utilizando el valor de la función de pérdida de validación de cada modelo.

Otro análisis que se observa es que los histogramas generados a partir de las distribuciones formadas en el espacio latente del modelo VAE CNN A R 3D o *What*

*Color*, forman a simple vista entre dos o tres distribuciones gaussianas dependiendo de la persona analizada. Es por esto, que en el proceso de clusterización que se explica en el siguiente subcapítulo, se deciden generar tres clústeres a partir del espacio latente.

#### **4.4 Resultados de Clusterización Mezcla de Gaussianas**

El proceso para llevar a cabo la clusterización es el siguiente, entra la señal de 60 intervalos RR normalizados acumulados, y en paralelo el dato de respiraciones por minuto normalizado, tal como se explicó en el modelo VAE CNN A R 3D. El muestreo realizado en este modelo se genera a partir de dos capas de tres neuronas densas cada una, generando un espacio latente de tres dimensiones. Cabe notar, que cada dato de entrada genera un punto en este espacio latente tridimensional.

Luego, se toman todos los puntos del espacio latente generados a partir del procesamiento de todos los datos fisiológicos de una persona y se clusterizan en tres grupos mediante la técnica de mezcla de gaussianas, debido a que las distribuciones de las dimensiones del espacio latente se asemejan a distribuciones gaussianas a causa de la divergencia de Kullback-Leibler.

En las Figuras 4-19, 4-20, 4-21, 4-22 se muestran cuatro histogramas correspondientes a medidas obtenidas a partir de la clusterización realizada al espacio latente de la persona número 2. En los anexos, se muestran los de la persona 3, 5, 7, 8 y 9. Los nombres de los clústeres provienen de asignarle el nombre de relajado y activo a los dos clústeres de los valores extremos, y a transición aquel que se encuentra entre ellos.

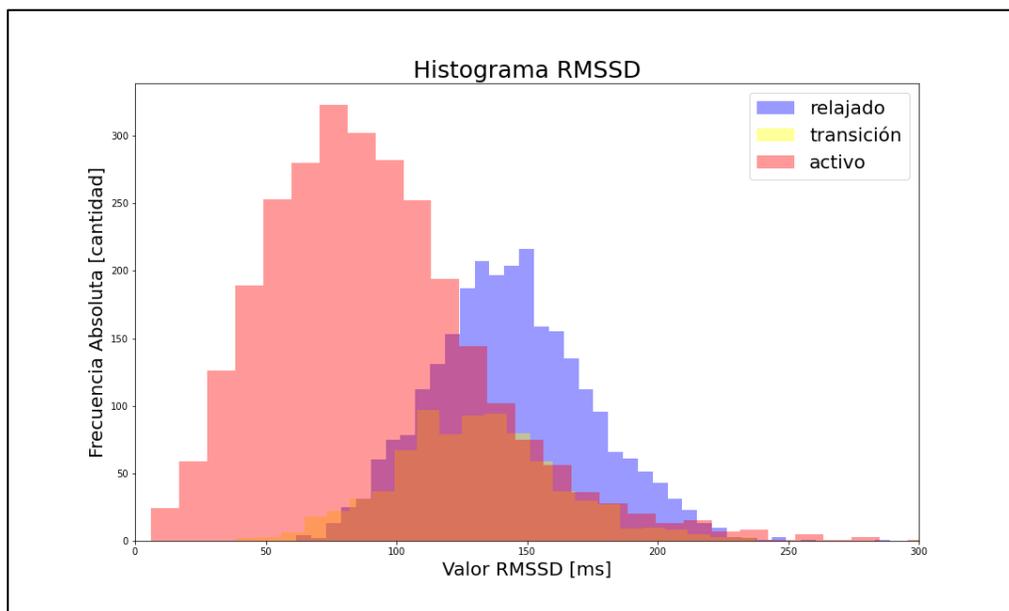


Figura 4-19: Histograma RMSSD de la clusterización de la persona número 2.

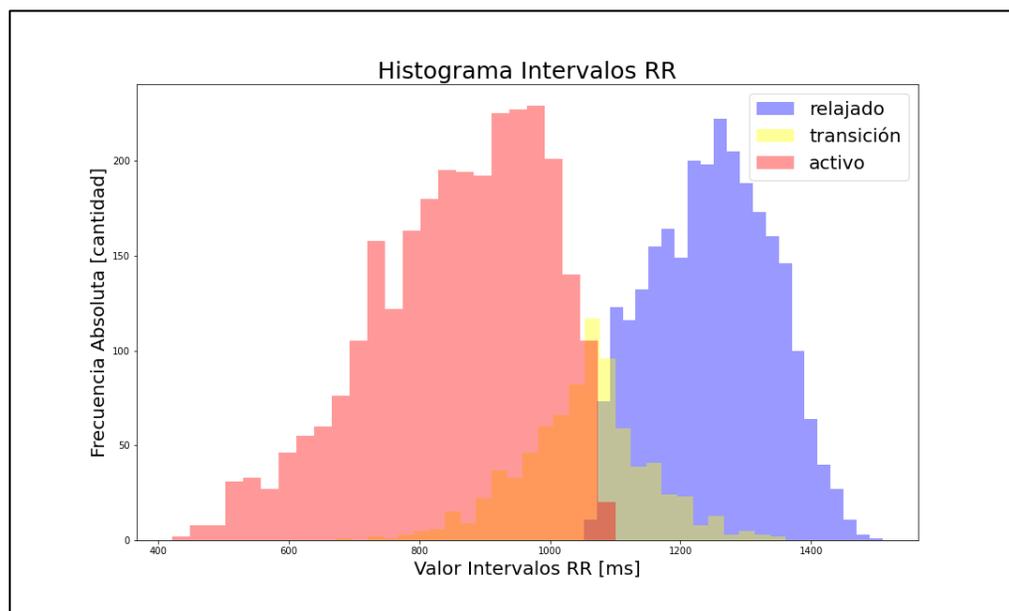


Figura 4-20: Histograma intervalos RR de la clusterización de la persona número 2.

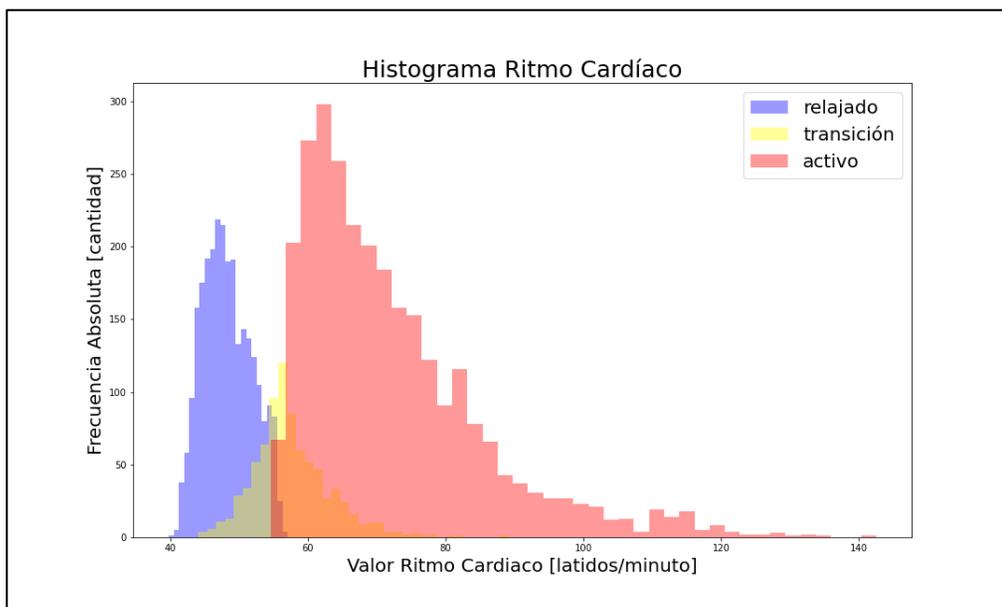


Figura 4-21: Histograma ritmo cardiaco de la clusterización de la persona número 2.

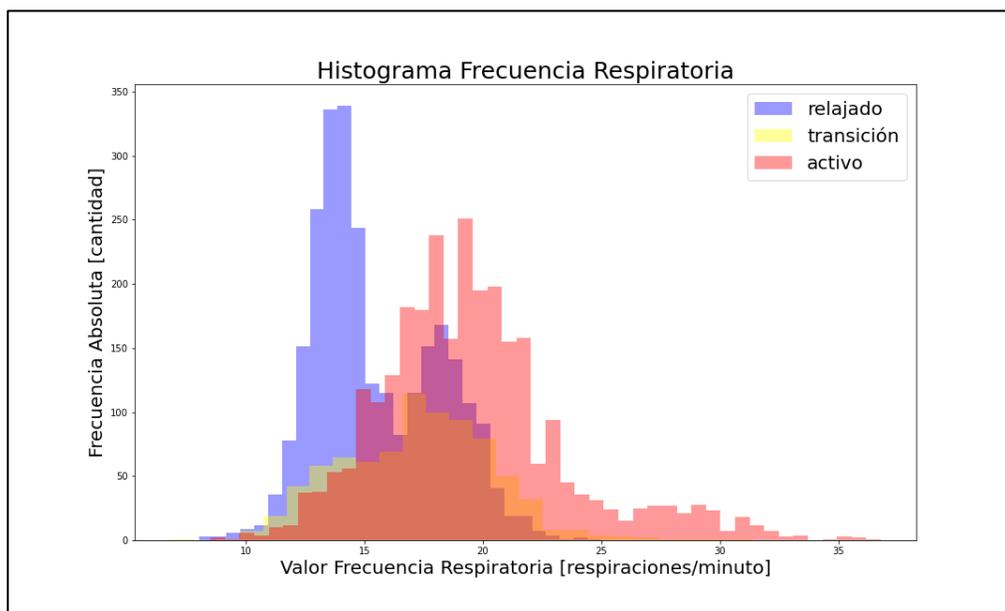


Figura 4-22: Histograma frecuencia respiratoria de la clusterización de la persona número 2.

En la tabla 4-2, se muestran los valores promedio de cada una de las variables, además de sus desviaciones estándar. En los anexos, se muestran las tablas para las personas 3, 5, 7, 8 y 9.

Tabla 4-2: Valores de medidas fisiológicas persona número 2.

REPORTE ESTADOS FISIOLÓGICOS DE ENTRENAMIENTO			
	Clúster Relajado	Clúster Transición	Clúster Activo
Variabilidad Ritmo Cardíaco RMSSD [ms]			
Promedio	144.18	130.69	91.59
Desv Estandar	30.27	32.37	43.24
Mínimo	61.82	38.82	6.19
Máximo	289.01	306.52	542.39
Intervalos R-R [ms]			
Promedio	1249.00	1050.38	856.41
Desv Estandar	90.35	98.44	134.18
Mínimo	1051.77	672.95	421.07
Máximo	1509.88	1361.40	1100.07
Ritmo Cardíaco [latidos/minuto]			
Promedio	48.29	57.65	72.10
Desv Estandar	3.52	5.69	13.36
Mínimo	39.74	44.07	54.54
Máximo	57.05	89.16	142.50
Frecuencia respiratoria [respiraciones/minuto]			
Promedio	15.47	17.24	19.49
Desv Estandar	2.62	3.25	4.00
Mínimo	8.00	6.80	8.50
Máximo	25.00	31.33	36.78

La Figura 4-23 es la medición del estado fisiológico la persona 2 aproximadamente minuto a minuto según la fecha y hora del día, durante el periodo de monitoreo. El valor 0 hace referencia al estado fisiológico relajado, el 1 al estado fisiológico de transición y el 2 el estado fisiológico activo, y los números entre ellos es la probabilidad de que ese minuto se encuentre en cierto estado fisiológico. Por ejemplo, si el punto se encuentra justo en el color rojo en el eje  $Y = 2$ , significa que es un 100% probable que

la persona se encuentre en un estado fisiológico activo, mientras que si el valor se encuentra en el color verde en el eje  $Y = 0,5$ , significa que existe un 50% de probabilidad que la persona se encuentre en un estado relajado y un 50% de probabilidad se encuentre en un estado de transición. El último ejemplo también se puede traducir en que la persona está en el momento de cambio entre el estado fisiológico relajado y de transición.

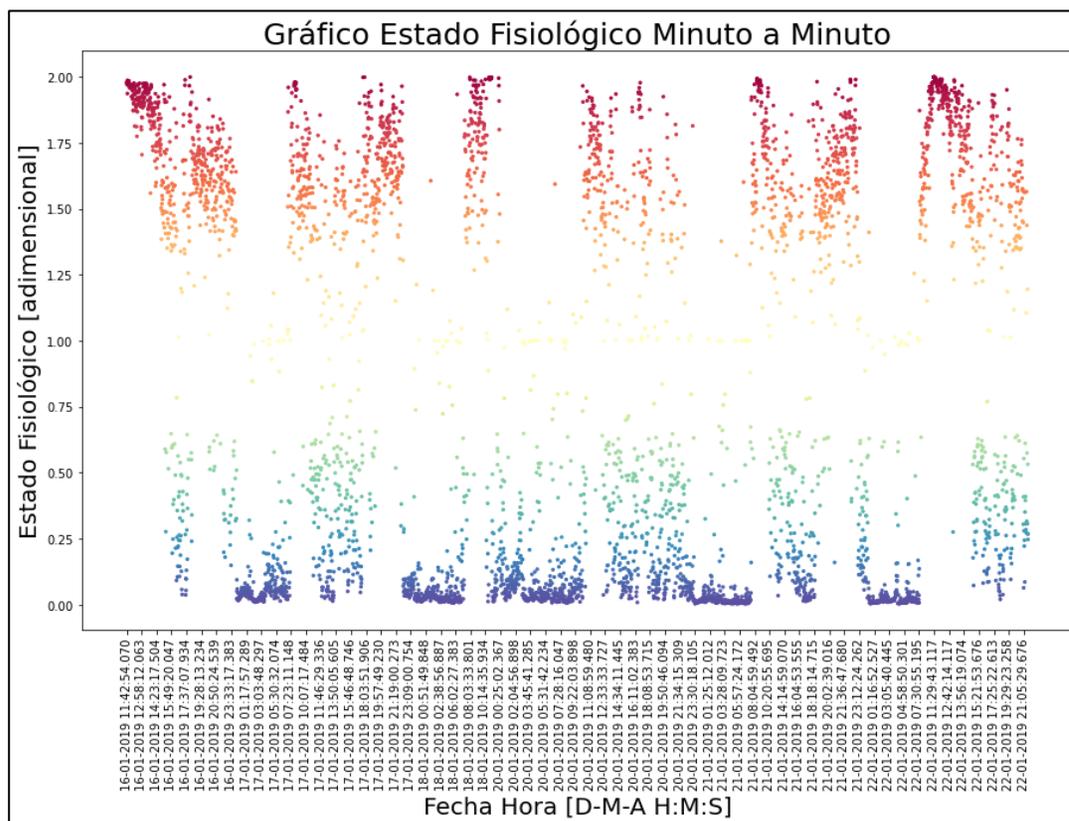


Figura 4-23: Estado fisiológico minuto a minuto persona número 2.

De aquí nace el nombre del modelo “*What Color*”, ya que cuando las personas se encuentren en su jornada laboral van a poder hacer el seguimiento de su estado

fisiológico en tiempo real, mediante la observación del color en que se encuentran en ese momento.

La Figura 4-24 muestra los grados de inclinación de la persona según la fecha y hora del día, durante el periodo de monitoreo, donde 180° grados significa que la persona se encuentra de forma horizontal y 90° significa que la persona se encuentra en forma vertical.

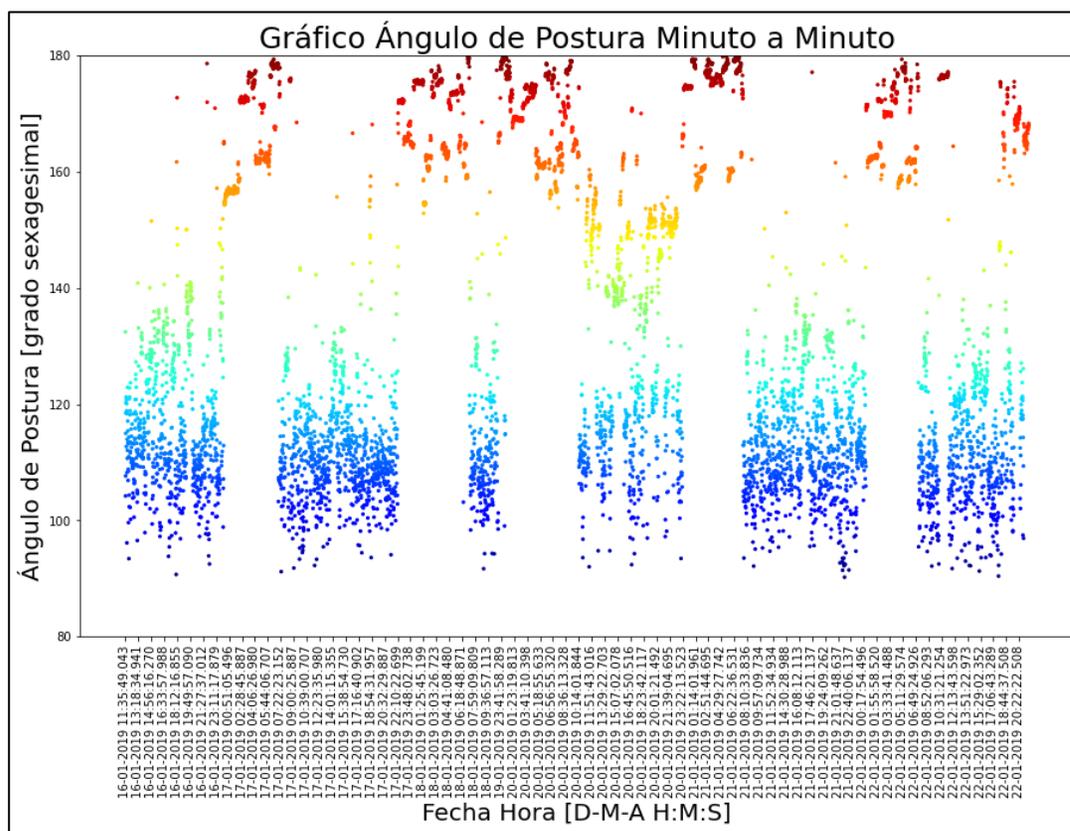


Figura 4-24: Ángulo de postura minuto a minuto persona número 2.

La Figura anterior se puede obtuvo a partir de los datos de giroscopio de la persona, y utilizando la siguiente fórmula:

$$\text{ángulo} = 90 - \tan^{-1} \left( \frac{\sqrt{x^2 + y^2}}{z} \right) \quad (4.1)$$

#### 4.5 Discusión sobre la Clusterización Mezcla de Gaussianas

El objetivo de la clusterización es agrupar los datos en tres grupos semánticamente diferentes entre sí, para que cada uno represente un estado fisiológico de la persona, y se pueda clasificar minuto a minuto su evolución en el tiempo. La gran interrogante por responder es si realmente la clusterización corresponde a estados fisiológicos. La respuesta más clara es que sí corresponden a estados fisiológicos, por cuatro principales análisis.

El primer análisis es observando las señales que habitan en cada uno de los clústeres resultado. En la Figura 4-25 se muestran señales representativas de cada clúster, donde la señal azul corresponde al clúster relajado, la señal anaranjada al clúster de transición, y la señal verde al clúster activo.

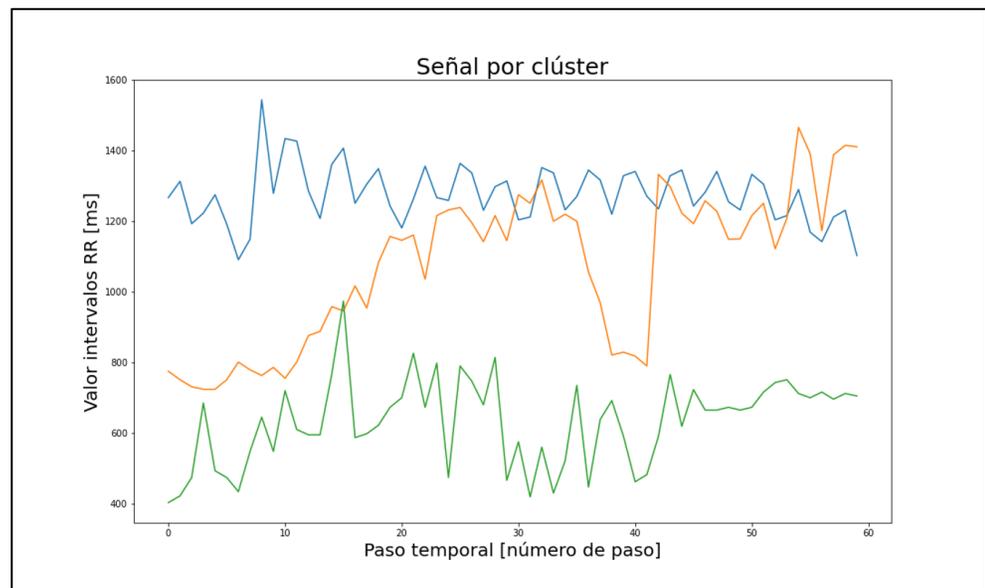


Figura 4-25: Señal representativa de cada clúster.

En general todas las señales provenientes de los clústeres poseen formas similares. Teniendo el clúster relajado valores superiores de intervalos RR que el clúster activo, mientras que el clúster de transición viaja entre ellos, partiendo en uno y terminando en otro. Lo anterior da una intuición positiva sobre la tesis planteada, ya que entrega información de que el estado de transición en general se mueve entre ellos y que existen dos polos fisiológicamente diferentes. Además, la información no es tajante en decir donde existe una delimitación numérica fija entre los clústeres, ya que como se ve en los histogramas para un mismo valor promedio de intervalos RR la señal puede vivir en diferentes clústeres.

El segundo análisis nace de la relación existente entre la clasificación de estados fisiológicos por minuto y la figura de grados del giroscopio. Existe una alta correlación entre los momentos en los cuales la persona se encuentra en un estado horizontal y la clasificación de un estado fisiológico relajado. En términos generales no necesariamente una persona siempre se encuentra descansando cuando se encuentra en una postura horizontal, pero la evidencia empírica dice que generalmente es así. Además, el análisis no acaba ahí, ya que esos momentos cuando la persona se encuentra en ese estado son en horarios que usualmente una persona descansa o duerme, entre las 23pm y 8am horas del día. Esto deja entrever una respuesta natural de los datos, que relaciona el estado fisiológico relajado con los momentos en que la persona se encuentra descansando o durmiendo.

Del mismo modo, no es una relación de uno a uno, ya que no necesariamente que una persona esté acostada significa que la persona se encuentre en un estado de relajo, lo

que también se muestra en la Figura 4-23 y Figura 4-24, donde hay momentos en los que la persona se encuentra en forma horizontal y su estado fisiológico es activo.

El tercer análisis surge de la tabla de valores de las variables fisiológicas. Es claro pensar que aquel estado fisiológicamente activo posee una respiración más agitada, y unos latidos cardiacos más frecuentes entre sí, y el promedio de las variables de los clústeres respetan esa regla.

Ahora, no necesariamente se debe cumplir esa relación, ya que existen casos donde el promedio de ritmo cardiaco es mayor en el clúster de transición que en el activo, y existen valores en el clúster relajado que son mayores que el de transición, pero en promedio existe una tendencia a que se cumpla lo anterior. Este análisis es importante, y vale la pena exponerlo, porque en ningún momento a los modelos de inteligencia artificial se les programa la instrucción para que generen esta tendencia, sino que los datos expresan esa relación de forma espontánea, ratificando y replicando la intuición humana.

El cuarto análisis viene de parte del estado del arte, que plantea una relación entre el valor de la RMSSD y el control cardiaco vagal proveniente del tono parasimpático. El aumento de la actividad del sistema nervioso simpático se da por una inhibición de parte de los grupos vagales pertenecientes al sistema nervioso parasimpático.

La relación es que cuando una persona se encuentra en un estado fisiológico estresado, la RMSSD es baja, mientras que cuando la persona se encuentra en un estado fisiológico normal, la RMSSD es mayor (Oskooei et al., 2019).

Ejemplo de lo anterior, es un estudio realizado en el campeonato del mundo de hockey hierba en el 2006, donde se monitoreaban a las jugadoras partido a partido. Los

resultados fueron que la RMSSD fue disminuyendo progresivamente a medida que avanzaban en el torneo. Lo anterior se debe a que la actividad del sistema parasimpático son indicativos de una buena adaptabilidad psíquico-física a las cargas de trabajo, y a medida que avanzaban esa capacidad se iba disminuyendo (Rodas et al., 2011).

Otro estudio realizado a 15 participantes donde simulan la conducción de un vehículo durante 60 minutos midiendo continuamente la HRV de los participantes, concluye que la RMSSD fue disminuyendo en respuesta al estrés de mantenerse alerta y rendir mientras aumentaba la somnolencia (Zhang et al., 2018). La RMSSD disminuye significativamente al incrementar la sobrecarga mental y ocurre lo mismo durante el estrés (como se cita en Zhang et al., 2018).

Si bien no existe un consenso en las definiciones de los estados fisiológicos alterados, varios estudios usan esta métrica para llegar a conclusiones del estado fisiológico de las personas, ya sea para medir estados relajados y cognitivamente estresado (Hernando et al., 2018), sobrecargas mentales para los pilotos de aviones (Mansikka et al., 2016), solo por nombrar algunos estudios.

Esta tendencia del RMSSD planteada por el estado del arte aparece en los resultados del estudio de forma espontánea, ya que en ningún caso fue una regla planteada, sino que los mismos datos a través del algoritmo desarrollaron esa relación. Ahora bien, esta relación no es categórica ya que existen casos donde no se cumple, y eso es positivo para el estudio, ya que el algoritmo utilizado no solo se concentra en valores fijos de variables como el RMSSD, sino que se centra en todos los valores de la señal, su avance en el tiempo, su forma de crecimiento y decrecimiento, entre otros. En

específico, de las 6 personas monitoreadas en el estudio, se cumple que la RMSSD del clúster activo es menor que el clúster relajado en 4 personas, y en las 2 personas que no se cumple es por una diferencia muy baja, de 10 ms en promedio.

Con respecto a la RMSSD, se muestra en las tablas de medidas fisiológicas que, en 5 de las 6 personas monitoreadas, el clúster de transición posee la RMSSD más alta entre los tres clústeres. Su explicación yace en el cálculo de la medida, como el clúster de transición viaja desde el clúster activo al clúster relajado, o viceversa, la variabilidad entre los puntos establecidos dentro de la señal es mayor que las existentes en los clústeres de los extremos.

Anexo a lo anterior, los análisis de variabilidad del ritmo cardiaco utilizando pequeños lapsos de tiempo no son nuevos. Generalmente la variabilidad cardiaca se mide en plazos de tiempo de al menos 24 horas, no obstante, varios autores utilizan periodos mucho más cortos para realizar sus análisis, destacando entre sus motivaciones los costos asociados a largos periodos de monitoreo (Shaffer et al., 2020; Nakamura et al., 2018). Estos periodos cortos de variabilidad del ritmo cardiaco pueden llegar a ser de 1 hasta 10 minutos.

#### **4.6 Resultados Repositorio de Datos Externos**

Además, del estudio aplicado a los datos recolectados de electrocardiograma y respiraciones de individuos explicados en el capítulo anterior, para comprobar que efectivamente el sistema creado identifica estados fisiológicamente relajado, de transición y activo, se aplicó el sistema a un repositorio libre de datos. El repositorio de datos corresponde a la colección de datos cardio respiratorios de 81 personas por un intervalo de aproximadamente entre 10 minutos a 120 minutos los monitoreos más

extensos. Las personas durante este tiempo tienen momentos de relajación, de ejercitación, y otras actividades dependiendo de la persona monitoreada (Burattini, 2020).

Se tomaron los datos de dos personas, la primera corresponde a una persona de sexo femenino, de 23 años, de altura 167 cm, y de peso 53 kilos, la persona no es fumadora ni consumidora de alcohol. La persona realizó tres actividades, la primera actividad fue de descanso desde el minuto 0 hasta el minuto 10 con 11 segundos, luego realizó un trote hasta el minuto 60 con 33 segundos, y posteriormente se recuperó hasta el minuto 73 con 15 segundos.

En la Figura 4-26 se muestra el resultado de introducir la información cardiorrespiratoria de la persona, segmentada minuto a minuto, y pasarla a través del sistema de identificación de estados fisiológicos.

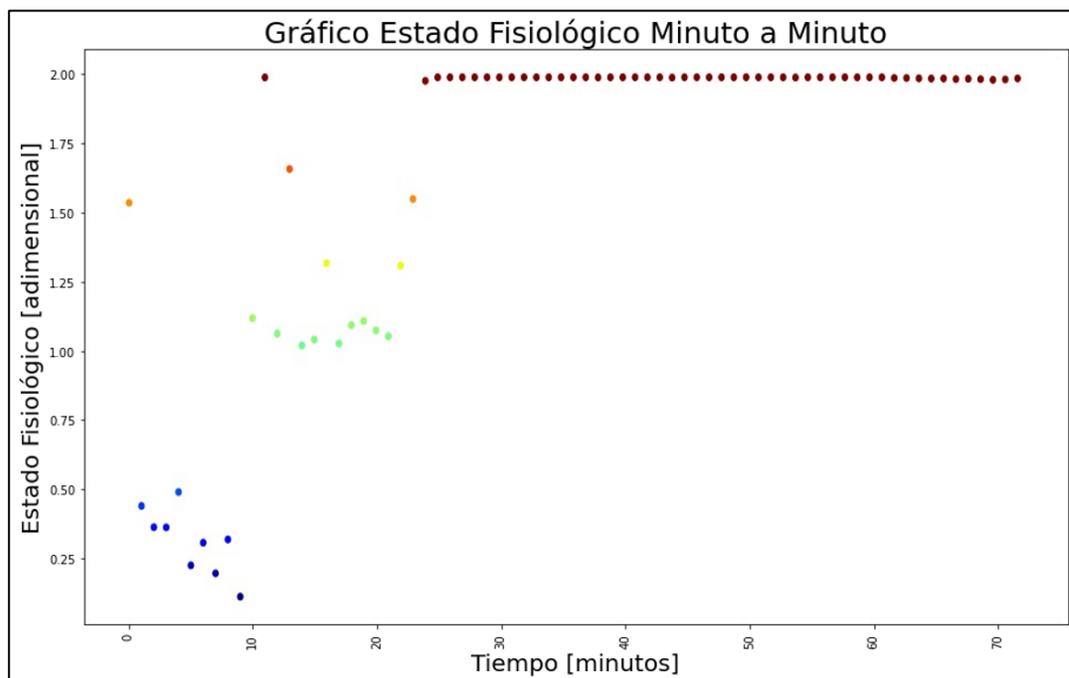


Figura 4-26: Gráfico estado fisiológico persona 1 repositorio de datos externos.

La segunda persona corresponde a una persona de sexo masculino, de 25 años, de altura 177 cm, y de peso 65 kilos, la persona no es fumadora ni consumidora de alcohol. La persona realizó tres actividades, la primera actividad fue de descanso desde el minuto 0 hasta el minuto 18 con 33 segundos, luego jugó fútbol hasta el minuto 111 con 16 segundos, y posteriormente se recuperó hasta el minuto 122 con 54 segundos.

En la Figura 4-27, al igual que la anterior, se muestra el resultado de introducir la información cardio-respiratoria de la persona, segmentada minuto a minuto, y pasarla a través del sistema de identificación de estados fisiológicos.

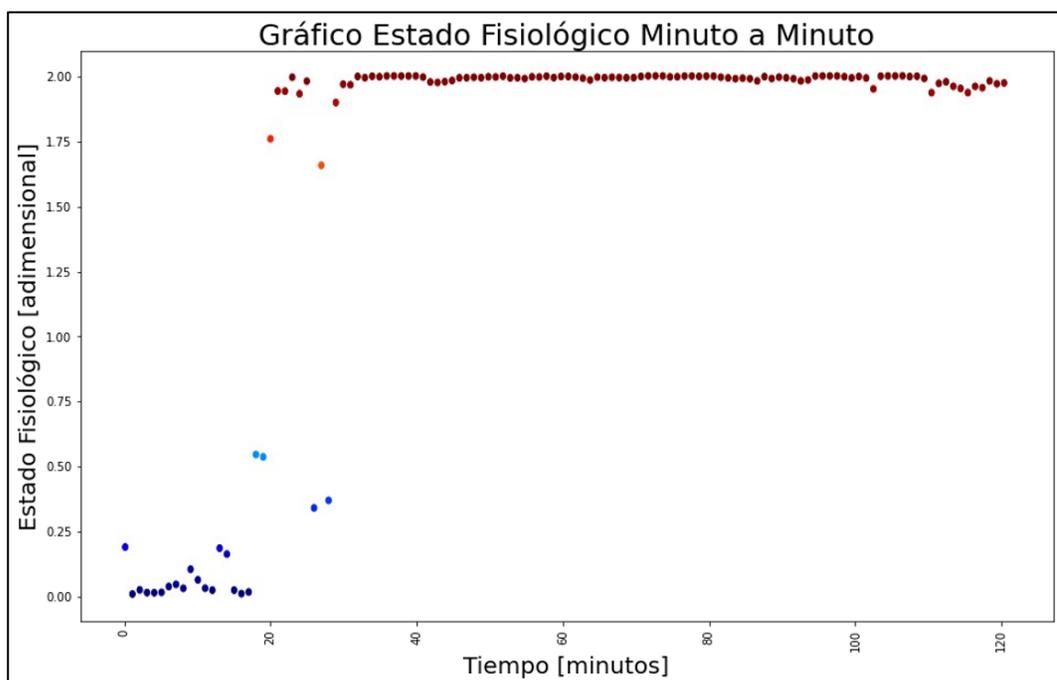


Figura 4-27: Gráfico estado fisiológico persona 2 repositorio de datos.

El entrenamiento utilizado para identificar los estados fisiológicos de las dos personas anteriores es uno de los seis entrenamientos explicados en el punto anterior, en

específico, aquel que su histograma de intervalos RR se asemeje más al histograma de intervalos RR de la persona del repositorio de datos.

No es posible realizar el entrenamiento en particular para cada una de estas dos personas, debido a que el monitoreo de sus variables fisiológicas no supera siquiera las 2 horas y 30 minutos de duración, mientras que los seis entrenamientos explicados en el punto anterior conllevan una base de datos de al menos una semana de monitoreo.

#### **4.7 Discusión sobre Repositorio de Datos Externos**

Las Figuras de la clasificación minuto a minuto del estado fisiológico de las personas del repositorio de datos externos responden de una manera adecuada a lo que se esperaría encontrar al aplicar el sistema creado. Cuando las personas se encuentran en el periodo de descanso el estado fisiológico predominante es el estado fisiológico relajado, mientras que a medida que avanzan en su actividad física, el monitoreo comienza a moverse al de transición, y finalmente cuando la persona se encuentra ya pasado un tiempo realizando actividad física la clasificación predominante es el estado fisiológico activo. Además, casi al final del monitoreo se ve levemente como los puntos bajan en su clasificación, pero se siguen manteniendo en un estado fisiológico activo, debido a que es poco el tiempo de descanso versus el tiempo que necesitan para volver a estar en las condiciones iniciales previas a realizar la actividad física.

Otro enfoque importante para considerar es que los resultados observados en el repositorio de datos externos, no corresponde al entrenamiento del modelo sobre esos datos, sino que se le aplicó el modelo entrenado de la persona que era más cercana en términos fisiológicos, y en base a eso se obtuvieron sus resultados. Esta adaptación abre nuevas aristas sobre un modelo en el cual se pudiese universalizar o extrapolar los

datos de pocas personas, a un grupo mayor de personas que posean características fisiológicas parecidas.

Los beneficios de aplicar este tipo de enfoque son variados, y transversales para todos los actores dentro de un sistema como el propuesto. Se reducirían drásticamente los tiempos entre crear un modelo y llevarlo a producción, como también se reducirían los costos económicos asociados a este proceso, tanto en el ámbito de recursos computacionales, como también humanos.

## 5. CONCLUSIONES Y TRABAJO FUTURO

### 5.1 Conclusiones

Una vez terminado el estudio, se cumplió el objetivo de diseñar, implementar y validar preliminarmente un sistema que identifique en tiempo real, minuto a minuto, el estado fisiológico de una persona, en base a datos fisiológicos no invasivos y técnicas de inteligencia artificial. Debido a lo anterior, se validó la tesis de la investigación sobre si era posible identificar en tiempo real el estado fisiológico de una persona mediante el uso de inteligencia artificial.

Según los resultados obtenidos se concluye que el mejor modelo para identificar los estados fisiológicos es el modelo VAE CNN A R 3D o también llamado “*What Color*”, que está compuesto de un autoencoder variacional con dos capas convolucionales de codificación y dos capas deconvolucionales de decodificación, ambas con un kernel de cinco, y un espacio latente de tres dimensiones, del cual nacen tres clústeres diferentes correspondientes a los estados fisiológicos de cada persona mediante la técnica de mezcla de gaussianas.

Además, la conclusión anterior se sostiene bajo la hipótesis de que la clusterización realizada efectivamente agrupa los datos en tres grupos de estados fisiológicos diferentes. Esta hipótesis se confirma bajo cinco argumentos. El primero, es mediante la observación visual de las señales de intervalos RR que vive en cada uno de los clústeres, donde se muestran dos polos fisiológicos diferentes, en conjunto con señales que viajan de un polo al otro. Siendo los polos opuestos los estados fisiológicos relajado y activo, mientras que las señales que viajan entre polos se denomina estado de transición.

El segundo argumento es la relación existente entre el estado fisiológico, la postura de la persona y los periodos de sueño. Existe una alta correlación entre los momentos en que la persona se encuentra en un estado fisiológico relajado y una postura horizontal, a lo que se suma también la tercera componente que son horarios en los que una persona promedio se encontrarían en lapsos de sueño o reposo, entre las 23:00 y las 8:00 hrs.

El tercero es que los valores promedios y desviaciones estándar existentes de las variables fisiológicas de cada uno de los participantes poseen una tendencia intuitiva a lo que se esperaría de un estado fisiológico activo, transición o relajado. En promedio el estado fisiológico alterado posee frecuencias de latidos cardiacos y respiraciones más altas que los otros estados, luego le sigue el estado de transición, y finalmente el estado relajado.

El cuarto argumento proviene del análisis del estado del arte sobre estados fisiológicos, donde se afirma que la variable fisiológica RMSSD que corresponde a la raíz cuadrada del valor medio de la suma de las diferencias al cuadrado de todos los intervalos RR sucesivos, disminuye a medida que una persona se encuentra en un estado de fatiga, estrés, somnolencia o sobrecarga mental en comparación a un estado fisiológico normal. Esta tendencia se cumple en la investigación, y surge de forma espontánea en los resultados de la clusterización de los estados fisiológicos, ratificando así el estado del arte.

Finalmente, el quinto argumento es que se aplicó el modelo a un repositorio externo de datos fisiológicos obteniendo resultados acordes a los esperados. En aquellos momentos cuando las personas se encontraban en reposo, el modelo marcó que las

personas se encontraban en un estado fisiológico relajado, y a medida que iban realizando actividad física su estado fisiológico fue aumentando progresivamente hasta llegar al estado fisiológico activo.

## **5.2 Limitaciones**

Existe una limitación computacional importante en el estudio. En primera instancia los primeros esfuerzos computacionales de entrenar los algoritmos de inteligencia artificial sobre los intervalos RR, se vieron frustrados, debido a falta de memoria computacional. Para solucionar este problema, se tuvo que incurrir en la compra de un computador con mejores características, y, aun así, se tuvo que analizar cada persona por separado, debido a que cuando se entrenaban los modelos de las 6 personas de manera de corrida, sumado a la elaboración de sus reportes, el computador se queda sin memoria.

Al mismo tiempo, los datos de electrocardiograma poseen mucha información que no fue recogida en el estudio. Solo se consideraron los intervalos RR existentes en el electrocardiograma, sin embargo, la cantidad de información que se puede obtener a partir del electrocardiograma es mucho más vasta que la utilizada. No obstante, el problema computacional sería mayor, debido a que la memoria ahora debería alcanzar a analizar el electrocardiograma de cada una de las 6 personas, durante una semana, lo cual se vuelve inviable computacionalmente con los medios existentes en el estudio.

En último lugar, otra limitación es la ausencia de un experto en el área de la biología o fisiología del ser humano. Si bien, el estado del arte revisado, y los conocimientos adquiridos logran situar un ambiente explicativo de como los problemas dentro de la fisiología humana se hacen presentes cuando se encuentra en un estado de estrés o

fatiga, es importante indicar, que algunos tópicos relacionados a ese flujo fueron omitidos o simplificados debido a falta de tiempo para entender en profundidad el fenómeno fisiológico que ocurre.

### **5.3 Trabajo Futuro**

Se sugiere que los próximos estudios en esta área se dirijan a expandir la cantidad de variables fisiológicas que se miden para entrenar los modelos, debido a que mientras más información se tenga acerca de cómo está la persona en tiempo real, será más completa la información que reciben los algoritmos de inteligencia artificial para llegar a un resultado correcto, junto con aumentar la capacidad computacional con la que se cuenta para entrenar dichos modelos.

Así también, se recomienda que los datos recolectados sean de personas que se encuentren solamente en su horario laboral, de esta manera los entrenamientos de los modelos se ajustarán a un contexto laboral, y se podrán analizar los resultados sobre qué momentos le generan a cada persona efectos adversos en su condición fisiológica, obteniendo así posibles entradas para eventuales sistemas que apunten a mitigar esos efectos.

Análogamente, se debería expandir la cantidad de clústeres que se generan a partir de los datos. Todas las personas poseen fisiologías diferentes, y mientras más continua sea la clasificación entre estados, es más fácil ver el avance de los estados fisiológicos en cada una. A modo de sugerencia, se debe pensar en un modelo continuo de identificación de estados fisiológicos en comparación a los tres clústeres generados en esta investigación, que es justamente a lo que se quiso llegar con los gráficos de probabilidad entre clústeres.

Sin lugar a duda, los algoritmos de inteligencia artificial progresan diariamente, y se debería trabajar con nuevas técnicas que garanticen una mejor clusterización, teniendo como objetivo la diferencia fisiológica entre los grupos.

También, trabajar en establecer consensos entre los investigadores, acerca de que es un estado fisiológico, cuanto tiempo debe durar cada estado, y como se debe medir.

Un estado fisiológico engloba una serie de conceptos tales como somnolencia, estrés, sobrecarga mental, fatiga, entre otros, y se hace difícil poder discernir entre ellos al momento de identificar el estado en que se encuentra la persona. Al mismo tiempo, se debe avanzar en la utilización de sensores que sean aún menos invasivos para el usuario que los usados en este estudio, para la medición de las variables fisiológicas.

## BIBLIOGRAFÍA

- Ahn, J. W., Ku, Y., & Kim, H. C. (2019). A Novel Wearable EEG and ECG Recording System for Stress Assessment. *Sensors*, 19(9), 1991.
- Anderson, M., & Denkl, M. (2010). The Heinrich Accident Triangle – Too Simplistic A Model For HSE Management in The 21st Century?. *SPE International Conference on Health, Safety and Environment in Oil and Gas Exploration and Production*. Society of Petroleum Engineers. Retrieved 18 November 2018.
- Antofagasta Minerals S.A. (2018). Reporte de sustentabilidad. *Recuperado de <http://www.aminerals.cl/media/6074/antofagasta-mineralsreportesustentabilidad2018.pdf>*.
- American Heart Association. (2021). “Target Heart Rates Chart”: American Heart Association. *Heart.org* <https://www.heart.org/en/healthy-living/fitness/fitness-basics/target-heart-rates>
- Bao, J., Liu, P., & Ukkusuri, S. V. (2019). A spatiotemporal deep learning approach for citywide short-term crash risk prediction with multi-source data. *Accident Analysis & Prevention*, 122, 239–254.
- Barsevick, A. M., Cleeland, C. S., Manning, D. C., O’Mara, A. M., Reeve, B. B., Scott, J. A., & Sloan, J. A. (2010). ASCPRO Recommendations for the Assessment of Fatigue as an Outcome in Clinical Trials. *Journal of Pain and Symptom Management*, 39(6), 1086–1099.
- Blake, H. (2017). “¿Qué le pasa a tu cuerpo cuando estás estresado?”: Holly Blake. *elpais.com.co*. [https://elpais.com/elpais/2017/08/11/ciencia/1502462353\\_596394.html](https://elpais.com/elpais/2017/08/11/ciencia/1502462353_596394.html)
- Blei, D., Kucukelbir, A., & McAuliffe, J. (2017). Variational Inference: A Review for Statisticians. *Journal of the American Statistical Association*.
- Burattini, L. (2020), “Sport Database: Cardiorespiratory data acquired through wearable sensors while practicing sports”. *Mendeley Data*, V1.
- Caldwell, J., Caldwell, L., J.; Thompson, L., & Lieberman, H. (2018). Fatigue and its management in the workplace. *Neuroscience & Biobehavioral Reviews*.
- Can, Y., Chalabianloo, N., Ekiz, D., & Ersoy C. (2019). Continuous Stress Detection Using Wearable Sensors in Real Life: Algorithmic Programming Contest Case Study. *Sensors*, 19(8), 1849.
- Cárdenas, D. Conde-González, J. Perales, J.C. (2016). La fatiga como estado motivacional subjetivo. *Revista Andaluza de Medicina del Deporte*, (), S1888754616300569–.

- Caterini, A. (2017). A Novel Mathematical Framework for the Analysis of Neural Networks. *UWSpace*.
- Choi, M., Koo, G., Seo, M., & Kim, S. (2018). Wearable Device-Based System to Monitor a Driver's Stress, Fatigue, and Drowsiness. *IEEE Transactions on Instrumentation and Measurement*, 67(3), 634-645.
- Colorado School of Mines. (2011). Accidents – The Total Cost A Guide for Estimating the Total Cost of Accidents. *Colorado: Mine Safety and Health Program Golden*.
- Codelco. (2018). Memoria anual de Codelco. *Recuperado de [https://www.codelco.com/prontus\\_codelco/site/artic/20190329/asocfile/20190329125919/codelco\\_memoria2018.pdf](https://www.codelco.com/prontus_codelco/site/artic/20190329/asocfile/20190329125919/codelco_memoria2018.pdf)*.
- Deisenroth, M., Faisal, A., & Ong, C. (2020). Mathematics for Machine Learning. *Cambridge University Press*.
- Goh, Y., Ubeynarayana, C., Wong, K., & Guo, B. (2018). Factors influencing unsafe behaviors: A supervised learning approach. *Accident Analysis and Prevention*, 118, 77-85.
- Graves, A. (2012). Supervised Sequence Labelling with Recurrent Neural Networks. *Studies in Computational Intelligence*.
- Gore, Brian F. (2018). Space Safety and Human Performance || Workload and fatigue. , (), 53–85.
- Gurel, N., Jung, H., Hersek, S., & Inan, O. (2019). Fusing Near-Infrared Spectroscopy With Wearable Hemodynamic Measurements Improves Classification of Mental Stress. *IEEE Sensors Journal*, 19(19), 8522-8531.
- Han, L., Zhang, Q., Chen, X., Zhan, Q., Yang, T., & Zhao, Z. (2017). Detecting work-related stress with a wearable device. *Computers in Industry*, 90, 42-49.
- Harrington, M. (2012). Neurobiological studies of fatigue. *Progress in Neurobiology*, 99(2), 93-105.
- Health and Safety Executive. (1999). The cost to Britain of workplace accidents and work-related ill health in 1995/96. p. 32. *Retrieved 18 November 2018*.
- Hernando, D., Roca, S., Sancho, J., Alesanco, Á., & Bailón, R. (2018). Validation of the Apple Watch for Heart Rate Variability Measurements during Relax and Mental Stress in Healthy Subjects. *Sensors*, 18(8), 2619.
- Hickman, J., & Geller, E. (2003). A safety self-management intervention for mining operations. *Journal of Safety Research*, 34(3), 299-308.

- Hochreiter, S. & Schmidhuber, J. (1997). Long Short-term Memory. *Neural computation*, 9(8), 1735-80.
- Hongxia, L., Yongbin, F., Shuicheng, T., Fen, L., & Huan, L. (2014). Study on the Job Stress of Miners. *Procedia Engineering*, 84(), 239-246.
- Huysmans, D., Smets, E., De Raedt, W., Van Hoof, C., Bogaerts, K., Van Diest, I., & Helic, D. (2018). Unsupervised Learning for Mental Stress Detection - Exploration of Self-Organizing Maps. *Proc. of Biosignals 2018*, 4, 26-35.
- Jacobé de Naurois, C., Bourdin, C., Bougard, C., & Vercher, J.-L. (2018). Adapting artificial neural networks to a specific driver enhances detection and prediction of drowsiness. *Accident Analysis & Prevention*, 121, 118–128.
- Jiang, Z., Zheng, Y., Tan, H., Tang, B., & Zhou, H. (2017). Variational Deep Embedding: An Unsupervised and Generative Approach to Clustering. *arXiv*, abs/1611.05148v3
- Katic, I., Ivanisevic, A., Lalic, G., Tasic, N., & penezić, N. (2013). Effects of fatigue to operational productivity with employees. *International Metallurgic*, 18, 170-176.
- Knigma, D., & Ba, J. (2017). Adam: A Method for Stochastic Optimization. *arXiv*, abs/1412.6980v9.
- Knigma, D., & Welling, M. (2014). Auto-Encoding Variational Bayes. *2<sup>nd</sup> International Conference on Learning Representations ICLR*.
- Kowalski, K. (2003). The Effects of Disaster on Workers: A Study of Burnout in Investigators of Serious Accidents and Fatalities in the U.S. Mining Industry. *International Journal of Emergency Management*, (1, 2), p. 155 – 169.
- Lee, B. G., Chong, T. W., Lee, B. L., Park, H. J., Kim, Y. N., & Kim, B. (2017). Wearable Mobile-Based Emotional Response-Monitoring System for Drivers. *IEEE Transactions on Human-Machine Systems*, 47(5), 636–649.
- Lee, B.-G., & Chung, W.-Y. (2017). Wearable Glove-Type Driver Stress Detection Using a Motion Sensor. *IEEE Transactions on Intelligent Transportation Systems*, 18(7), 1835–1844.
- Leka, S., Jain, A., Iavicoli, S., Vartia, M., & Ertel, M. (2011). The role of policy for the management of psychosocial risks at the workplace in the European Union. *Safety Science*, 49(4), 558–564.
- Leukemia & Lymphoma Society (LLS) (2019). Manejo de estrés, efectos del estrés y como sobrellevarlos. *New York: 3 International Drive*.

- Lilić, N., Obradović, I., & Cvjetić, A. (2010). An intelligent hybrid system for surface coal mine safety analysis. *Engineering Applications of Artificial Intelligence*, 23(4), 453–462.
- Lim, K., Jiang, X., & Yi, C. (2020). Deep Clustering with Variational Autoencoder. *IEEE Signal Processing Letters*.
- Maaoui, C., & Pruski, A. (2018). Unsupervised stress detection from remote physiological signal. *2018 IEEE International Conference on Industrial Technology (ICIT)*.
- Mansikka, H., Simola, P., Virtanen, K., Harris, D., & Oksama, L. (2016). Fighter pilots' heart rate, heart rate variation and performance during instrument approaches. *Ergonomics*, 59(10), 1344–1352.
- Mansour, M. (2016). Quantifying the intangible costs related to non-ergonomic work conditions and work injuries based on the stress level among employees. *Safety Science*, 82, 283-288.
- Martínez-García, D., Dalgo, V., Herrera-López, J., Analuisa-Jiménez, E., & Velasco-Acurio, E. (2019). Avances de la inteligencia artificial en salud. *Dominio de las Ciencias*. 5(3), 603.
- Nakamura, F., Antunes, P., Nunes, C., Costa, J., Esco, M., & Travassos, B. (2018). Heart Rate Variability Changes From Traditional vs. Ultra-Short-Term Recordings in Relation to Preseason Training Load and Performance in Futsal Players. *Journal of Strength and Conditioning Research*. 1.
- Oficina internacional del trabajo. (2019). Estado del Trabajo Decente en el Mundo. *Recuperado de [https://www.ilo.org/wcmsp5/groups/public/---europe/---ro-geneva/---ilo-madrid/documents/genericdocument/wcms\\_723294.pdf](https://www.ilo.org/wcmsp5/groups/public/---europe/---ro-geneva/---ilo-madrid/documents/genericdocument/wcms_723294.pdf)*.
- Oskooei, A., Chau, S., Weiss, J., Sridhar, A., Rodriguez, M., & Michel, B. (2019). DeStress: Deep Learning for Unsupervised Identification of Mental Stress in Firefighters from Heart-rate Variability (HRV) Data. *arXiv*, abs/1911.13213.
- Paul, P., & Maiti, J. (2007). The role of behavioral factors on safety management in underground mines. *Safety Science*, 45(4), 449-471.
- Paul, P., & Maiti, J. (2008). The synergic role of sociotechnical and personal characteristics on work injuries in mines. *Ergonomics*, 51(5), 737-767.
- Pelders, J. & Nelson, G. (2019). Contributors to fatigue at a platinum smelter in South Africa. *Southern African Institute of Mining and Metallurgy*, 119(3), 313-319.
- Qing-Gui, C., Kai, L., Ye-Jiao, L., Qi-Hua, S., & Jian, Z. (2012). Risk management and workers' safety behavior control in coal mine. *Safety Science*, 50(4), 909-913.

- Rodas, G., Yanguas, X., Pedret, C., Ramos, J., & Capdevila, L. (2011). Cambios en la variabilidad de la frecuencia cardiaca (VFC) en jugadores de hockey hierba durante el Campeonato del Mundo de 2006. *Apunts. Medicina de l'Esport*, 46(171), 117–123.
- Sanmiquel, L., Rossell, J., & Vintró, C. (2015). Study of Spanish mining accidents using data mining techniques. *Safety Science*, 75(C), 49-55.
- Sarkar, S., Vinay, S., Raj, R., Maiti, J., & Mitra, P. (2019). Application of optimized machine learning techniques for prediction of occupational accidents. *Computers and Operations Research*, 106, 210-224.
- Sernageomin. (2018). Accidentabilidad Minera. Gobierno de Chile. *Recuperado de <https://www.sernageomin.cl/wp-content/uploads/2019/03/PresentacionAccidentes2018.pdf>*
- Shaffer F, Meehan Z & Zerr C. (2020). A Critical Review of Ultra-Short-Term Heart Rate Variability Norms Research. *Front Neurosci*. 14:594880.
- Shalev-Shwartz, S. & Ben-David, S. (2014). Understanding Machine Learning: From Theory to Algorithms. *Cambridge University Press*.
- Slavich, G. M. (2016). Life Stress and Health. *Teaching of Psychology*, 43(4), 346–355.
- Strahan, C., Watson, B., & Lennon, A. (2008). Can organizational safety climate and occupational stress predict work-related driver fatigue?. *Transportation Research Part F: Psychology and Behaviour*, 11(6), 418-426.
- Street, T., Lacey, S., & Somoray, K. (2018). Employee Stress, Reduced Productivity, and Interest in a Workplace Health Program: A Case Study from the Australian Mining Industry. *International Journal of Environmental Research and Public Health*, 16(1), 94.
- Suárez A, Núñez F & Rodriguez-Fernandez M. (2021) Circadian Phase Prediction from Non-Intrusive and Ambulatory Physiological Data. *IEEE Journal of Biomedical and Health Informatics*.
- Tixier, A., Hallowell, M., Rajagopalan, B., & Bowman, D. (2016). Application of machine learning to construction injury prediction. *Automation in Construction*, 69(C), 102-114.
- Vildjiounaite, E., Kallio, J., Mäntyjärvi, J., Kyllönen, V., Lindholm, M., & Gimel'farb, G. (2017). Unsupervised Stress Detection Algorithm and Experiments with Real Life Data. *Lecture Notes in Computer Science*, 95–107.
- Wang, C., Wang, J., Wang, X., Yu, H., Bai, L., & Sun, Q. (2019). Exploring the impacts of factors contributing to unsafe behavior of coal miners. *Safety Science*, 115, 339-348.
- Wang, J., Liu, B., Fu, T., Liu, S., & Stipanovic, J. (2019). Modeling when and where a secondary accident occurs. *Accident Analysis and Prevention*, 130, 160-166.

Wang, Y. (2020). A Mathematical Introduction to Generative Adversarial Nets (GAN). *arXiv*, abs/2009.00169

Zhang, N., Fard, M., Bhuiyan, M., Verhagen, D., Azari, M., & Robinson, S. (2018). The effects of physical vibration on heart rate variability as a measure of drowsiness. *Ergonomics*, 1–12.

Zhang, Y., Shao, W., Zhang, M., Li, H., Yin, S., & Xu, Y. (2016). Analysis 320 coal mine accidents using structural equation modeling with unsafe conditions of the rules and regulations as exogenous variables. *Accident Analysis and Prevention*, 92, 189-201.

Zhang, S., Shi, X., & Wu, C. (2017). Measuring the effects of external factor on leadership safety behavior: Case study of mine enterprises in China. *Safety Science*, 93, 241-255.

**ANEXO**

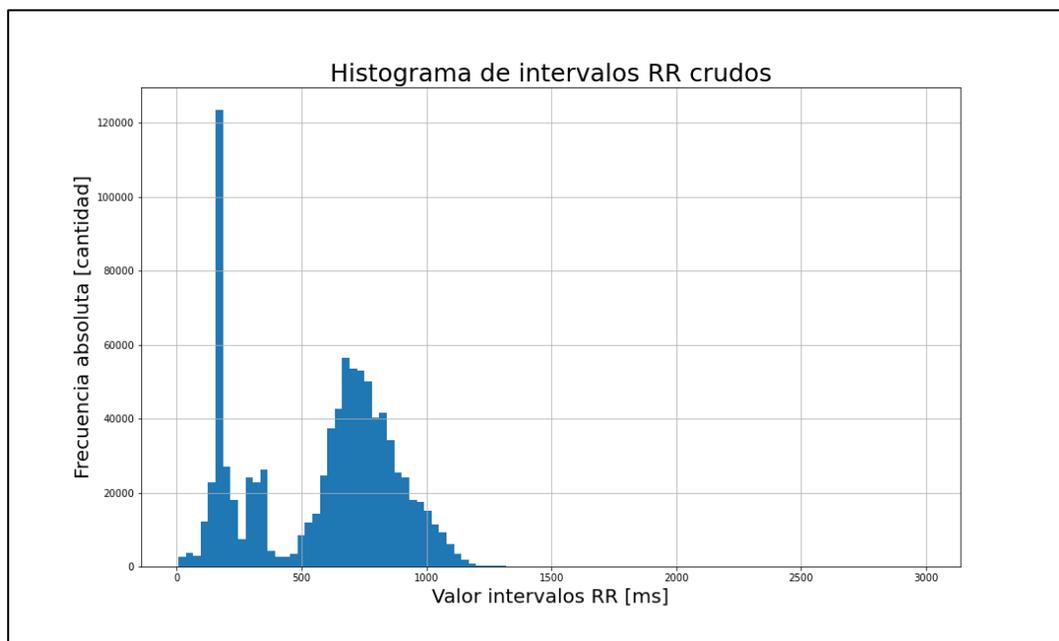


Figura 7-1: Histograma intervalos RR de entrenamiento persona número 3.

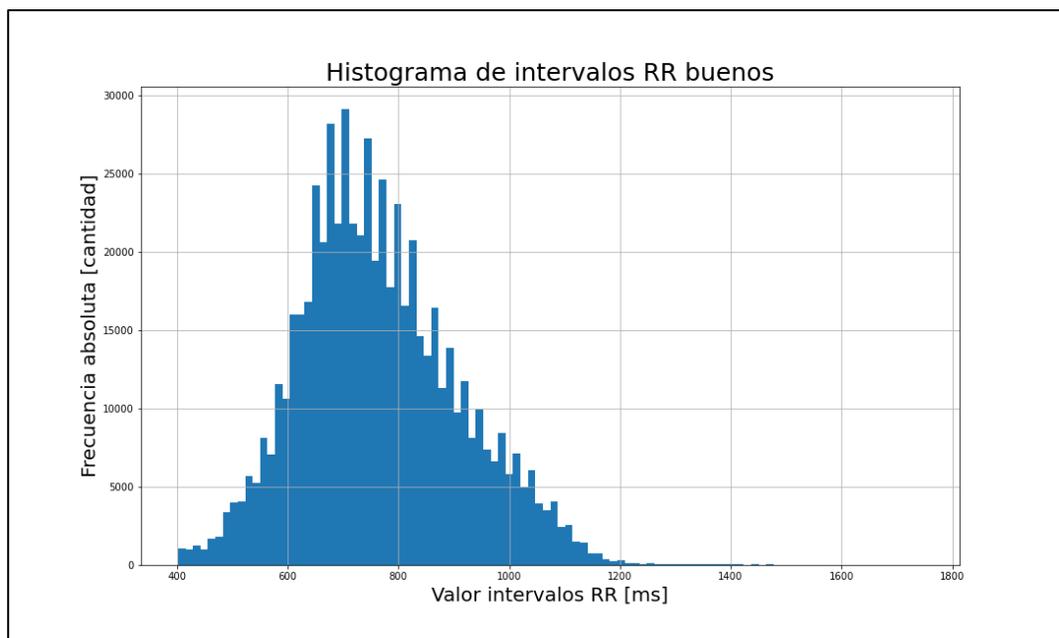


Figura 7-2: Histograma pre procesado intervalos RR de entrenamiento persona número 3.

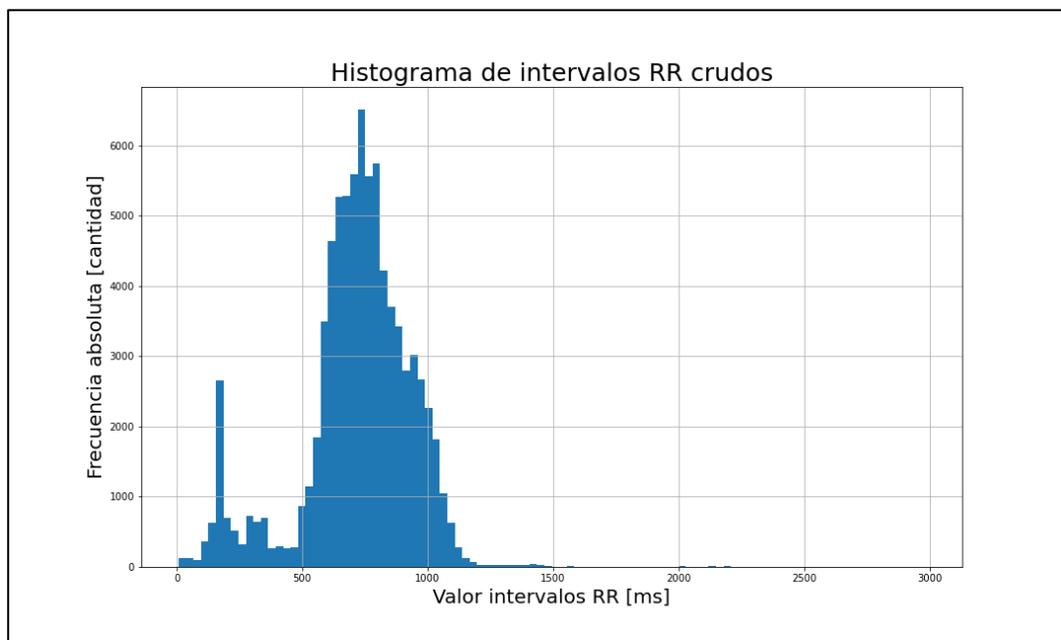


Figura 7-3: Histograma intervalos RR de validación persona número 3.

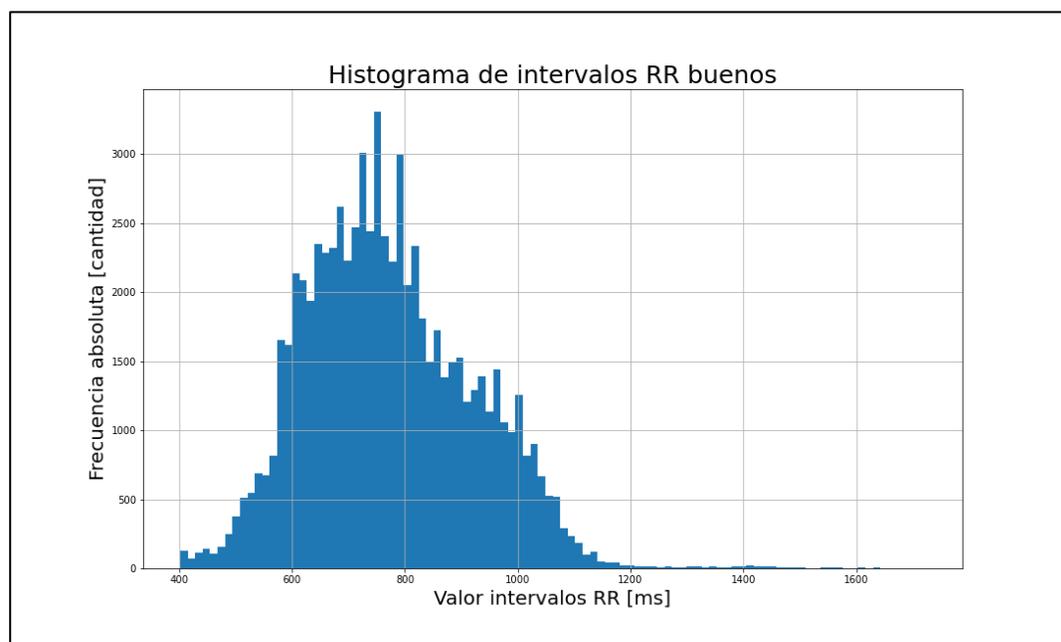


Figura 7-4: Histograma pre procesado intervalos RR de validación persona número 3.

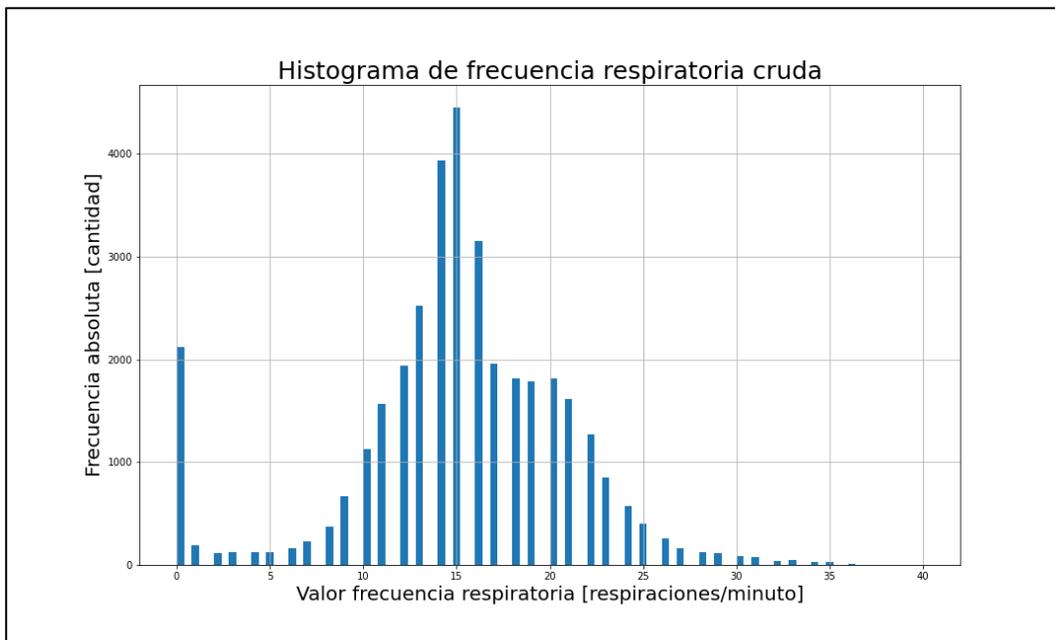


Figura 7-5: Histograma frecuencia respiratoria de entrenamiento persona número 3.

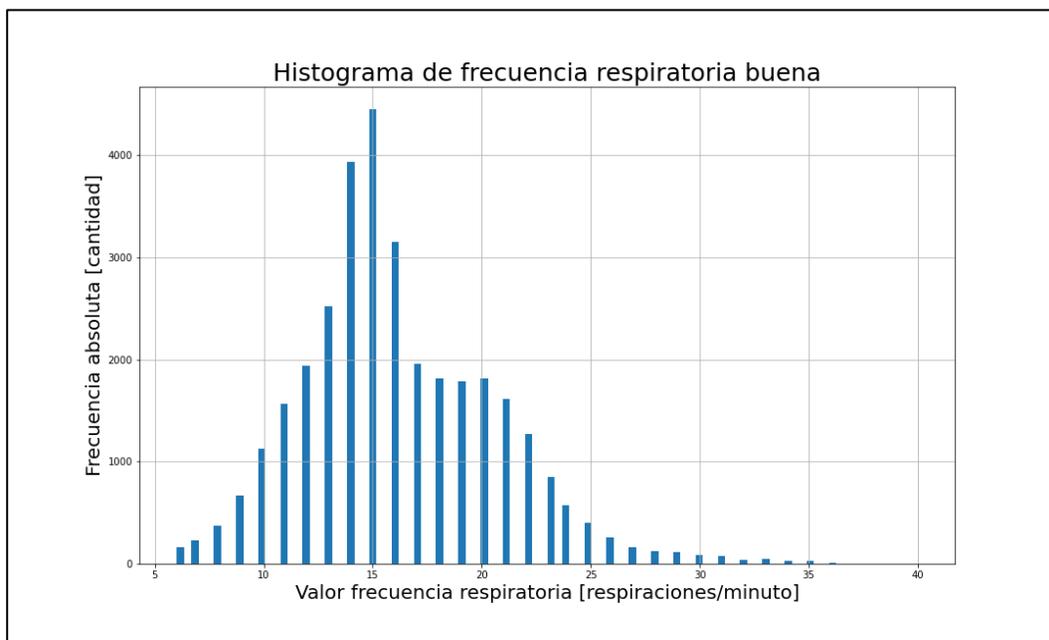


Figura 7-6: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 3.

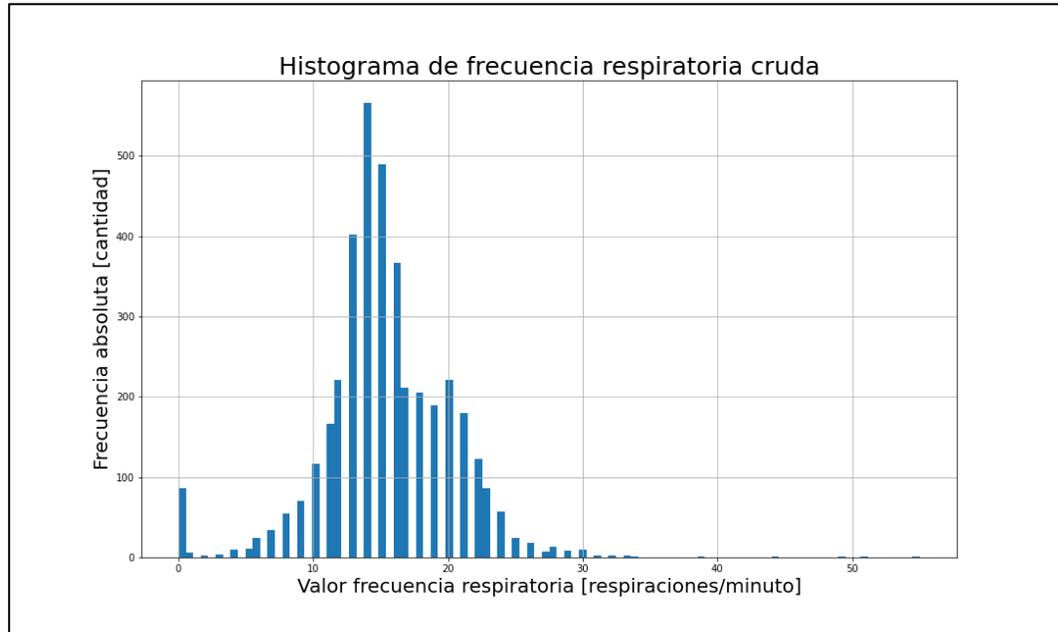


Figura 7-7: Histograma frecuencia respiratoria de validación persona número 3.

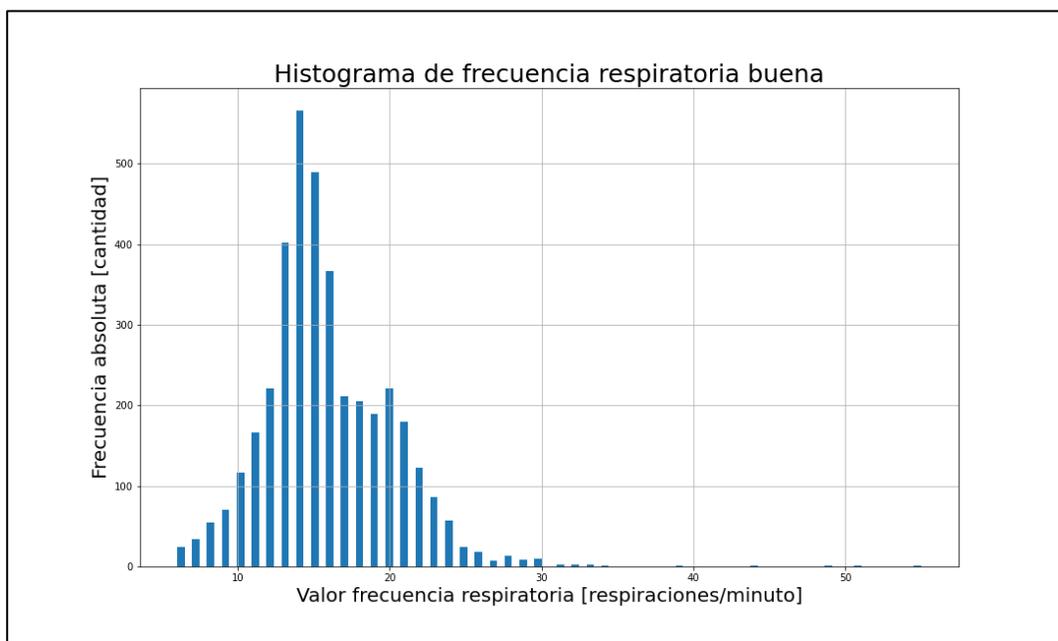


Figura 7-8: Histograma pre procesado frecuencia respiratoria de validación persona número 3.

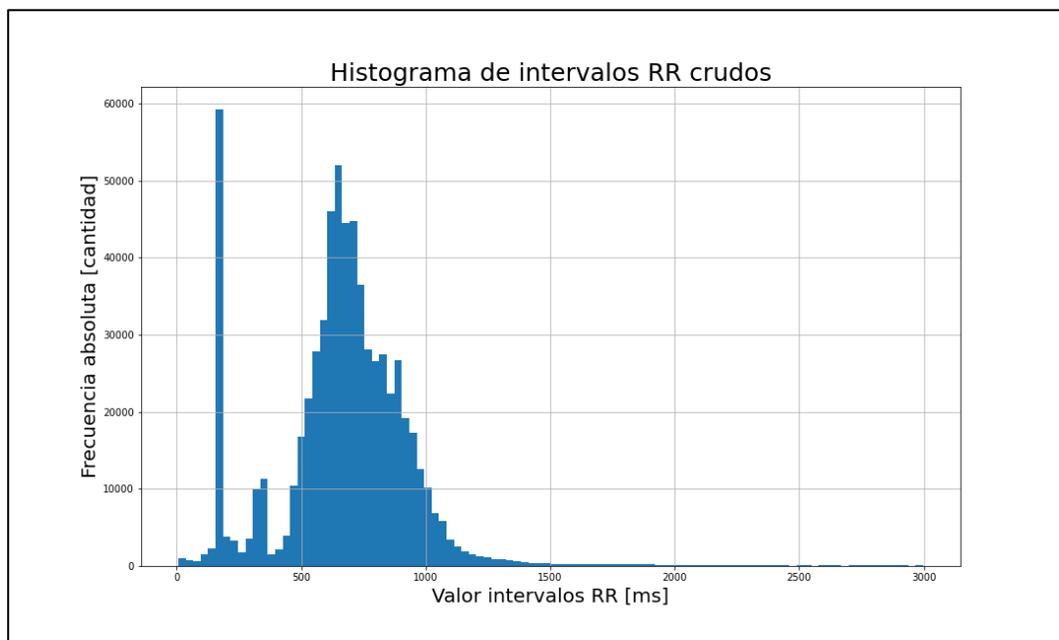


Figura 7-9: Histograma intervalos RR de entrenamiento persona número 5.

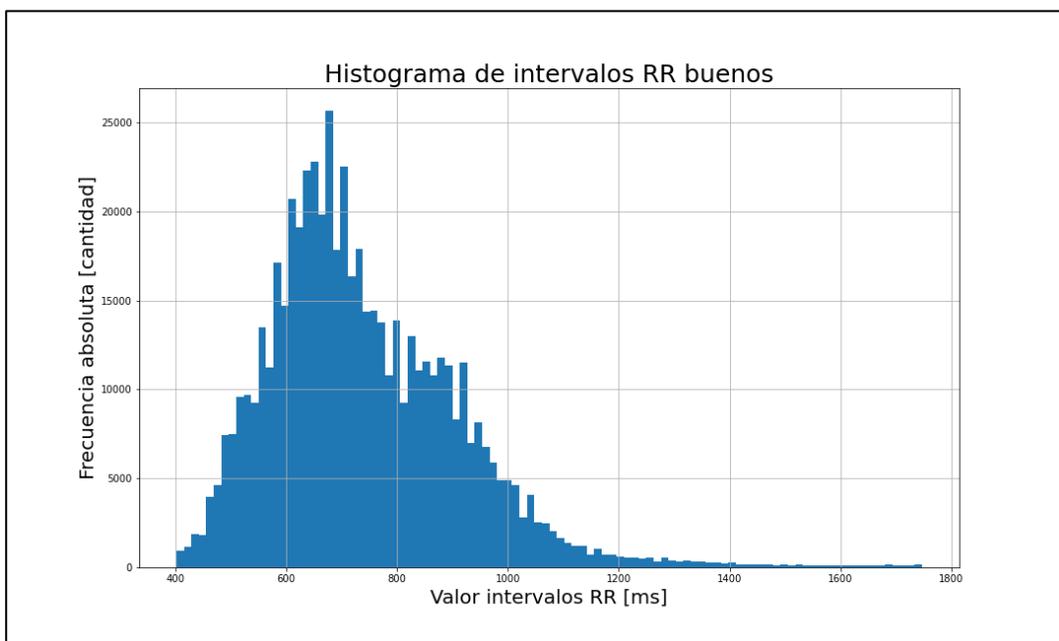


Figura 7-10: Histograma pre procesado intervalos RR de entrenamiento persona número 5.

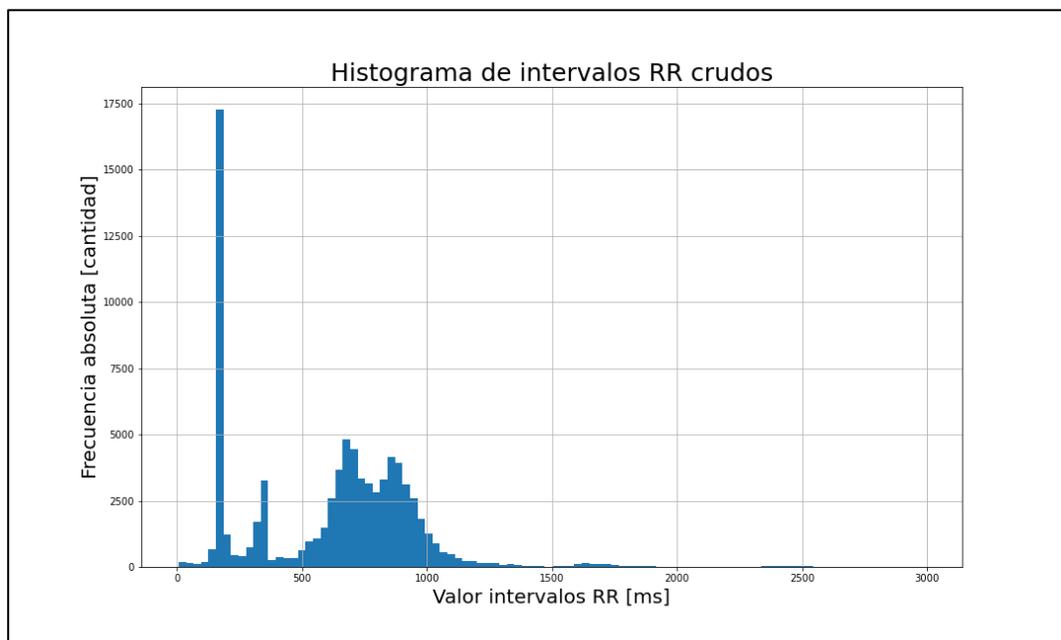


Figura 7-11: Histograma intervalos RR de validación persona número 5.

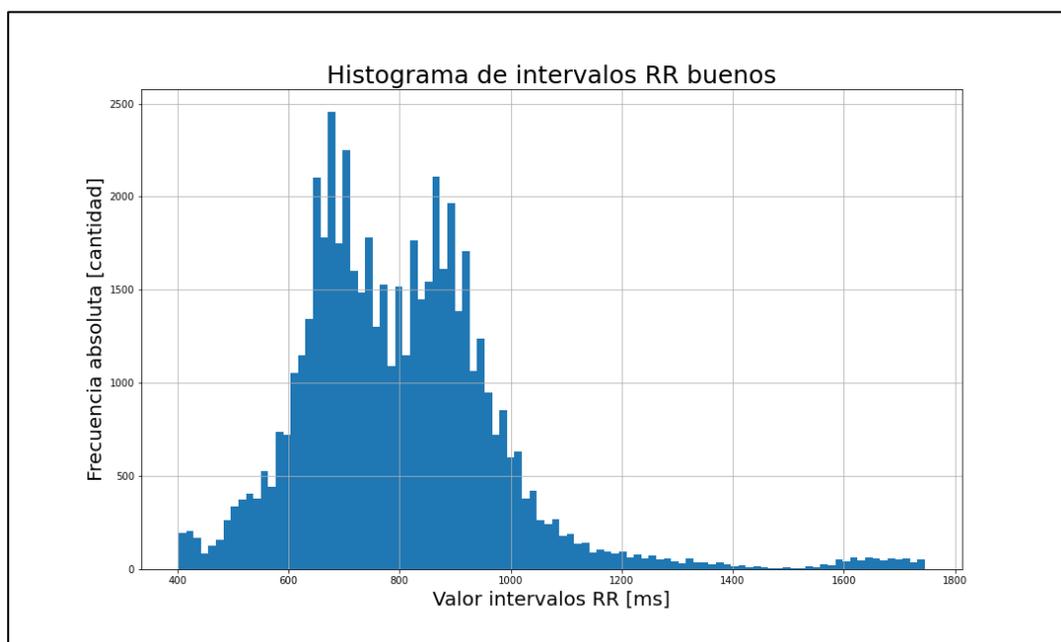


Figura 7-12: Histograma pre procesado intervalos RR de validación persona número 5.

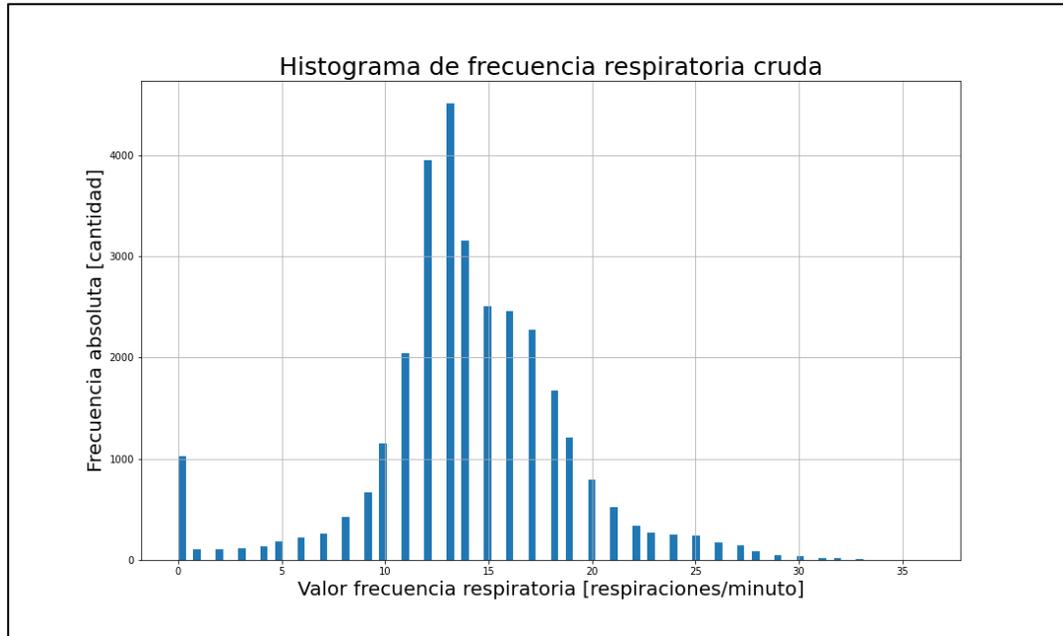


Figura 7-13: Histograma frecuencia respiratoria de entrenamiento persona número 5.

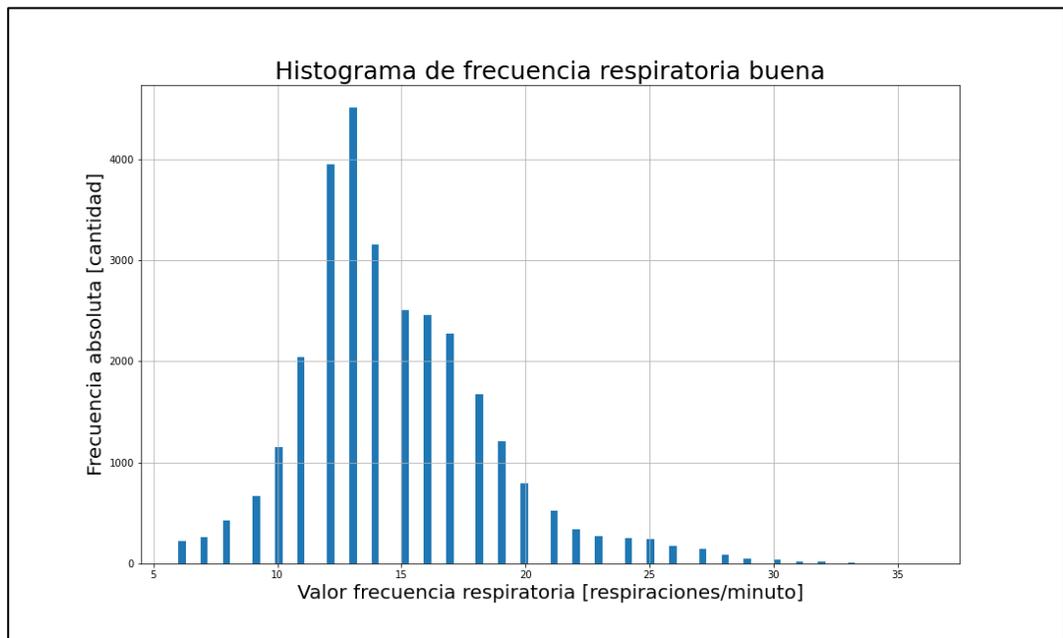


Figura 7-14: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 5.

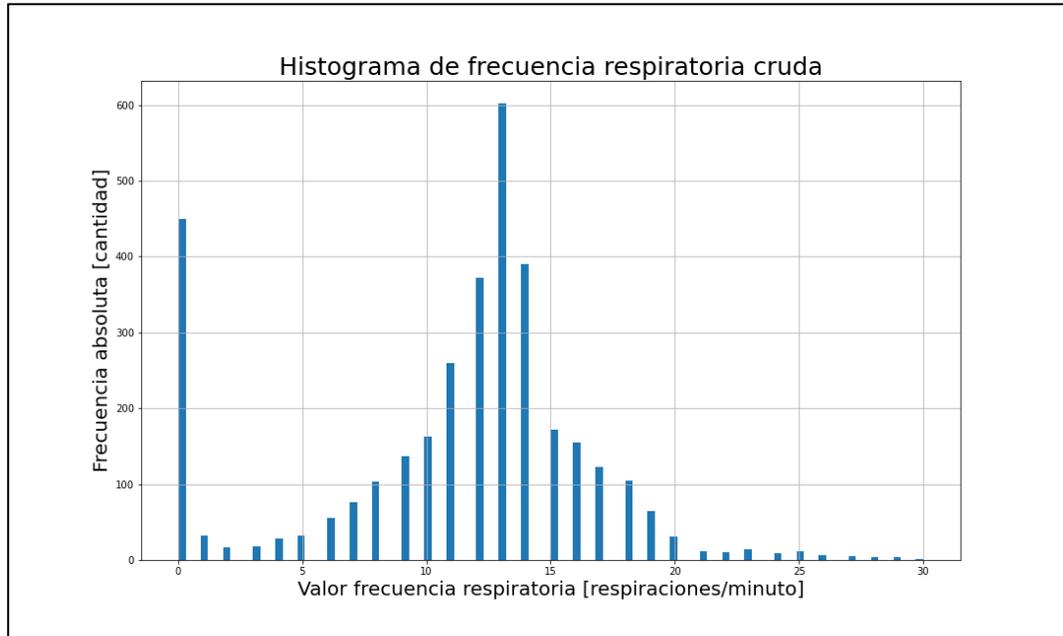


Figura 7-15: Histograma frecuencia respiratoria de validación persona número 5.

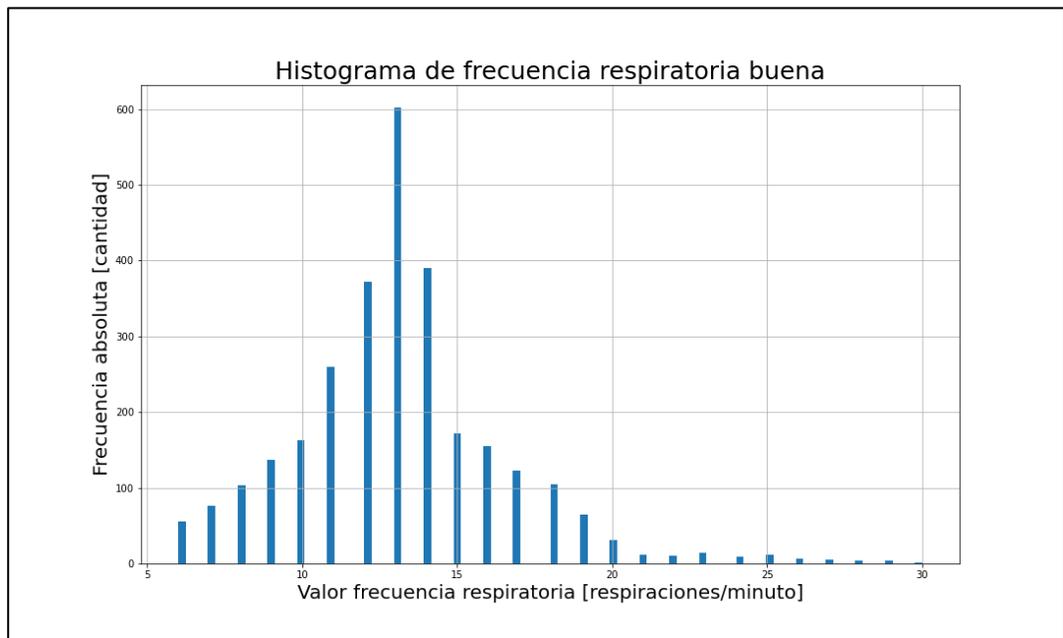


Figura 7-16: Histograma pre procesado frecuencia respiratoria de validación persona número 5.

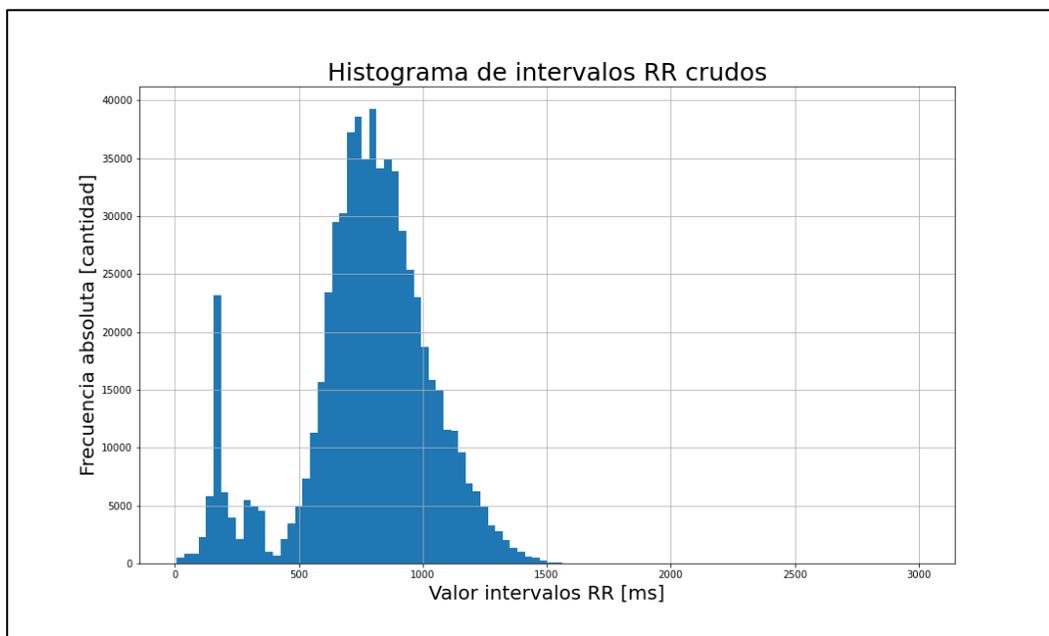


Figura 7-17: Histograma intervalos RR de entrenamiento persona número 7.

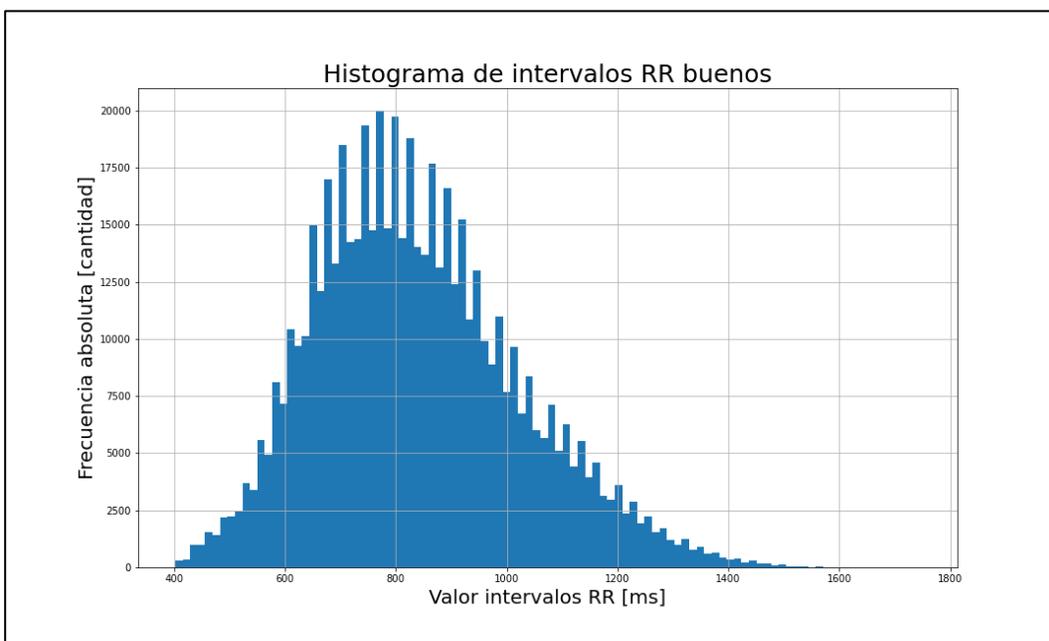


Figura 7-18: Histograma pre procesado intervalos RR de entrenamiento persona número 7.

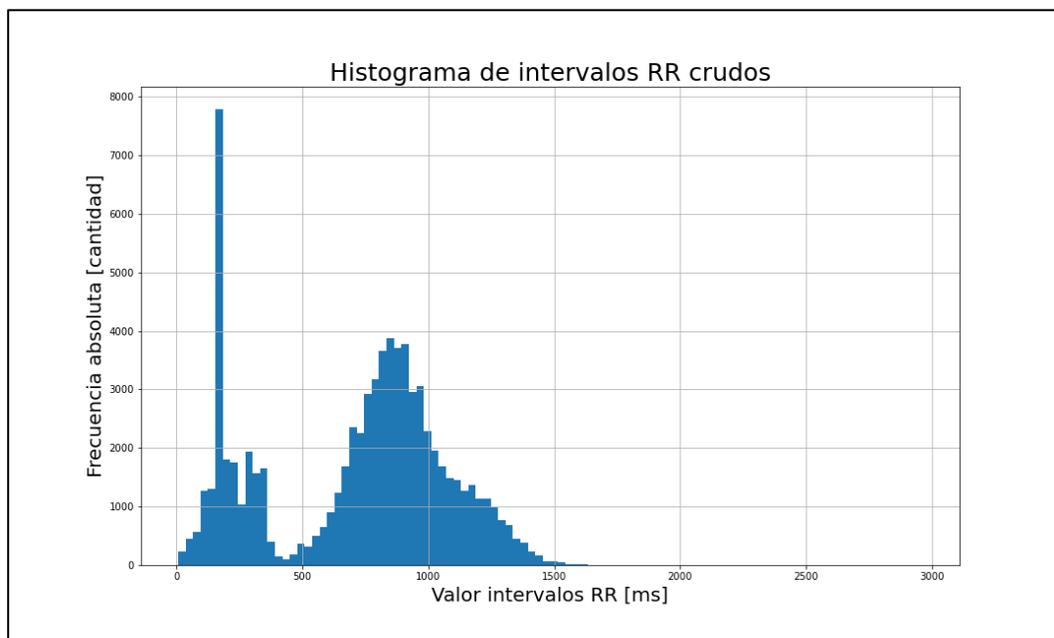


Figura 7-19: Histograma intervalos RR de validación persona número 7.

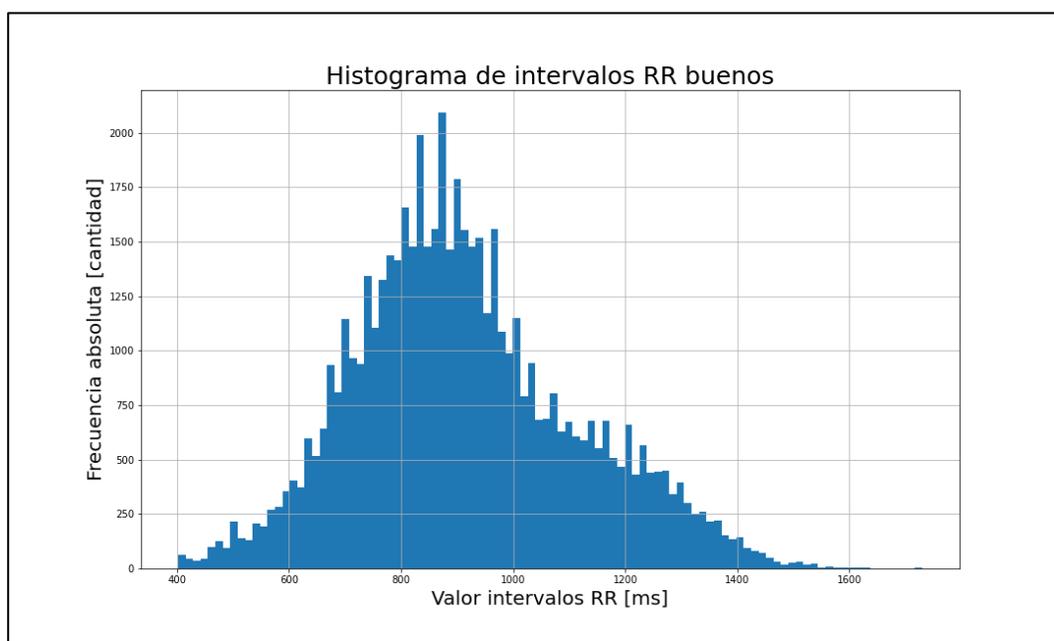


Figura 7-20: Histograma pre procesado intervalos RR de validación persona número 7.

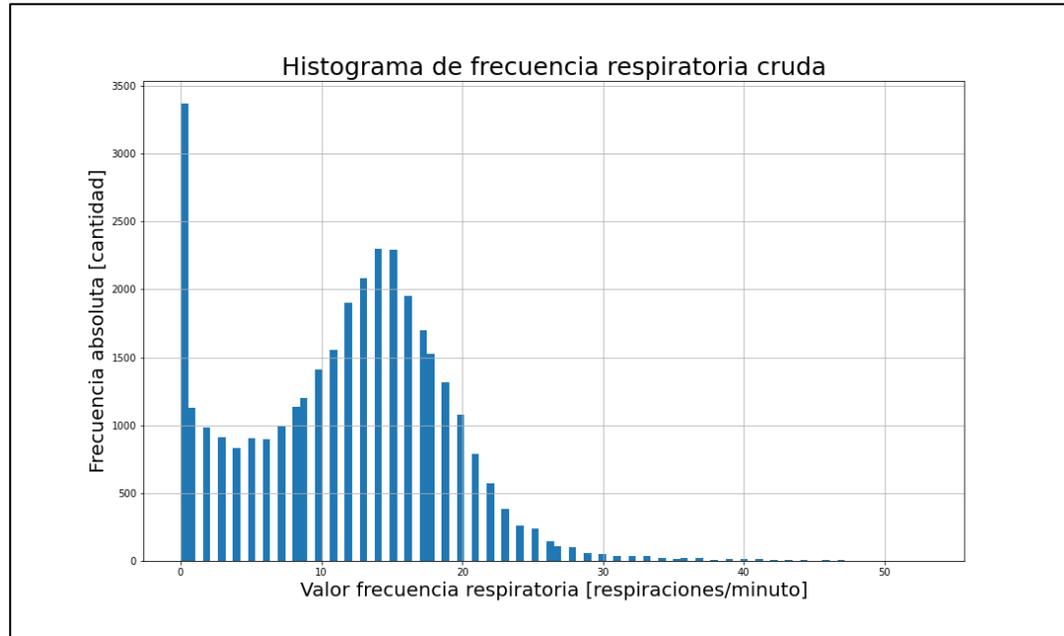


Figura 7-21: Histograma frecuencia respiratoria de entrenamiento persona número 7.

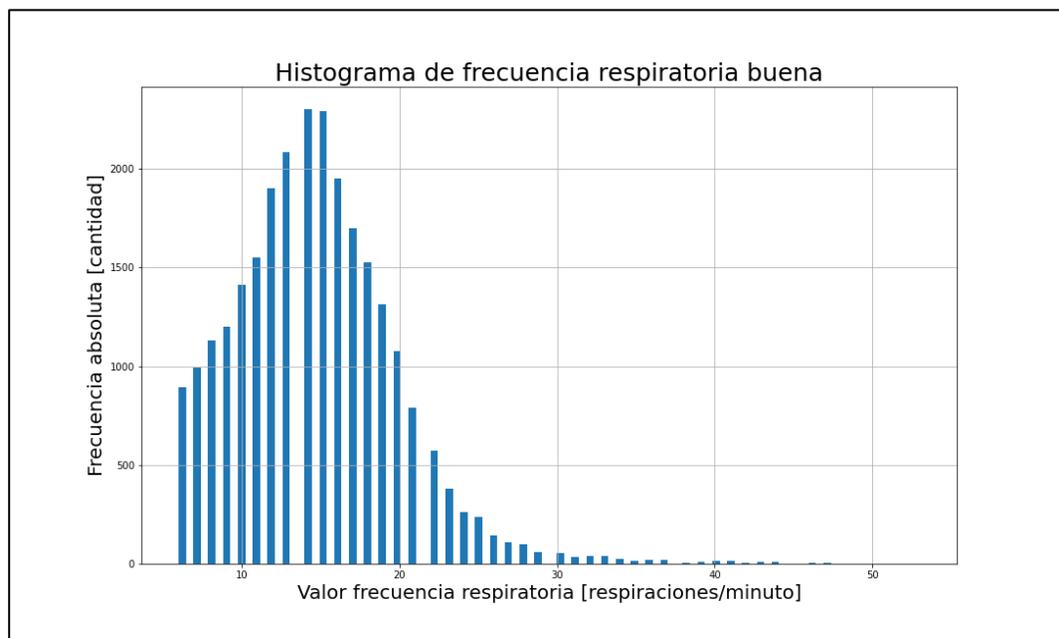


Figura 7-22: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 7.

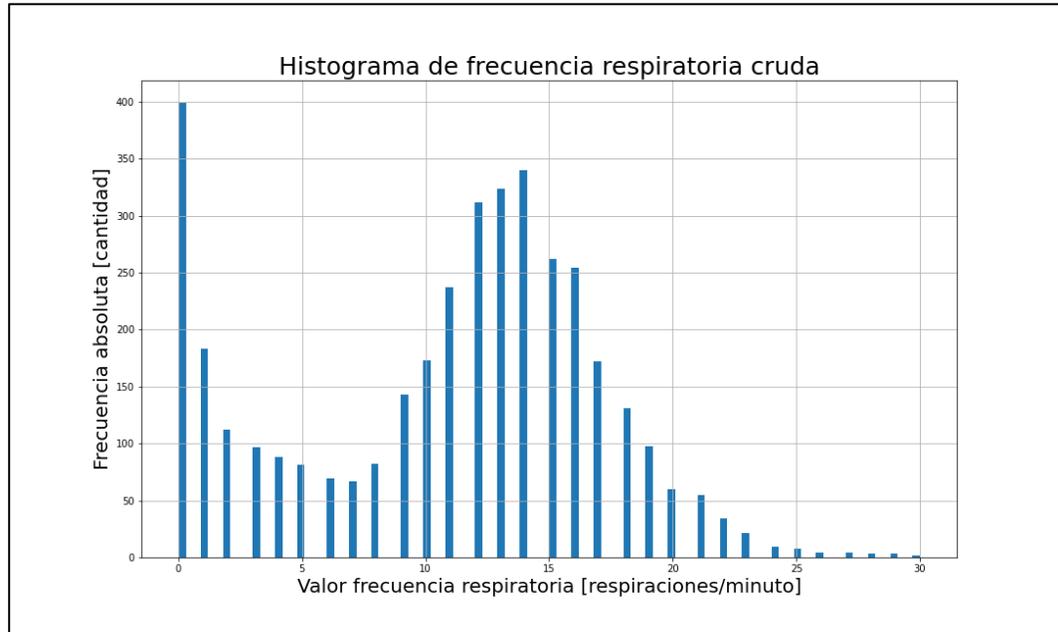


Figura 7-23: Histograma frecuencia respiratoria de validación persona número 7.

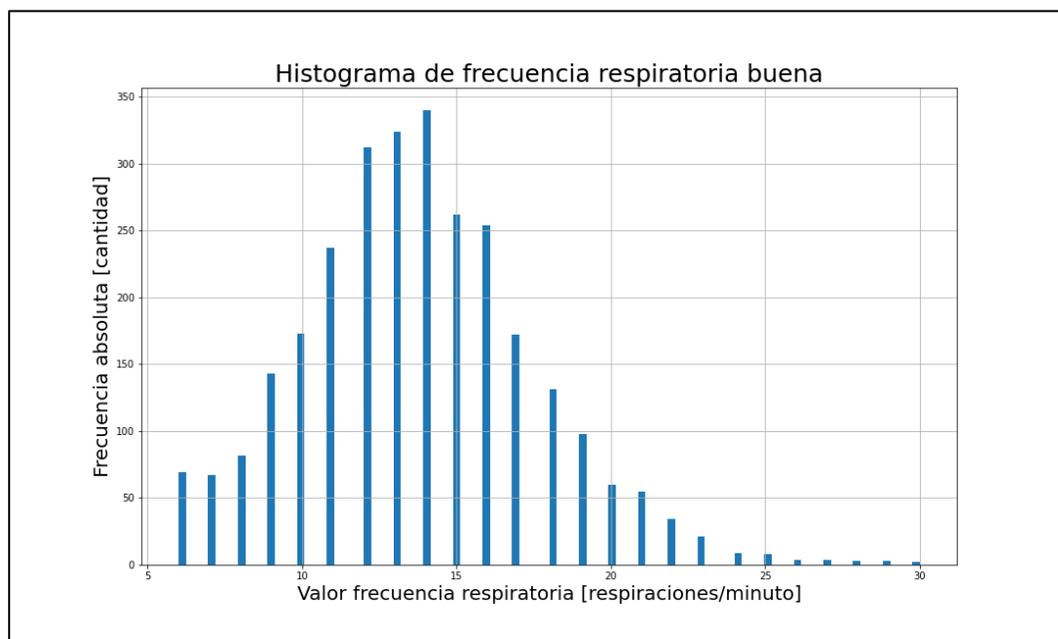


Figura 7-24: Histograma pre procesado frecuencia respiratoria de validación persona número 7.

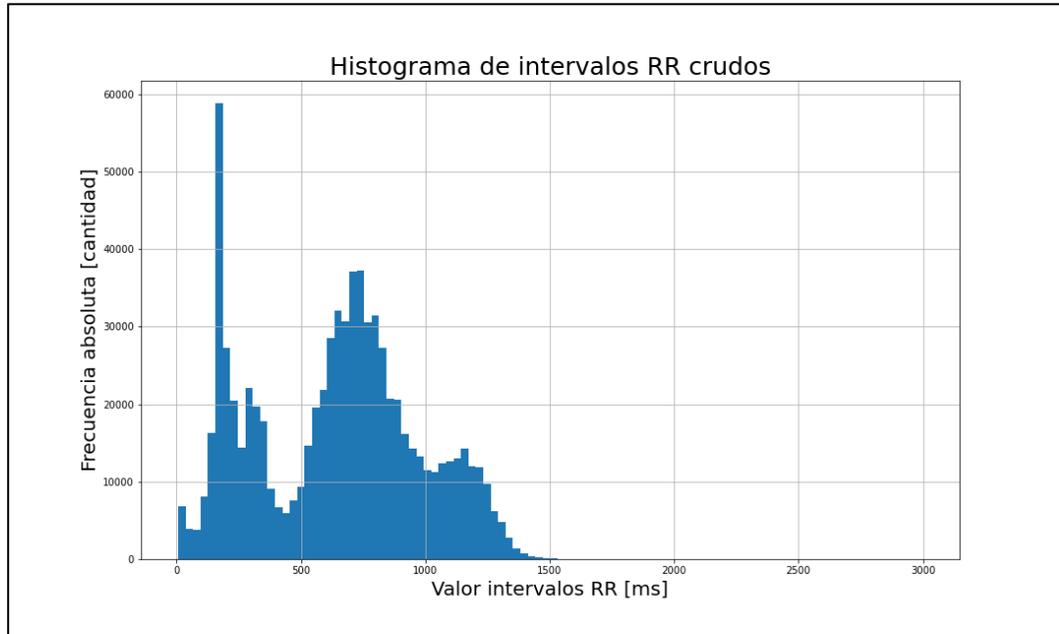


Figura 7-25: Histograma intervalos RR de entrenamiento persona número 8.

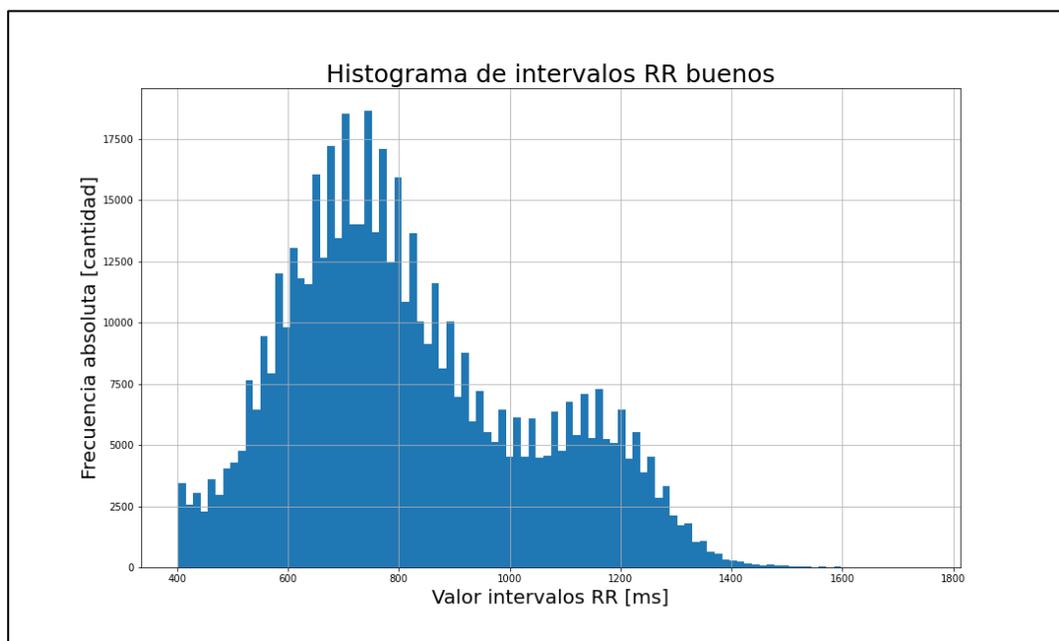


Figura 7-26: Histograma pre procesado intervalos RR de entrenamiento persona número 8.

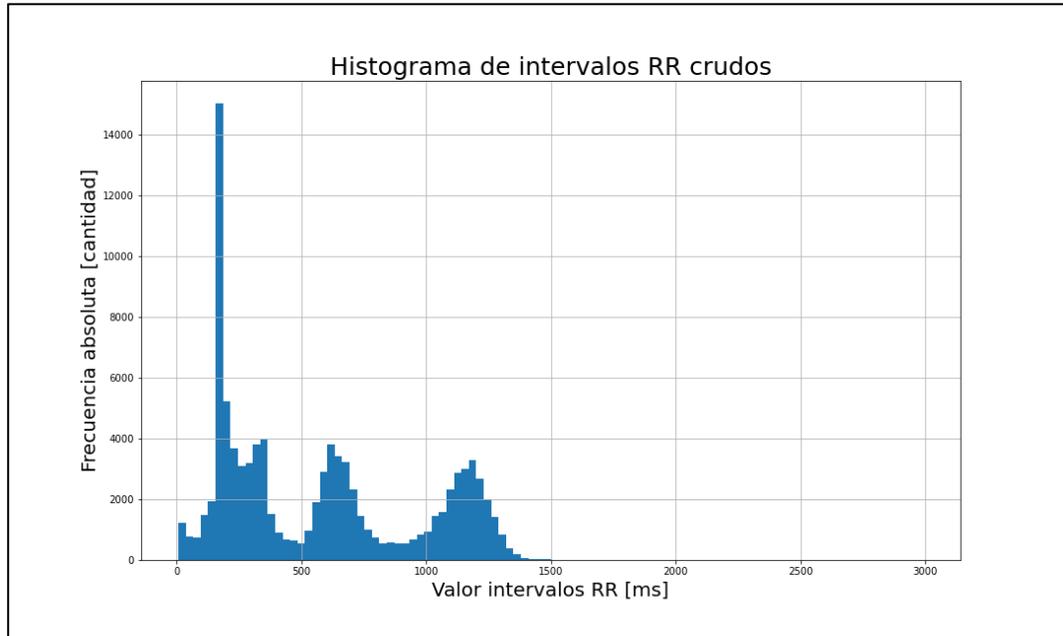


Figura 7-27: Histograma intervalos RR de validación persona número 8.

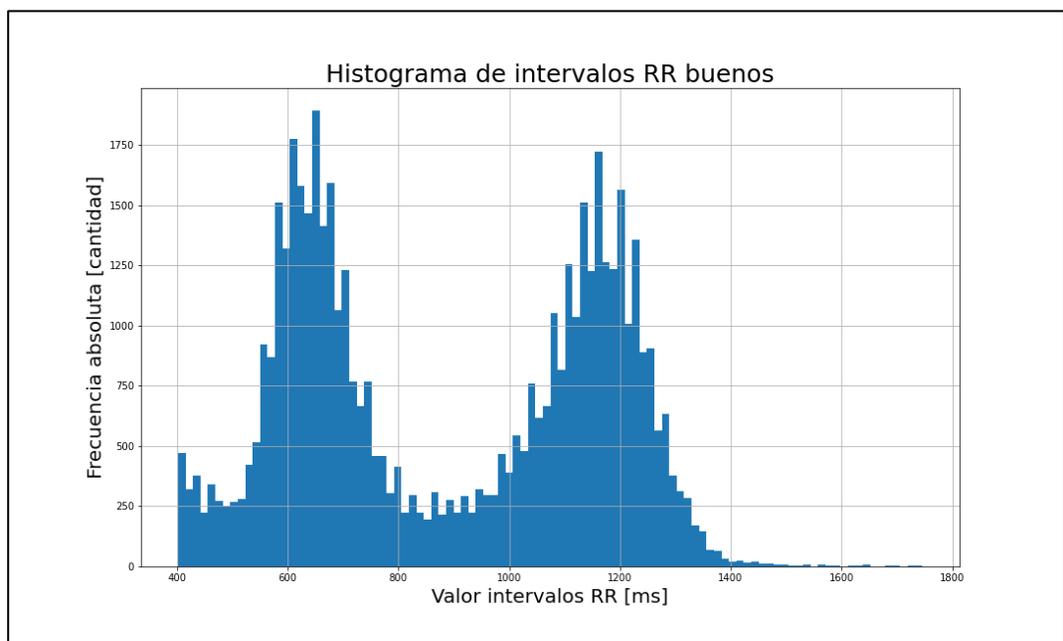


Figura 7-28: Histograma pre procesado intervalos RR de validación persona número 8.

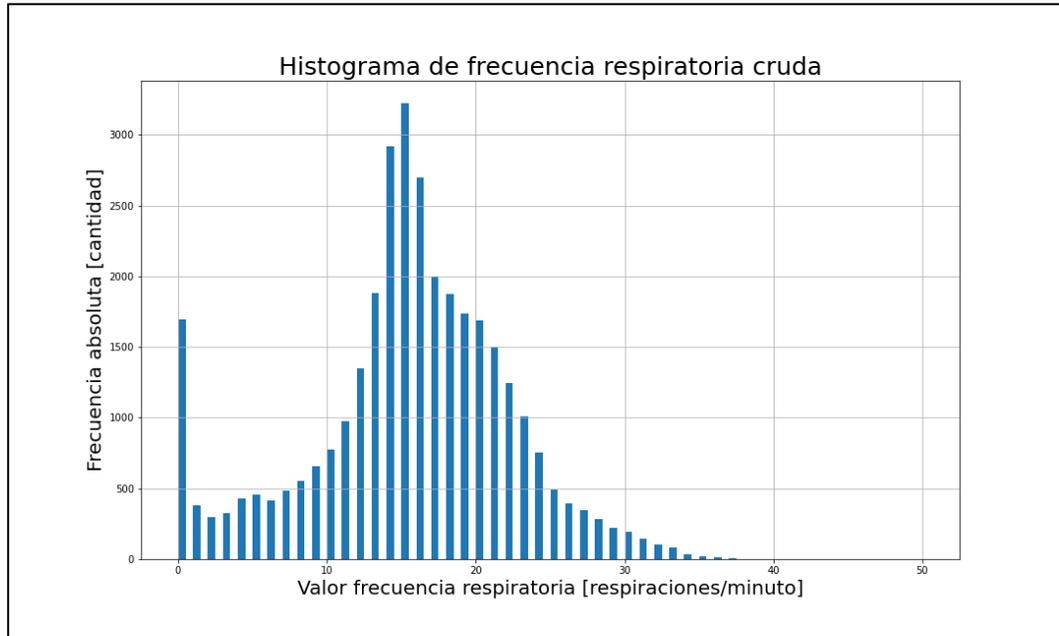


Figura 7-29: Histograma frecuencia respiratoria de entrenamiento persona número 8.

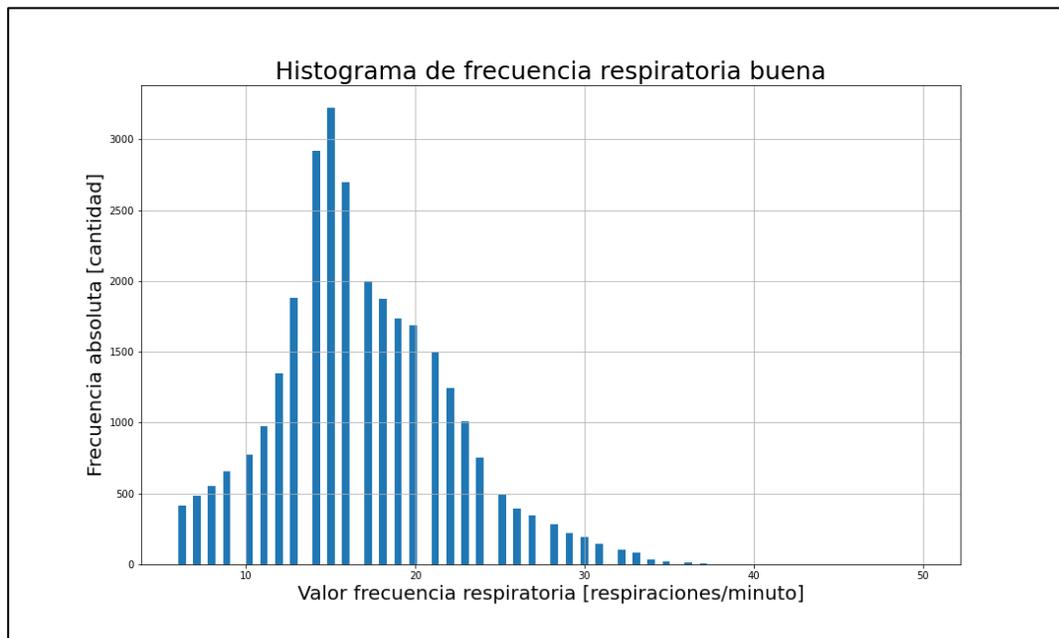


Figura 7-30: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 8.

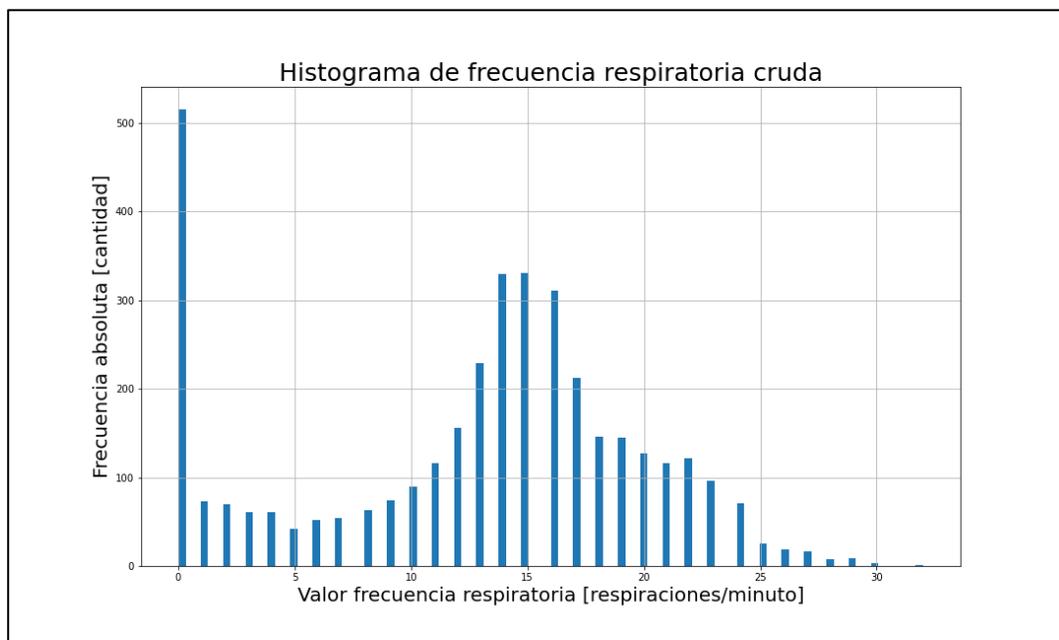


Figura 7-31: Histograma frecuencia respiratoria de validación persona número 8.

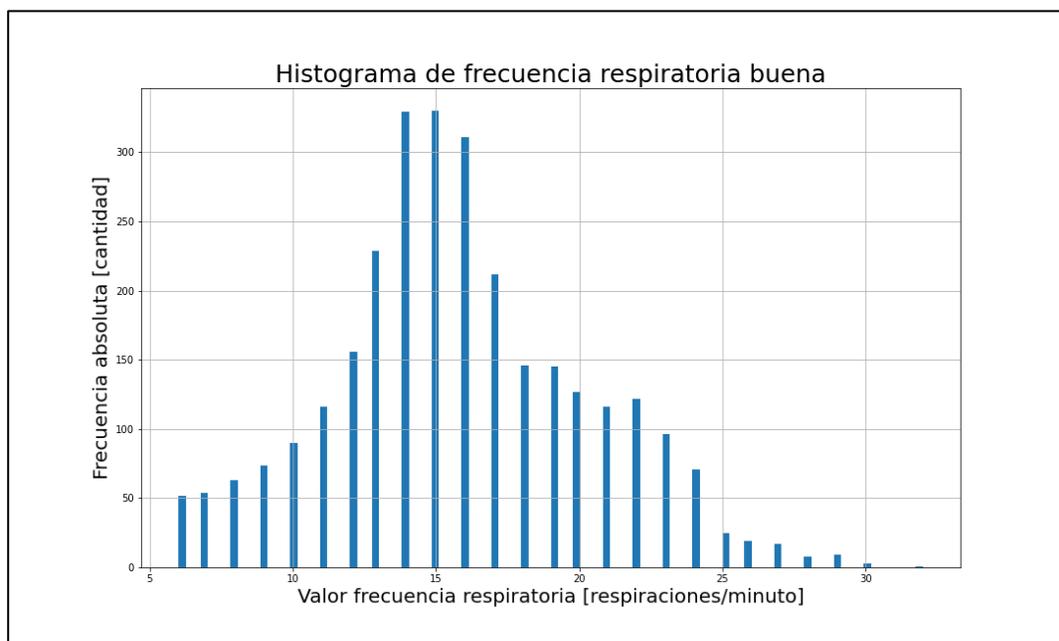


Figura 7-32: Histograma pre procesado frecuencia respiratoria de validación persona número 8.

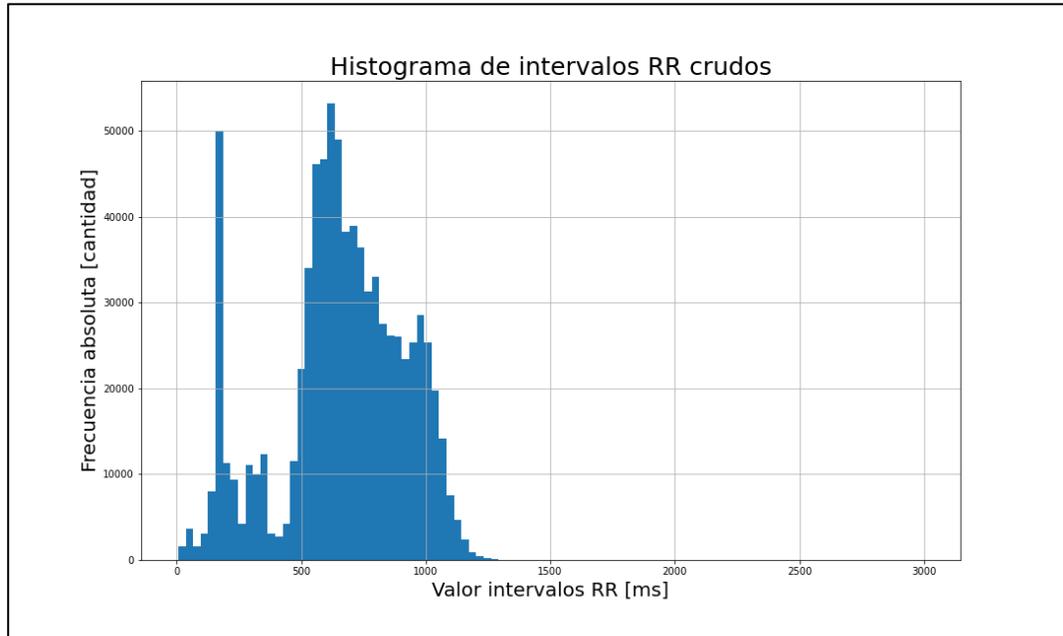


Figura 7-33: Histograma intervalos RR de entrenamiento persona número 9.

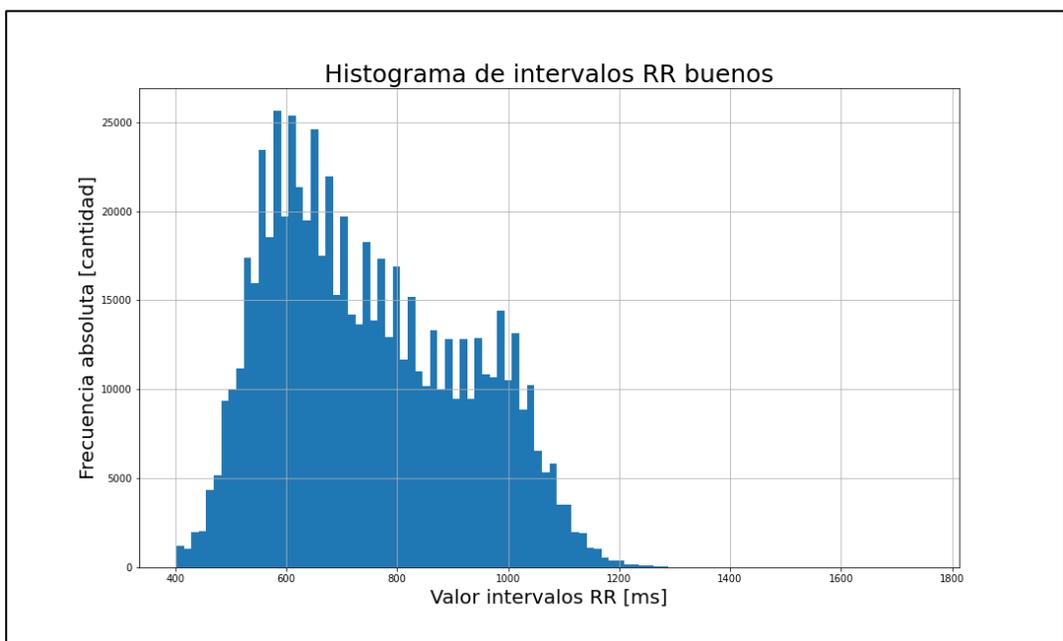


Figura 7-34: Histograma pre procesado intervalos RR de entrenamiento persona número 9.

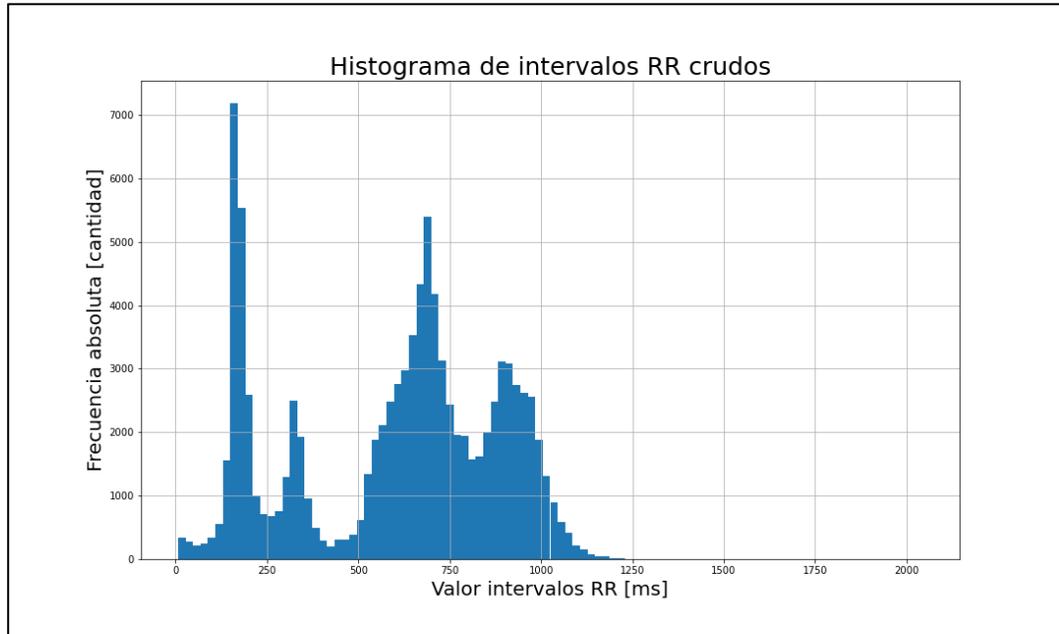


Figura 7-35: Histograma intervalos RR de validación persona número 9.

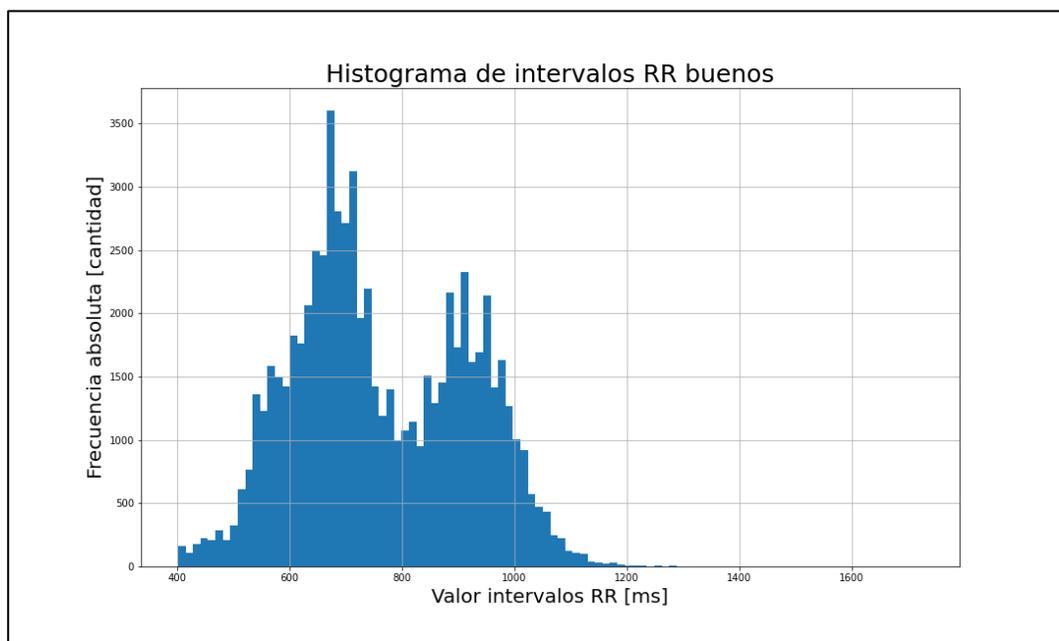


Figura 7-36: Histograma pre procesado intervalos RR de validación persona número 9.

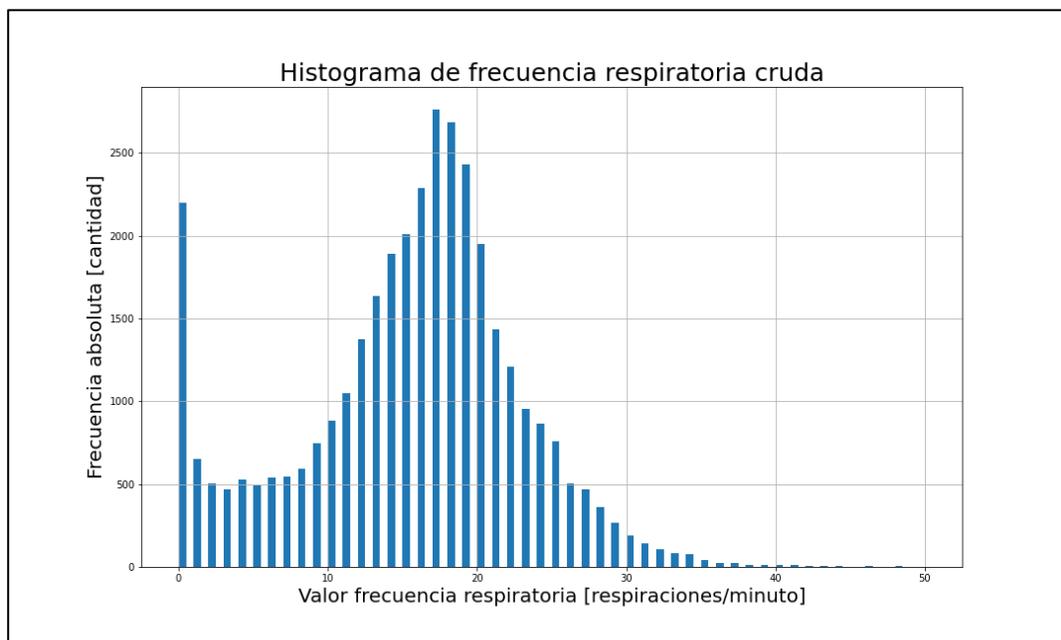


Figura 7-37: Histograma frecuencia respiratoria de entrenamiento persona número 9.

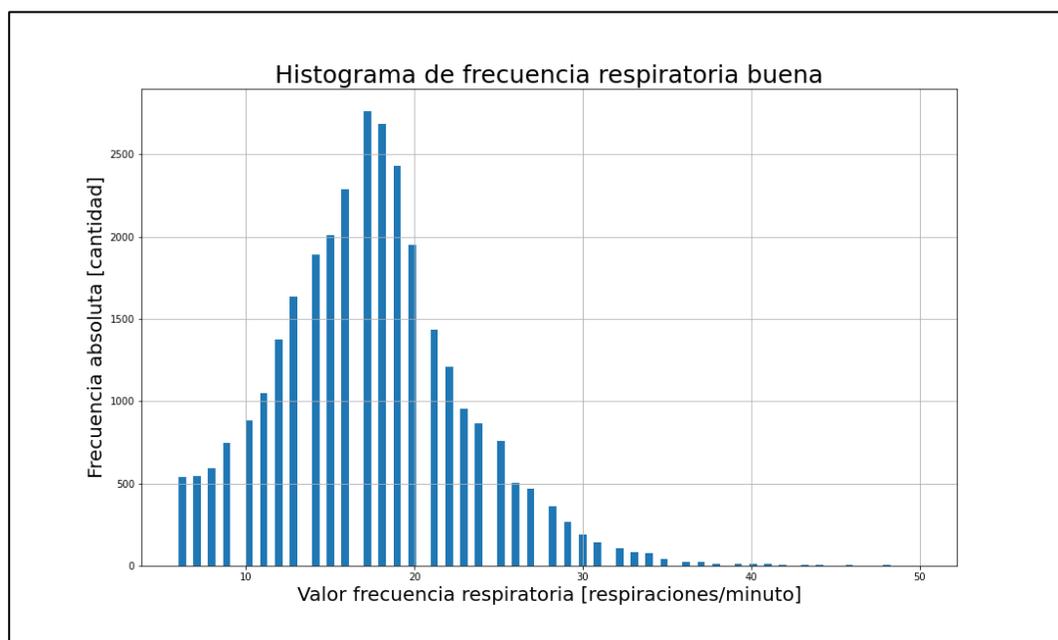


Figura 7-38: Histograma pre procesado frecuencia respiratoria de entrenamiento persona número 9.

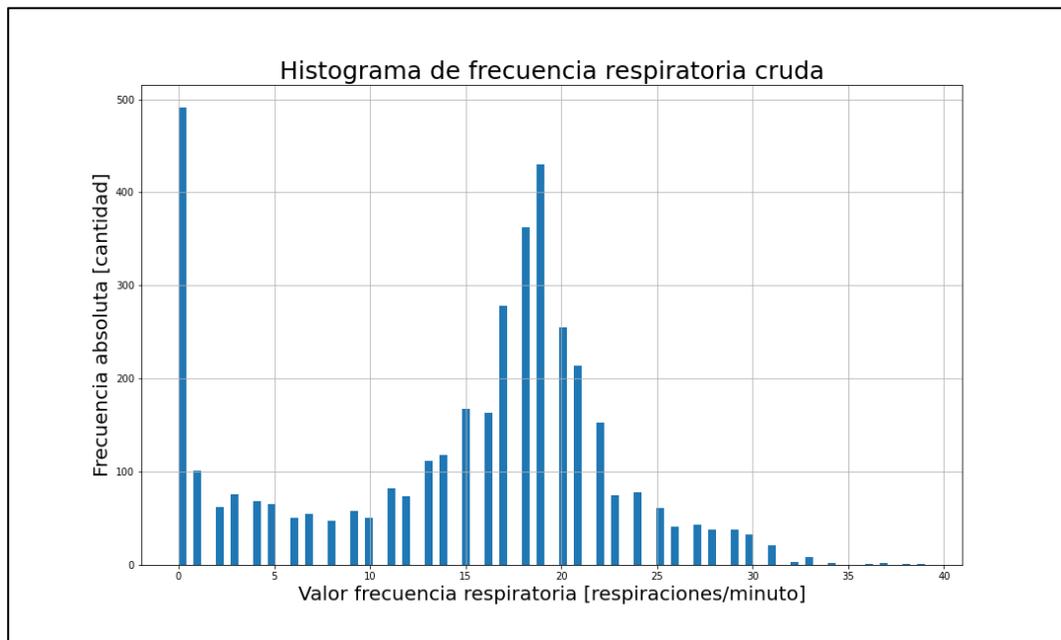


Figura 7-39: Histograma frecuencia respiratoria de validación persona número 9.

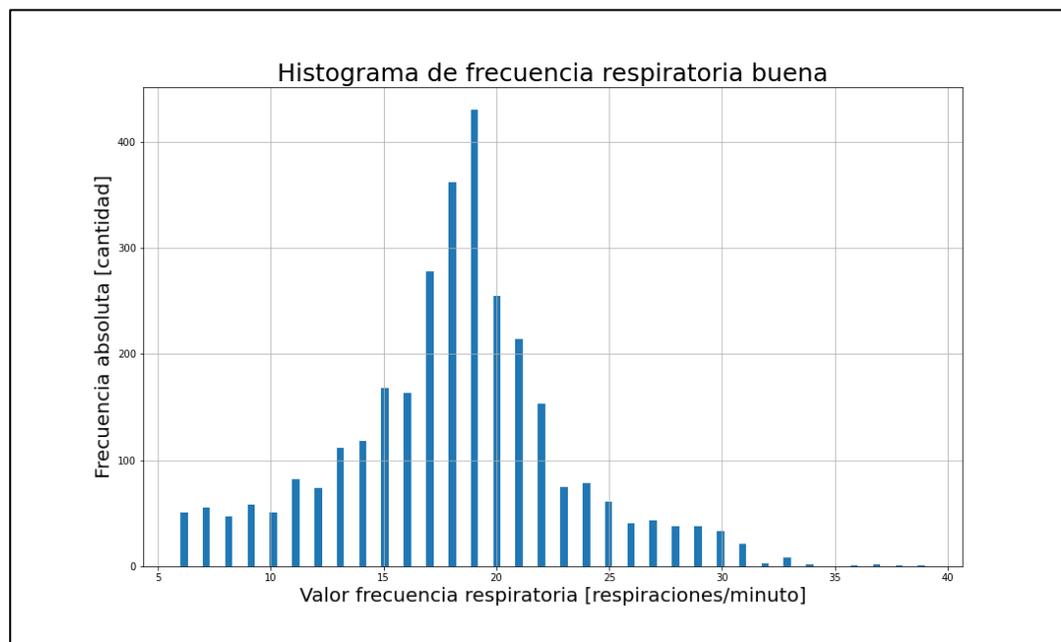


Figura 7-40: Histograma pre procesado frecuencia respiratoria de validación persona número 9.

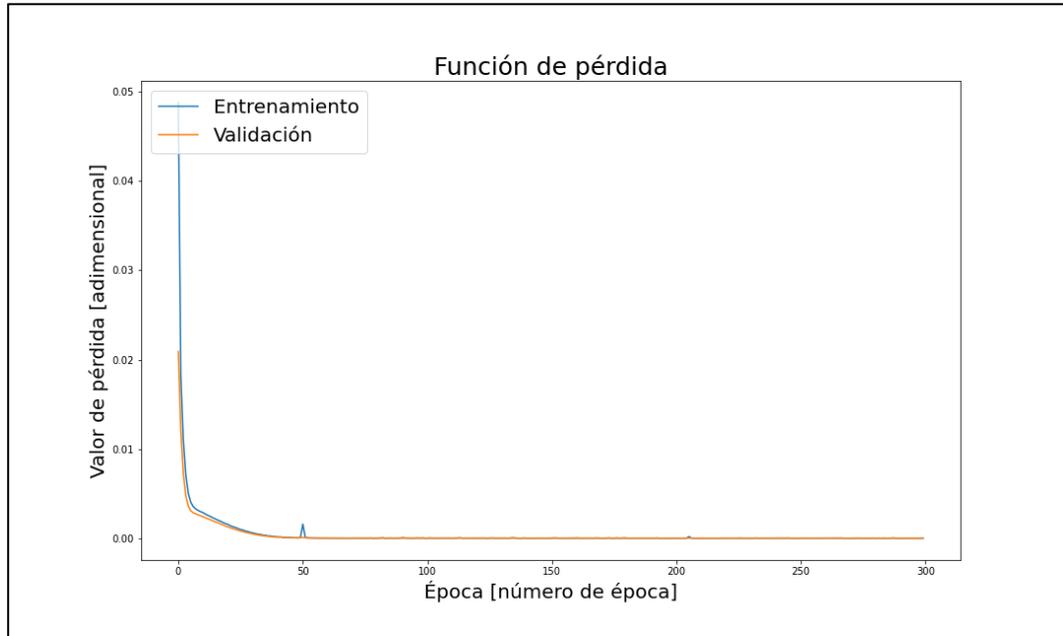


Figura 7-41: Valores función de pérdida persona número 3.

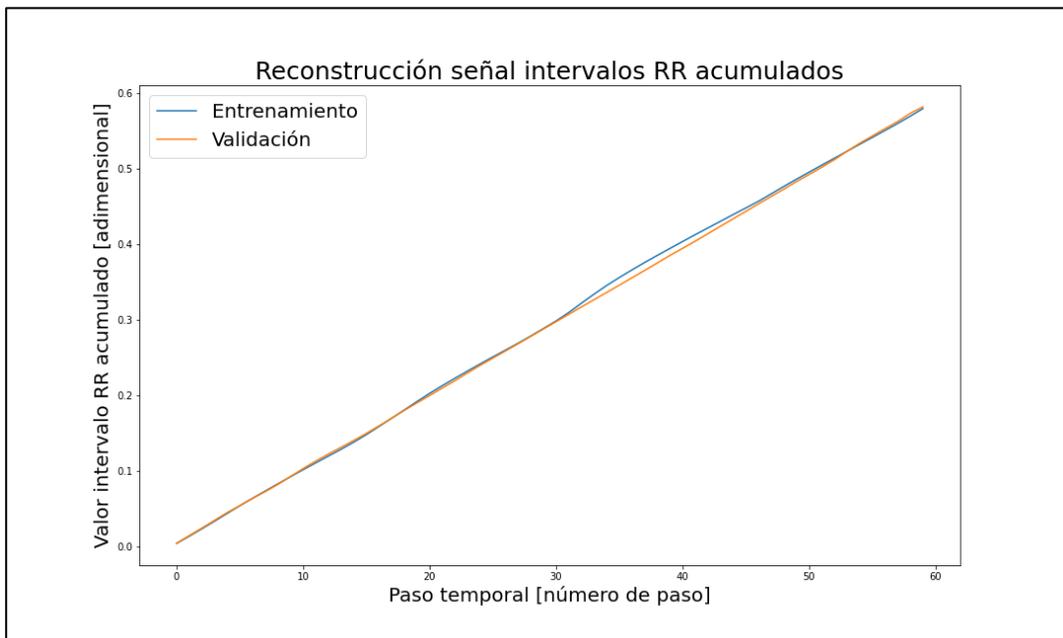


Figura 7-42: Reconstrucción intervalos RR acumulada normalizada persona 3.

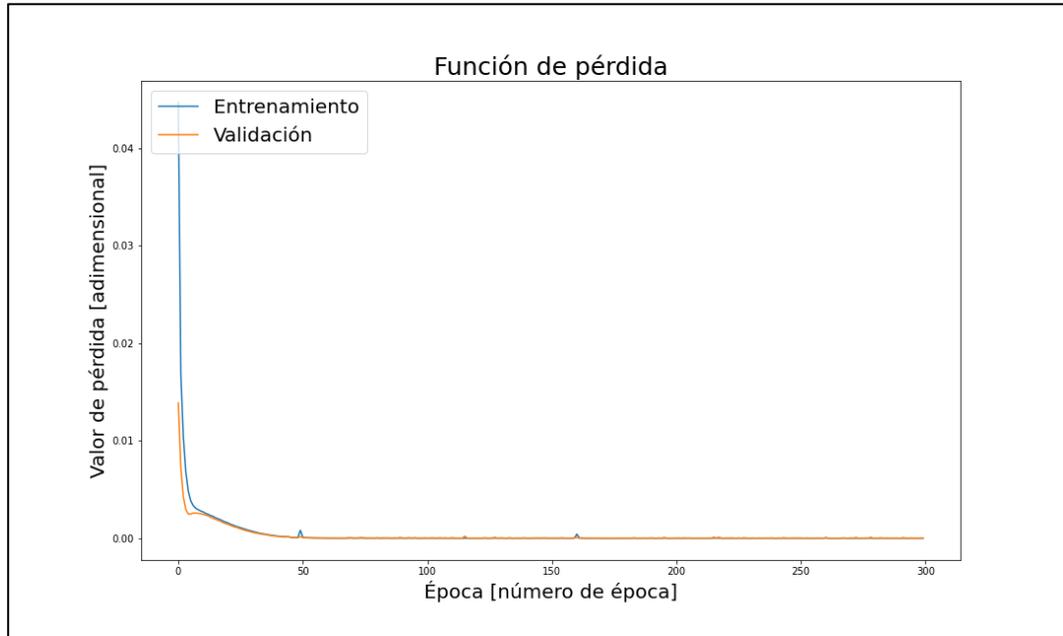


Figura 7-43: Valores función de pérdida persona número 5.

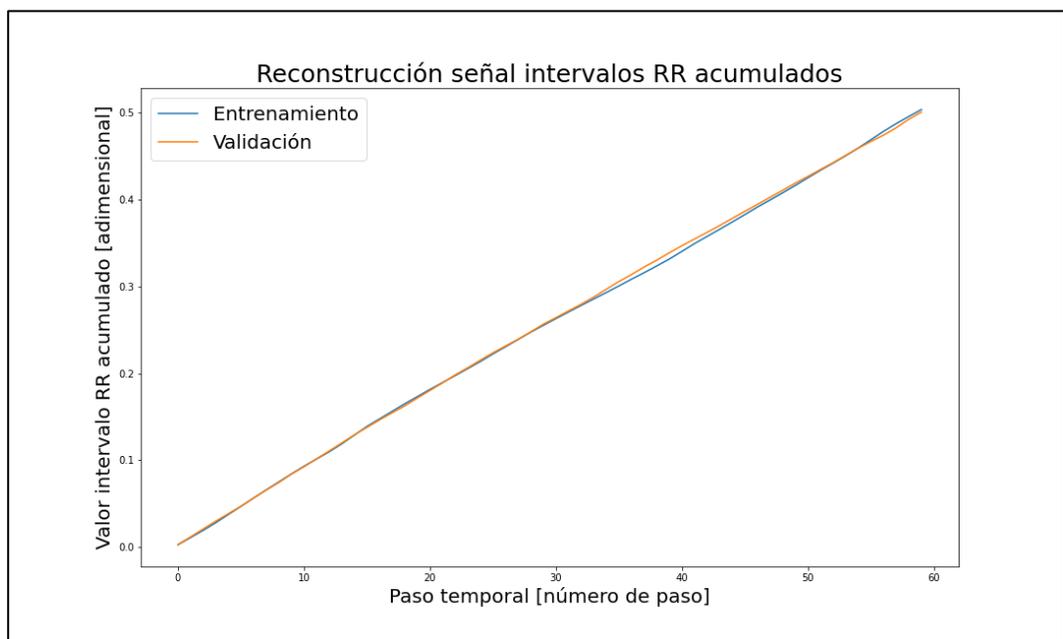


Figura 7-44: Reconstrucción intervalos RR acumulada normalizada persona 5.

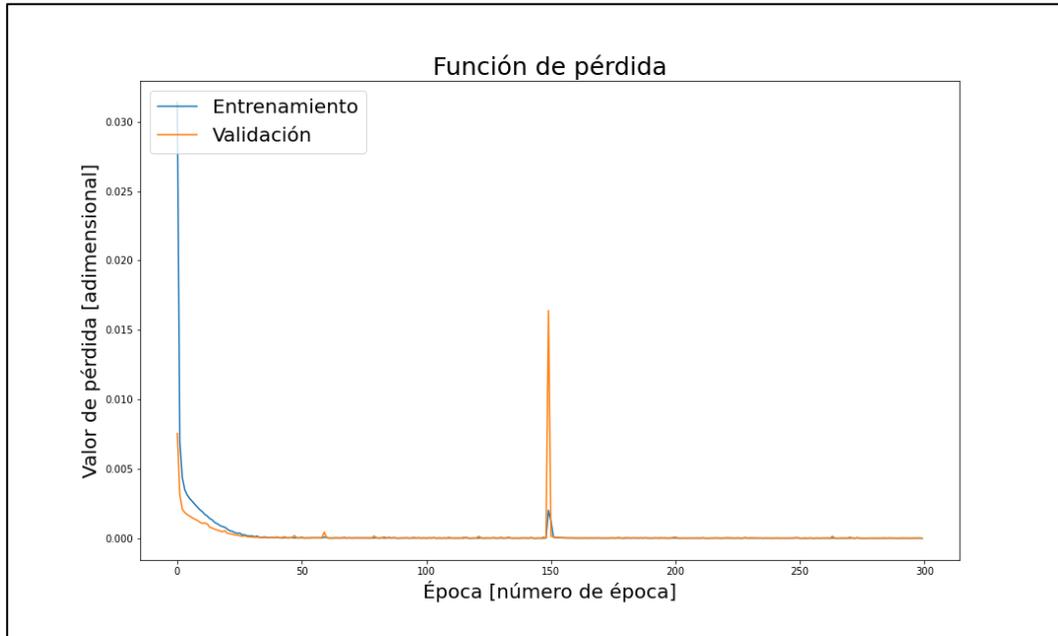


Figura 7-45: Valores función de pérdida persona número 7.

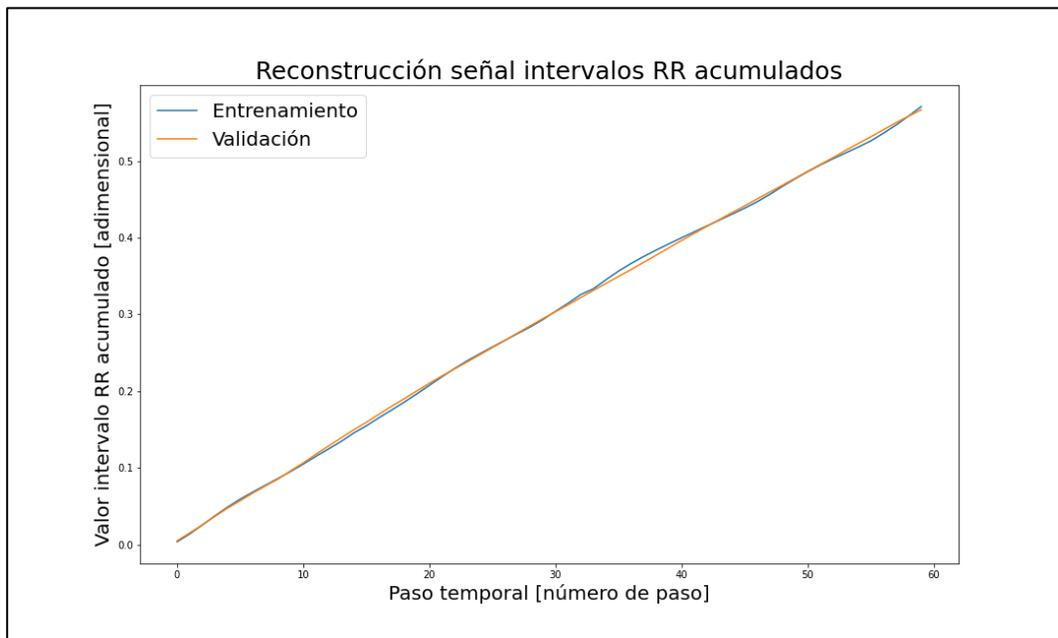


Figura 7-46: Reconstrucción intervalos RR acumulada normalizada persona 7.

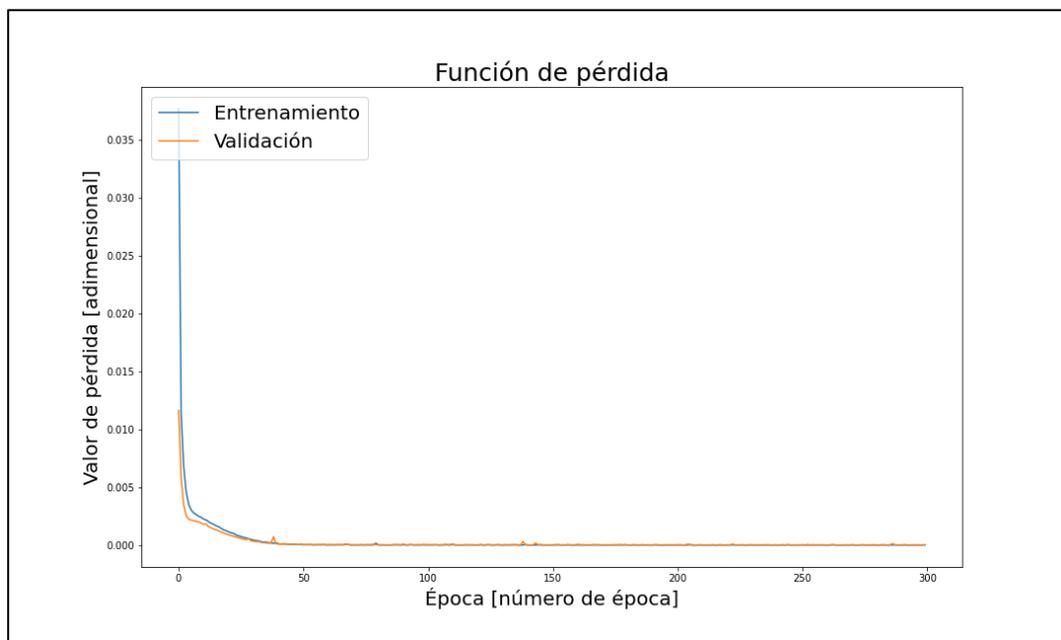


Figura 7-47: Valores función de pérdida persona número 8.

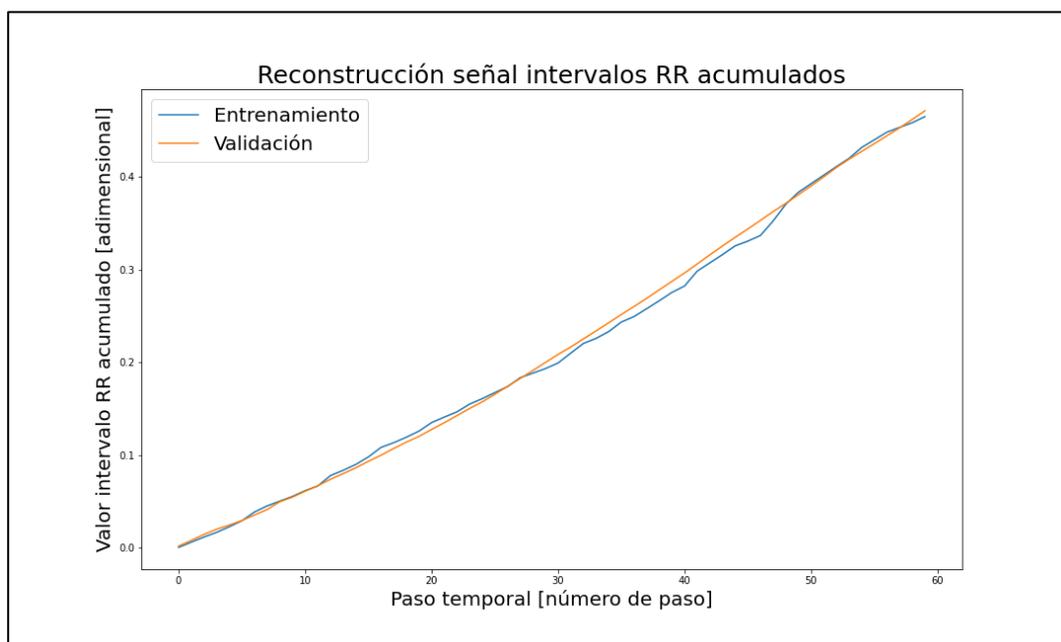


Figura 7-48: Reconstrucción intervalos RR acumulada normalizada persona 8.

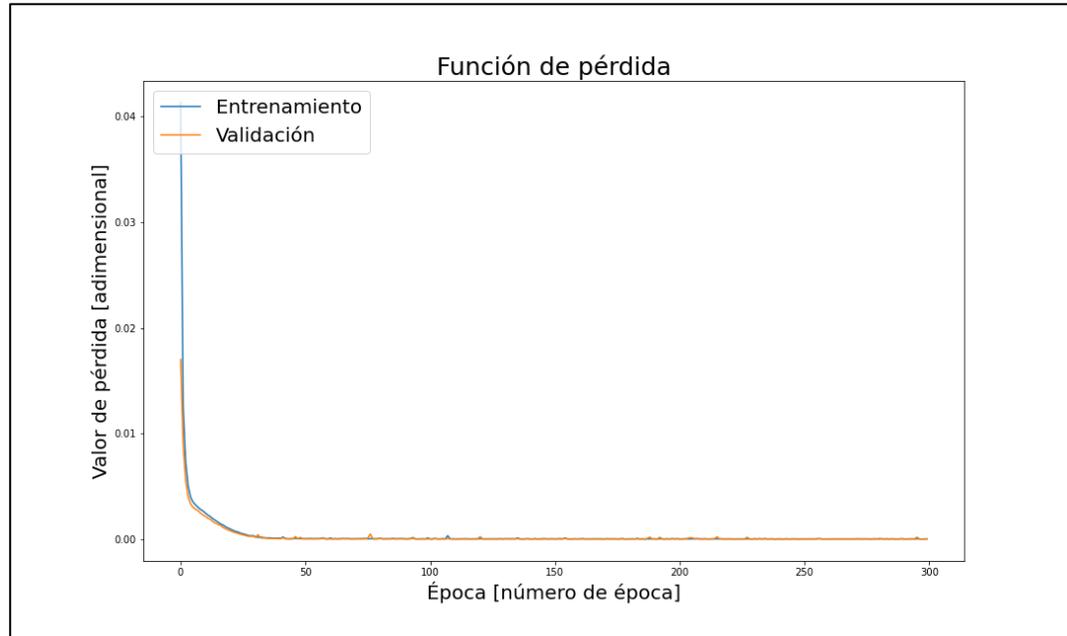


Figura 7-49: Valores función de pérdida persona número 9.

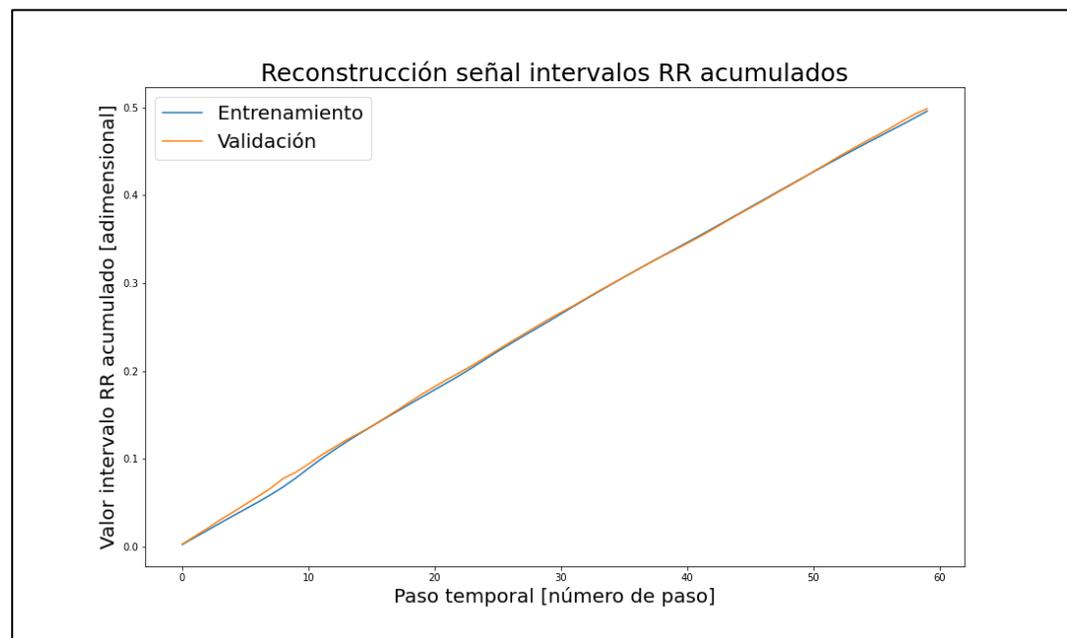


Figura 7-50: Reconstrucción intervalos RR acumulada normalizada persona 9.

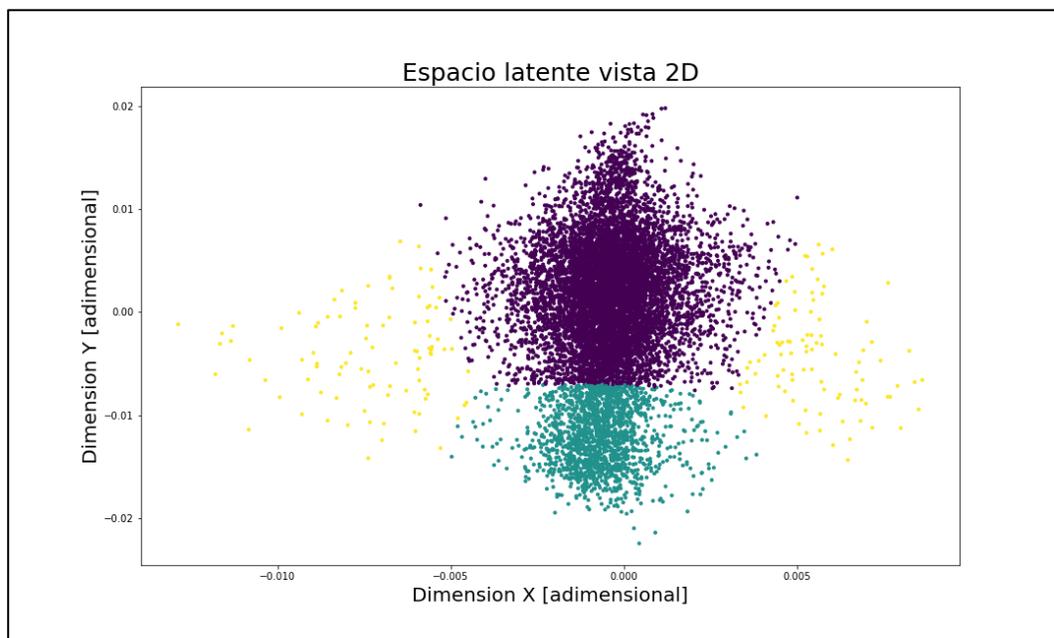


Figura 7-51: Espacio latente vista 2D persona número 3.

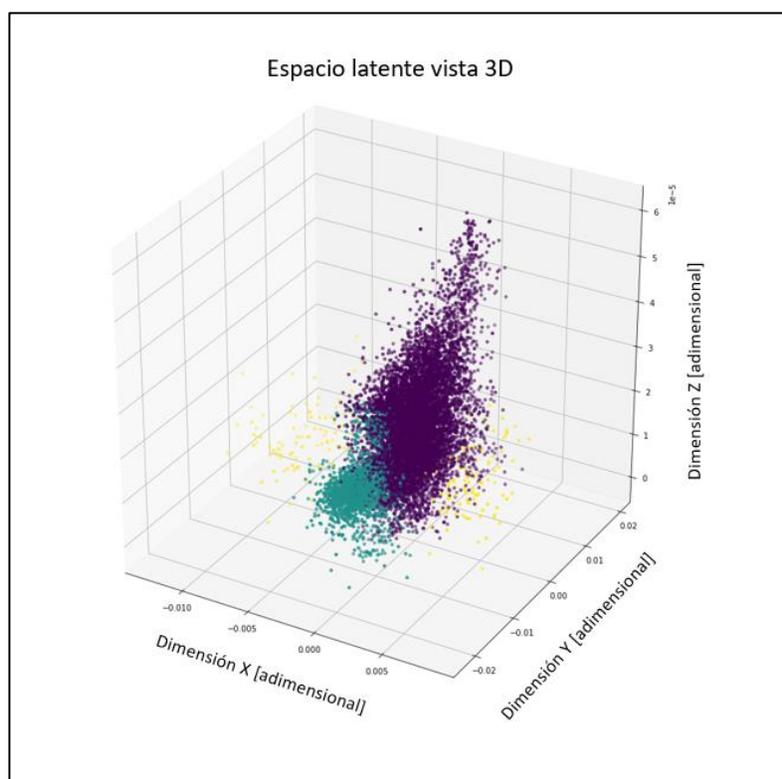


Figura 7-52: Espacio latente vista 3D persona número 3.

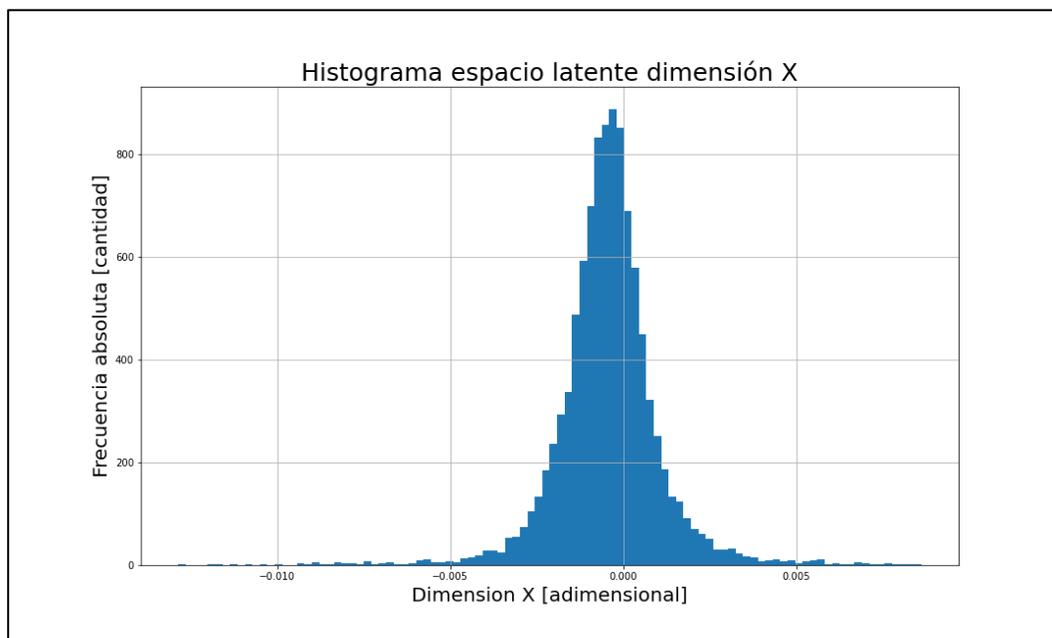


Figura 7-53: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 3.

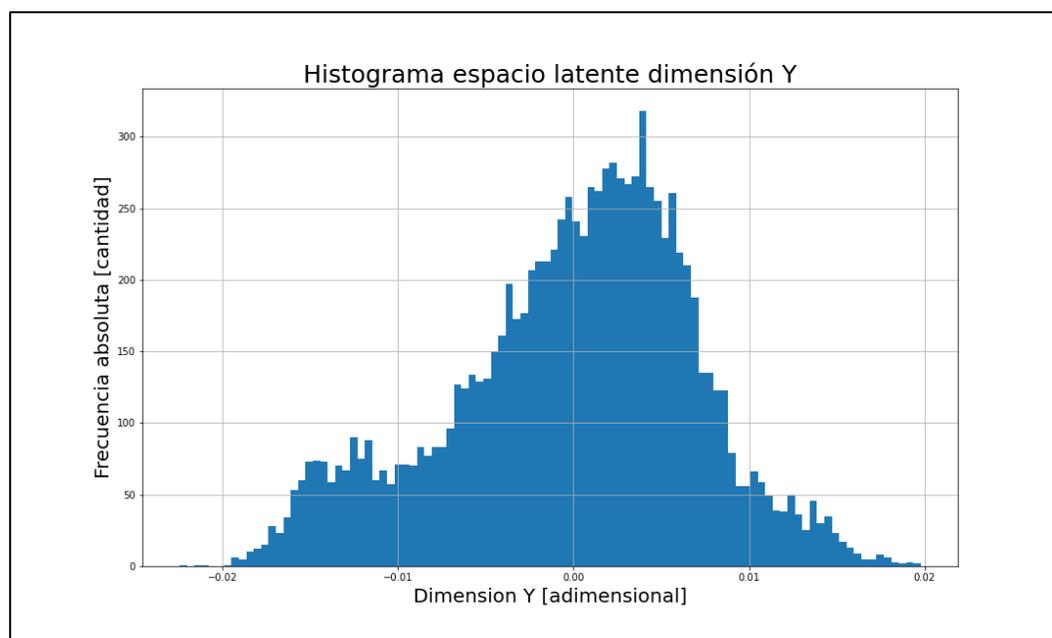


Figura 7-54: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 3.

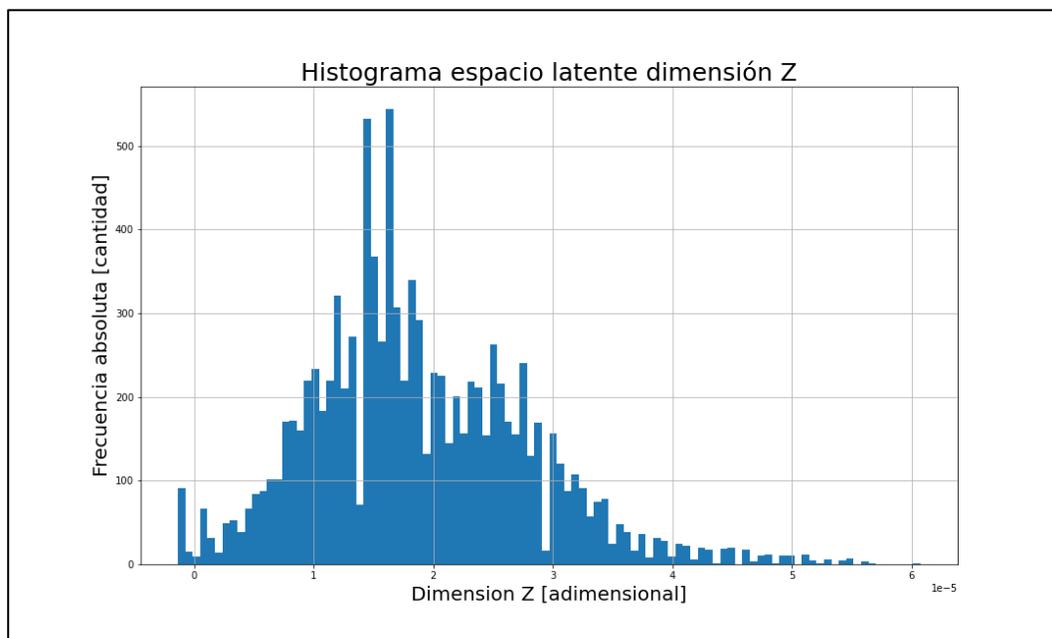


Figura 7-55: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 3.

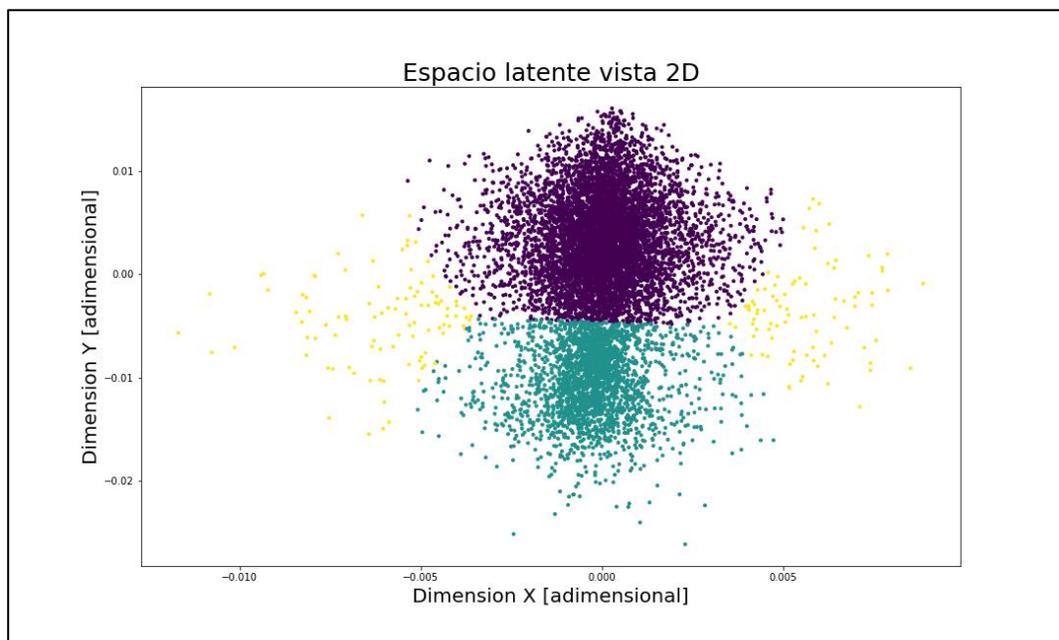


Figura 7-56: Espacio latente vista 2D persona número 5.

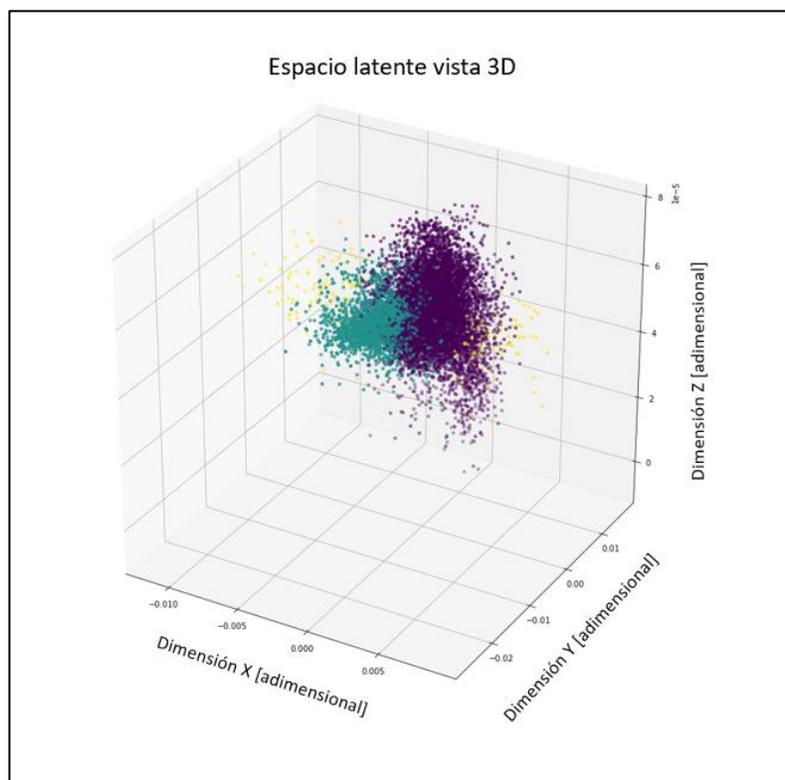


Figura 7-57: Espacio latente vista 3D persona número 5.

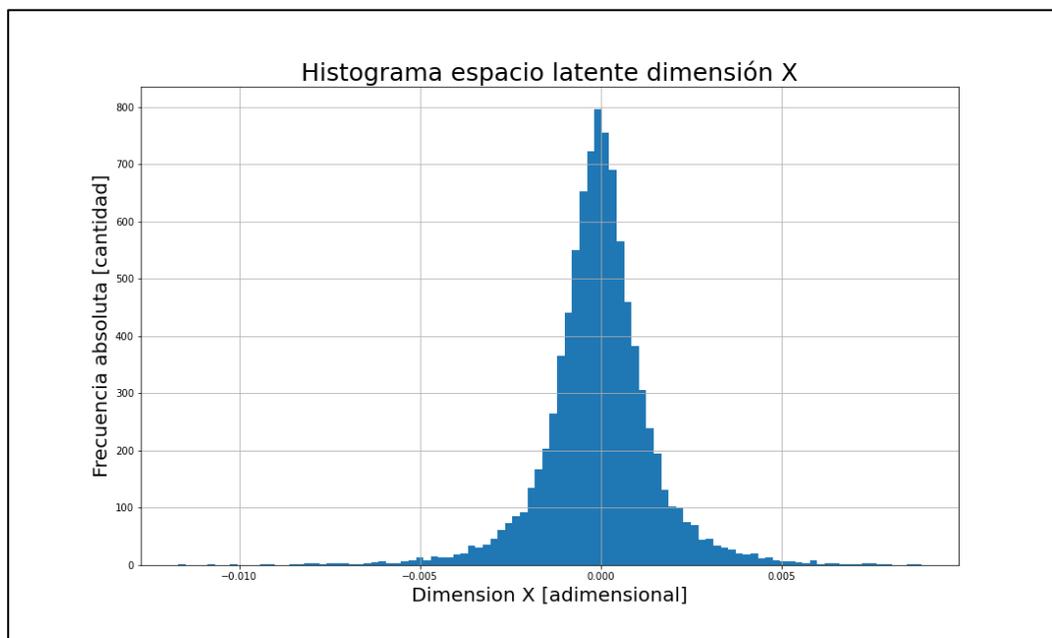


Figura 7-58: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 5.

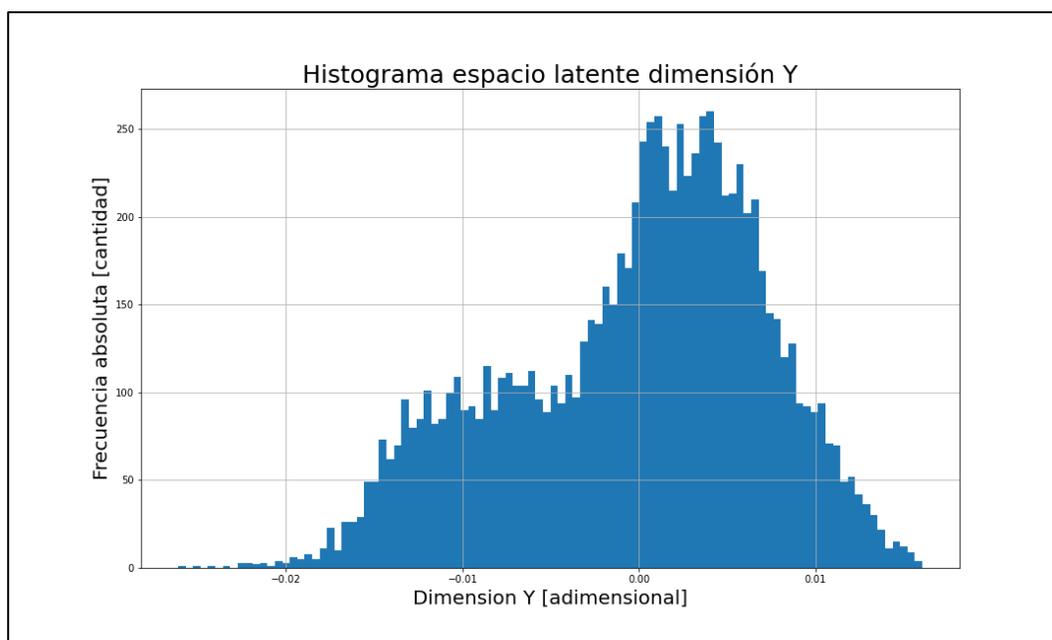


Figura 7-59: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 5.

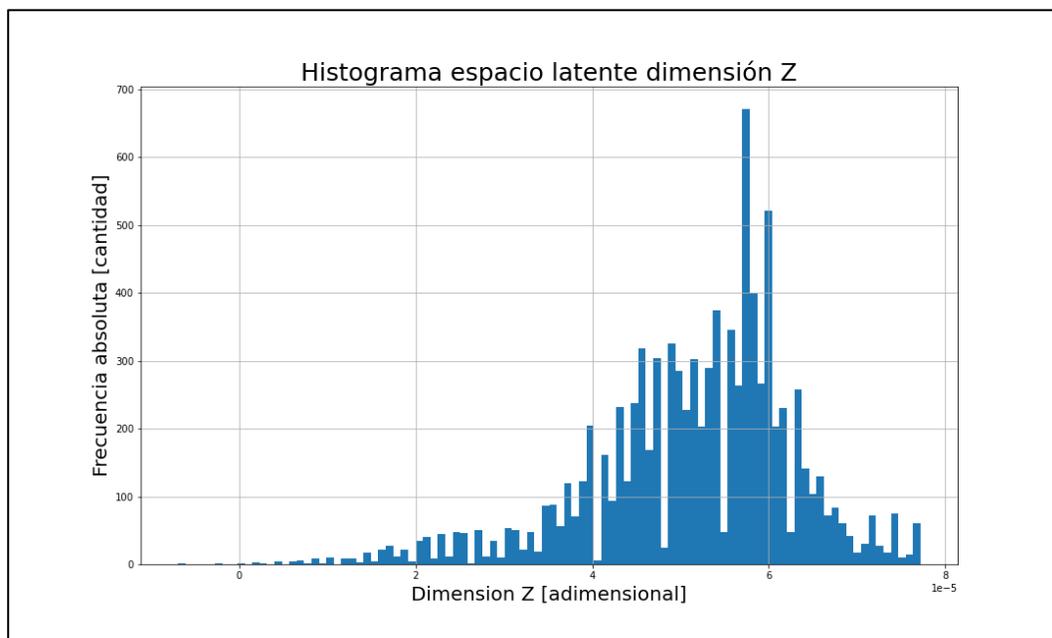


Figura 7-60: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 5.

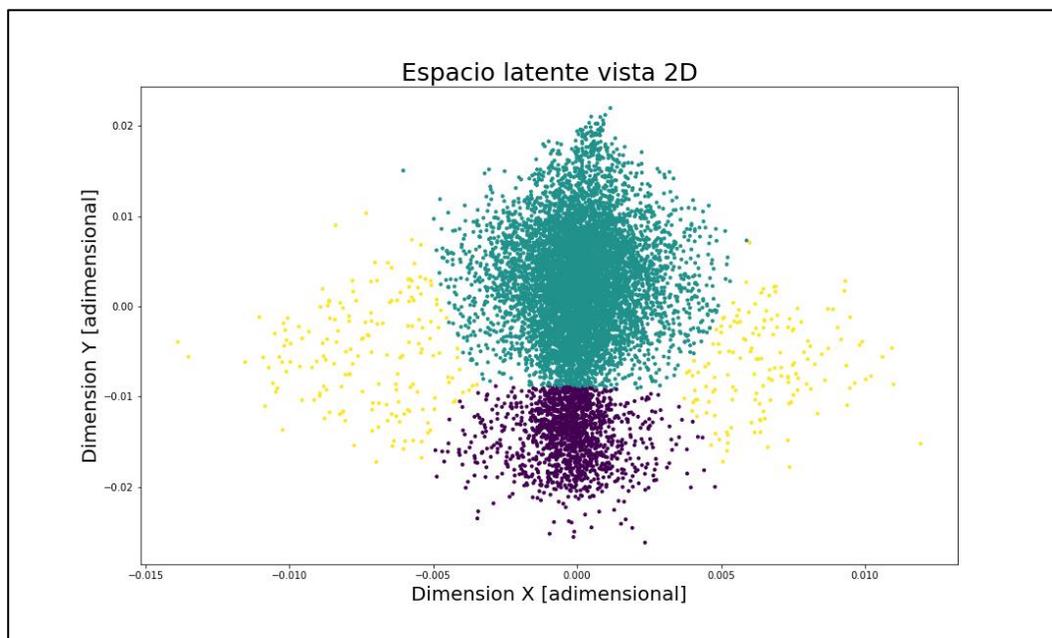


Figura 7-61: Espacio latente vista 2D persona número 7.

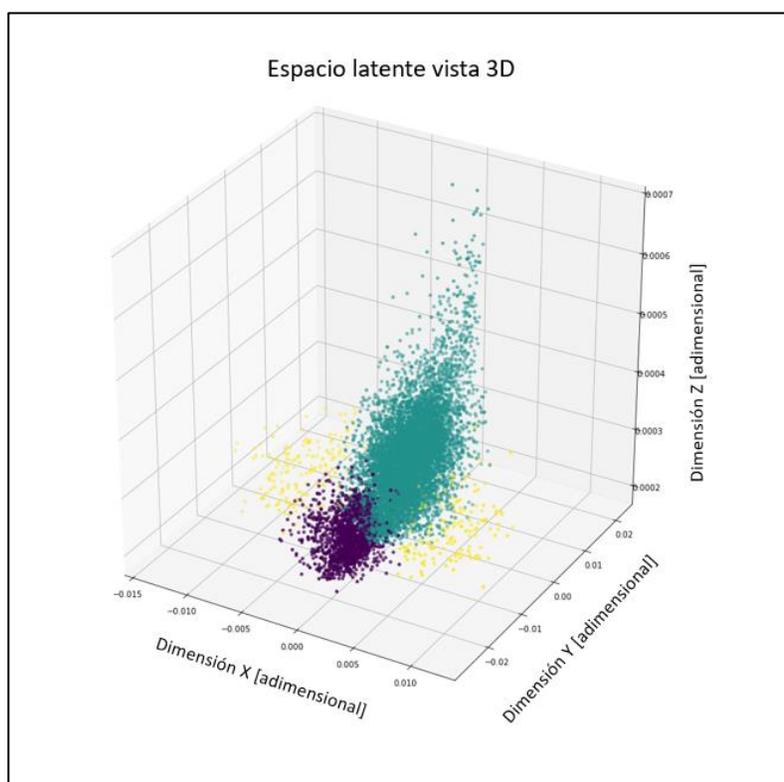


Figura 7-62: Espacio latente vista 3D persona número 7.

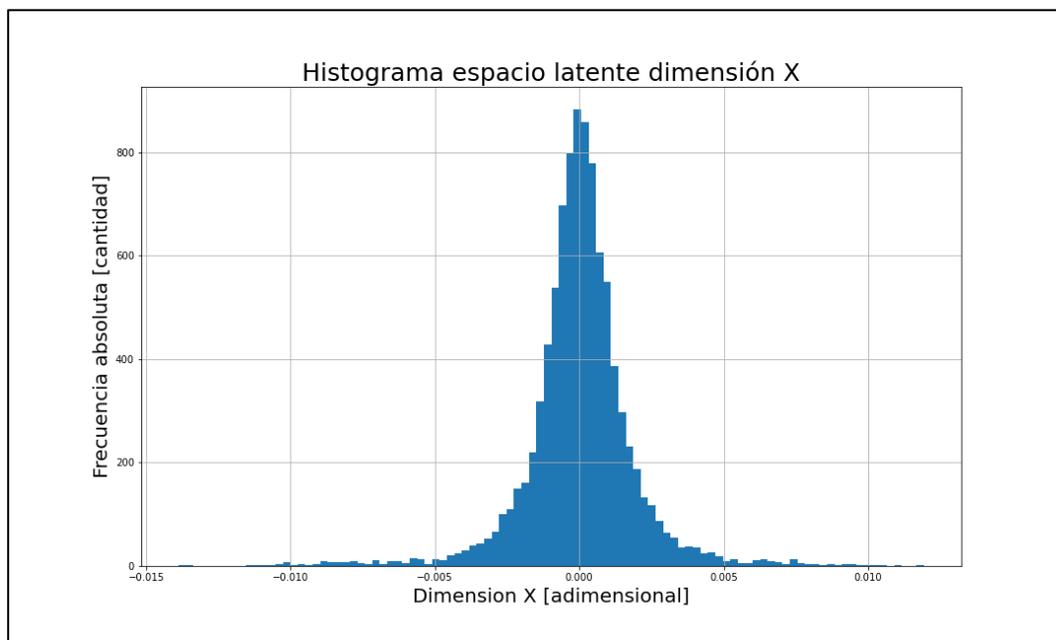


Figura 7-63: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 7.

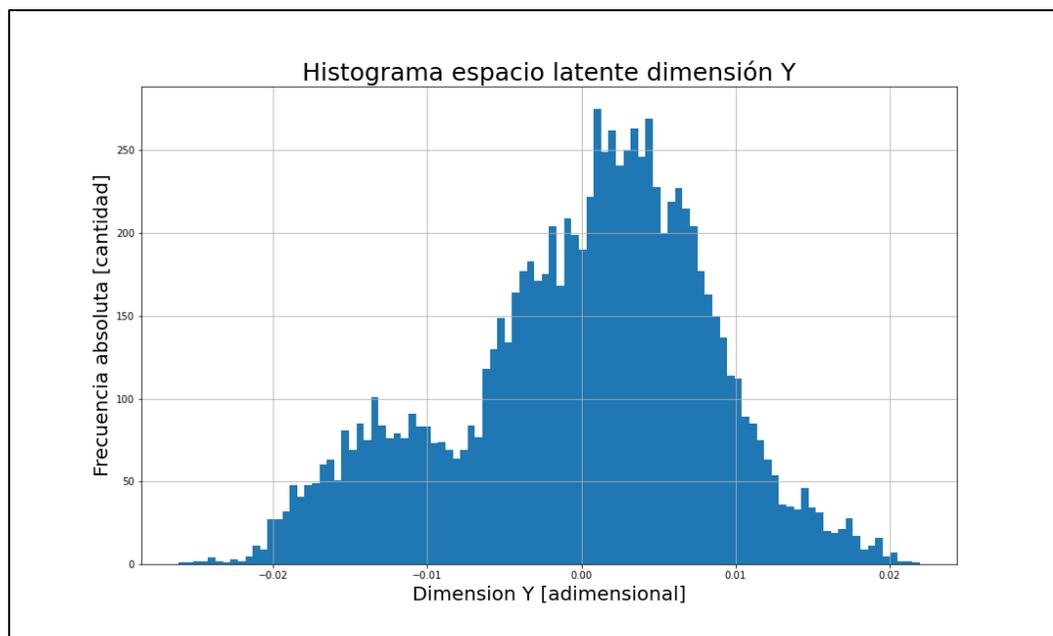


Figura 7-64: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 7.

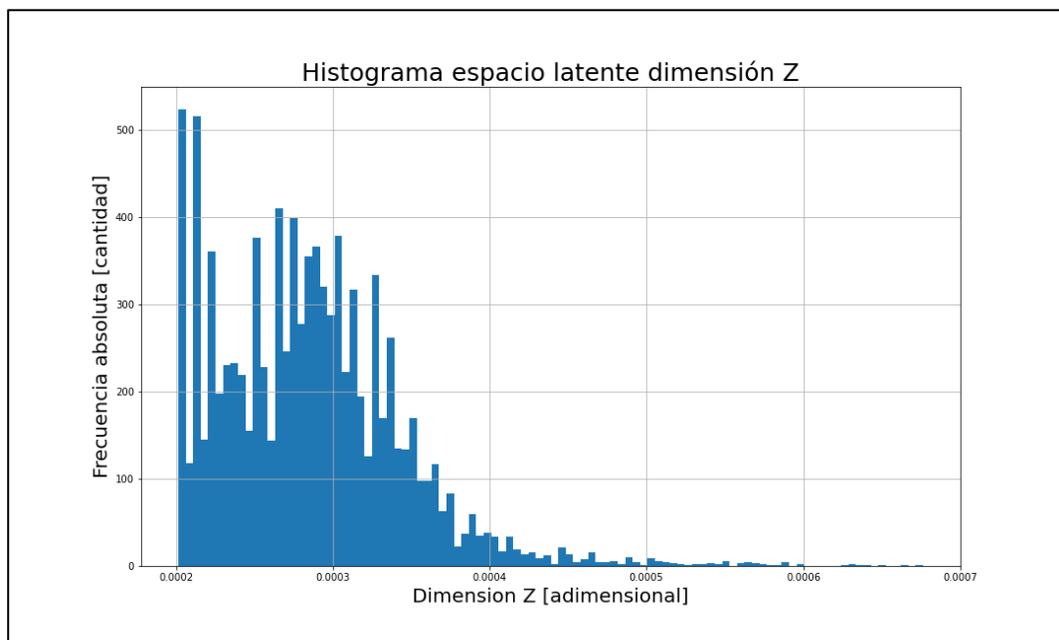


Figura 7-65: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 7.

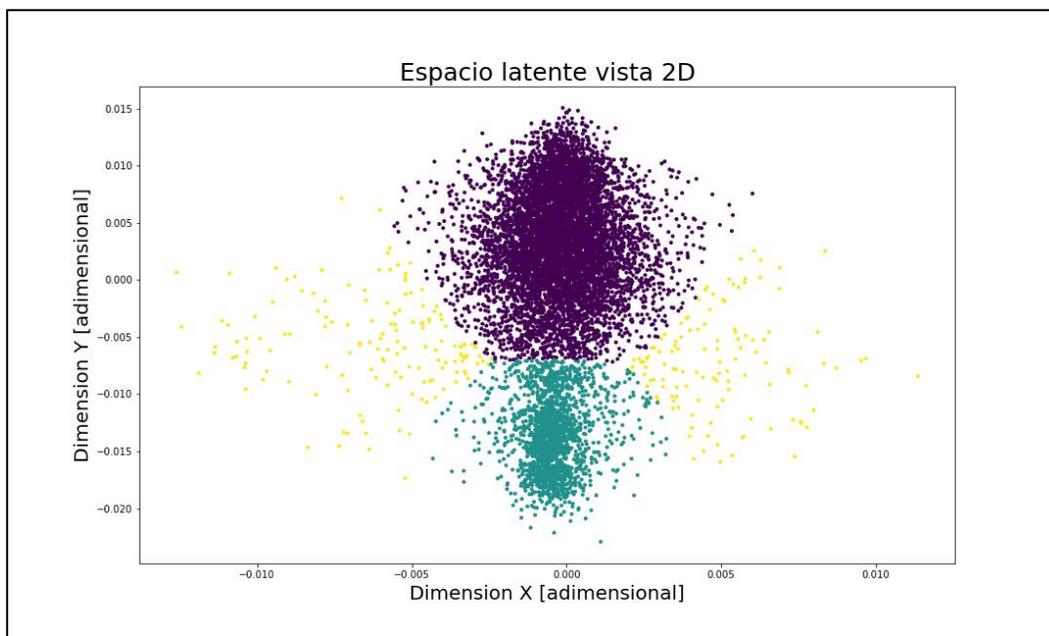


Figura 7-66: Espacio latente vista 2D persona número 8.

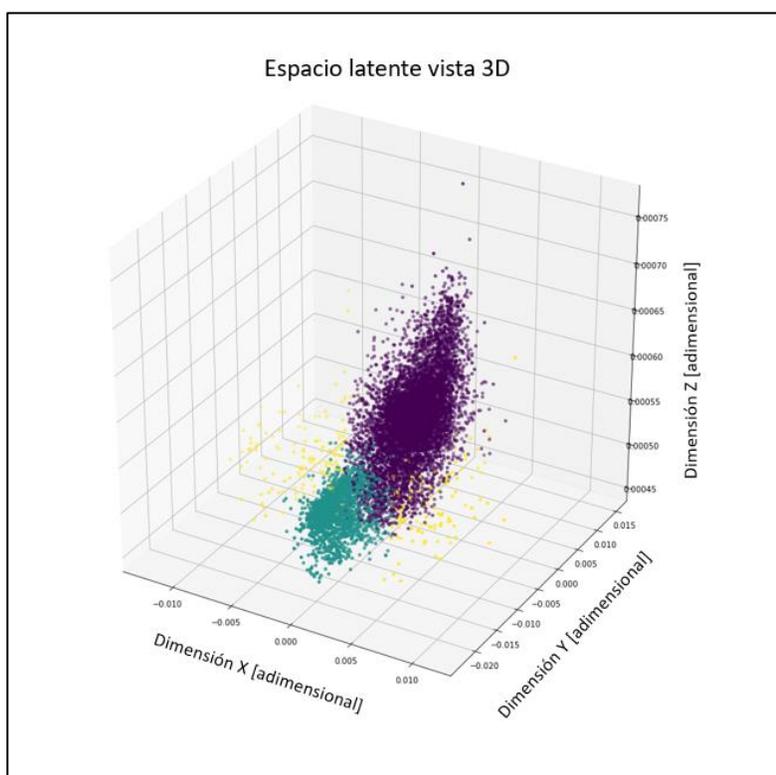


Figura 7-67: Espacio latente vista 3D persona número 8.

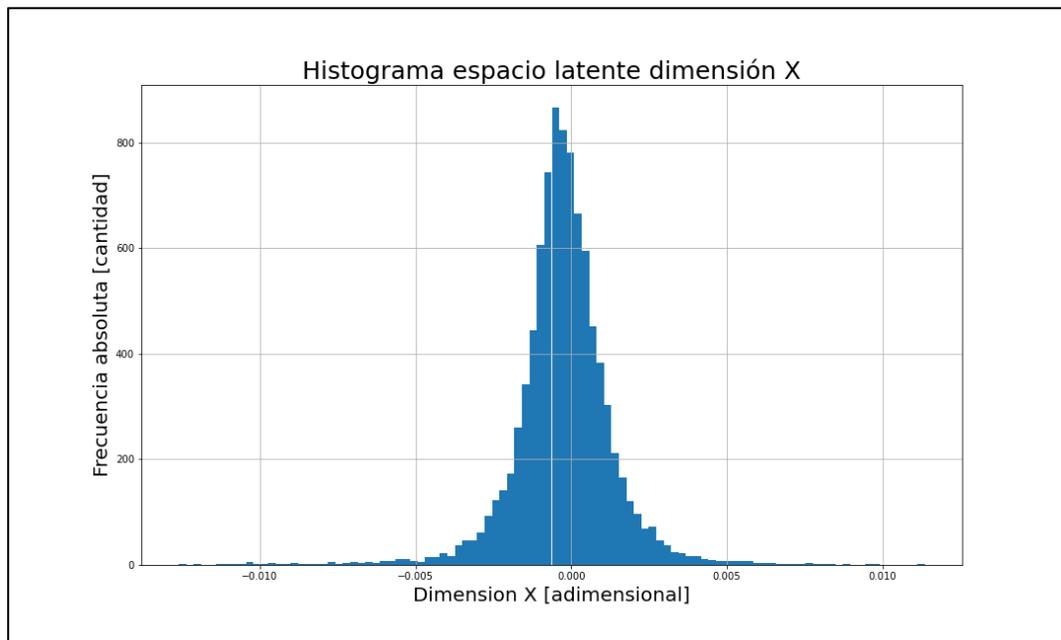


Figura 7-68: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 8.

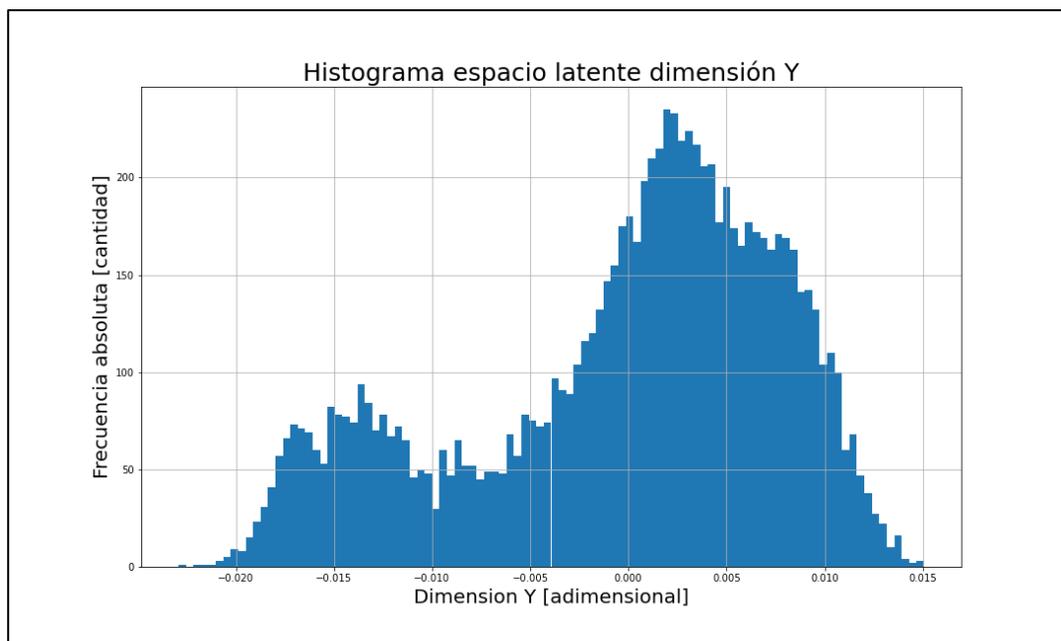


Figura 7-69: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 8.

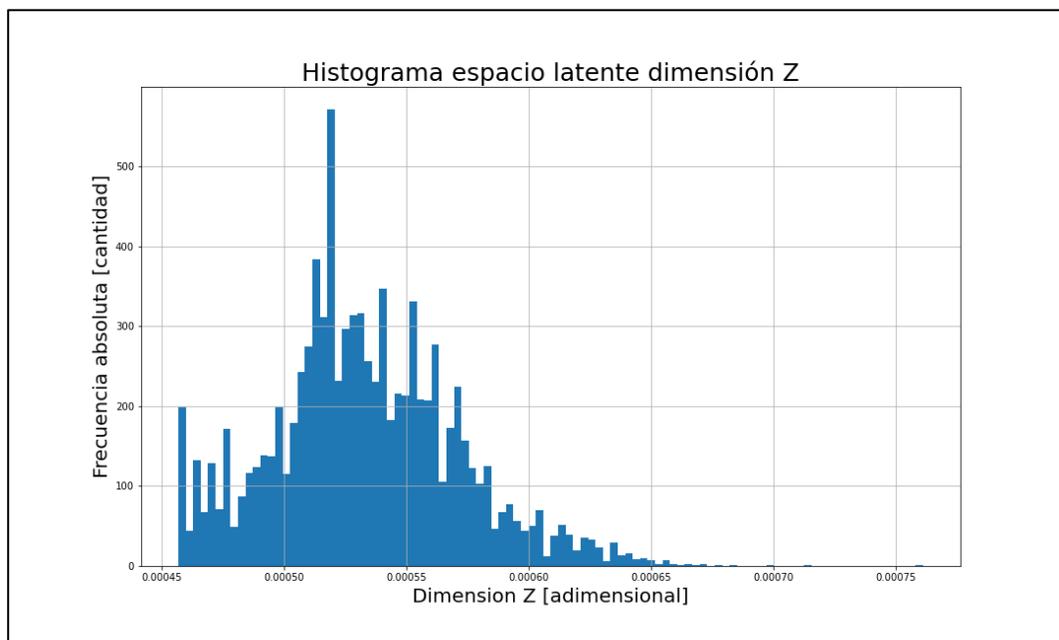


Figura 7-70: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 8.

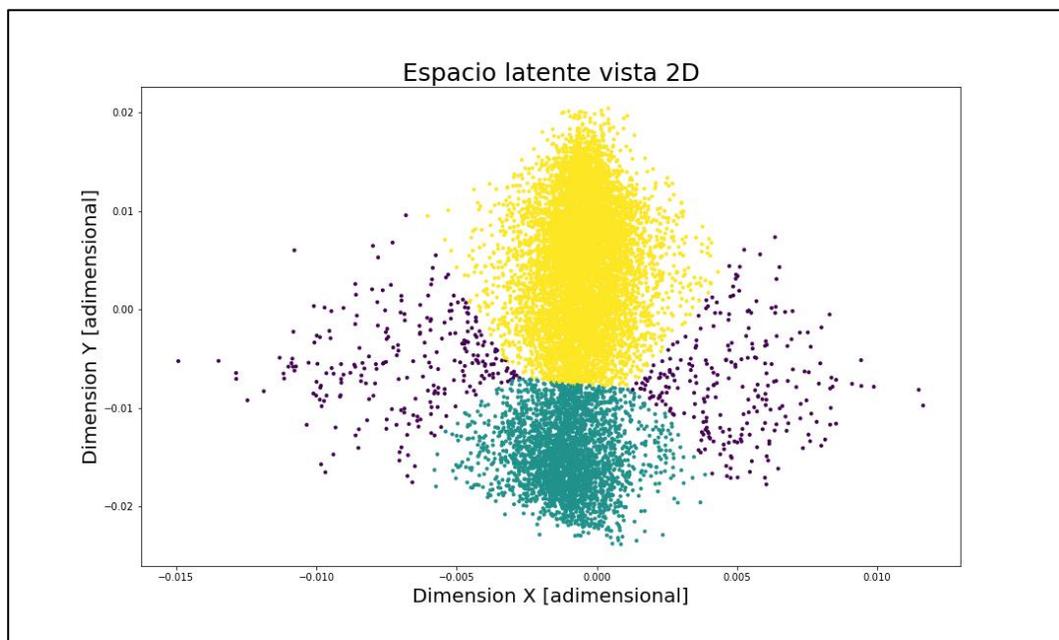


Figura 7-71: Espacio latente vista 2D persona número 9.

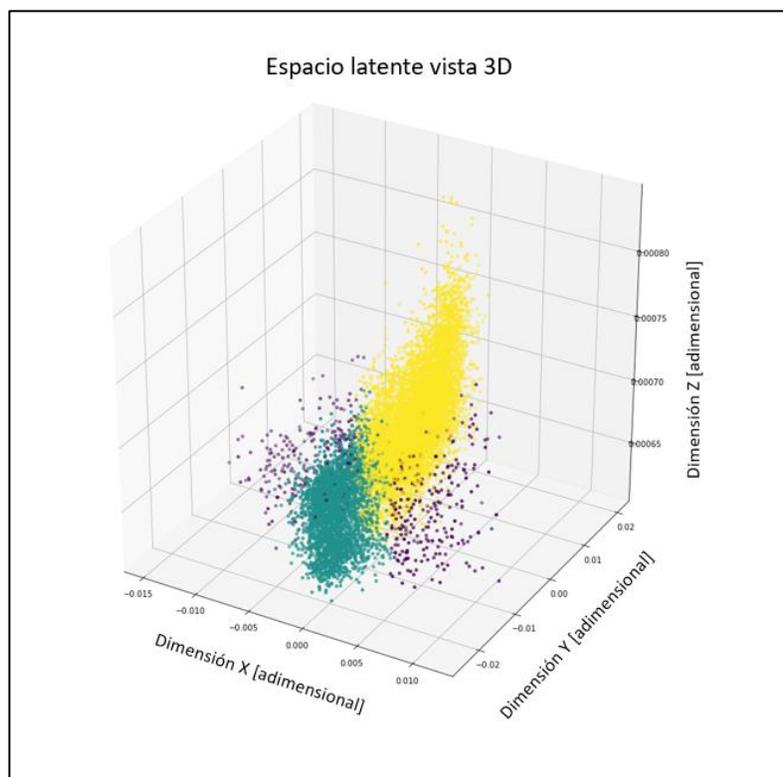


Figura 7-72: Espacio latente vista 3D persona número 9.

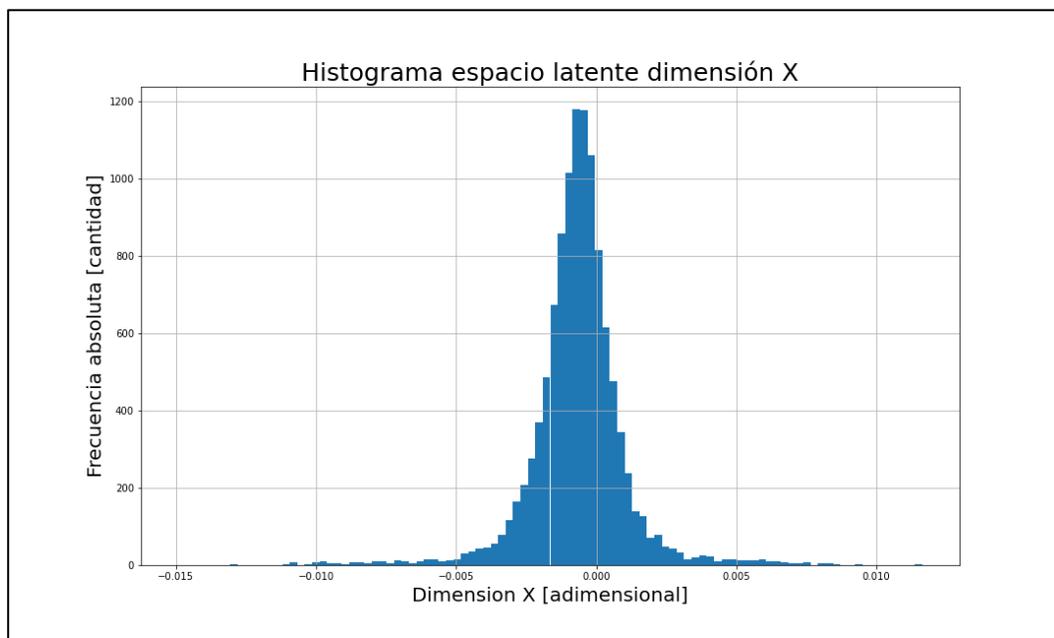


Figura 7-73: Histograma de la distribución formada en la dimensión X del espacio latente de la persona número 9.

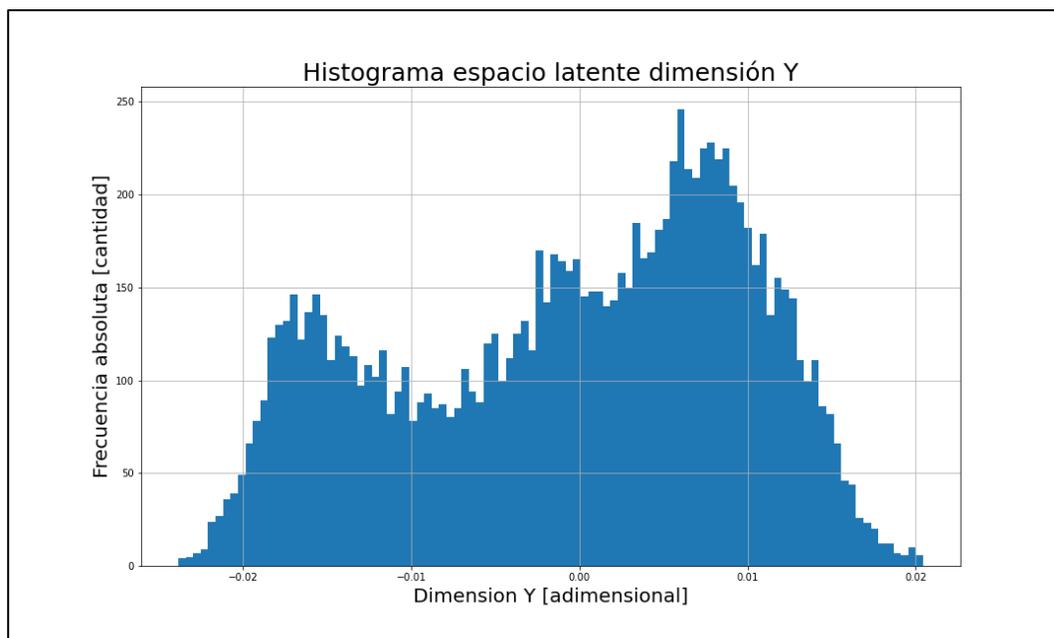


Figura 7-74: Histograma de la distribución formada en la dimensión Y del espacio latente de la persona número 9.

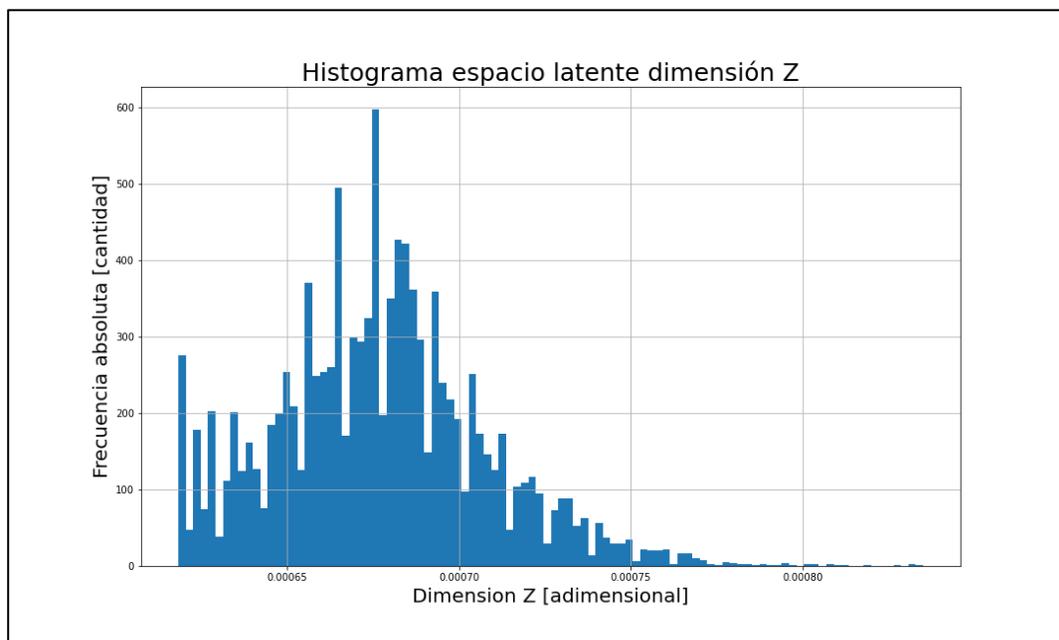


Figura 7-75: Histograma de la distribución formada en la dimensión Z del espacio latente de la persona número 9.

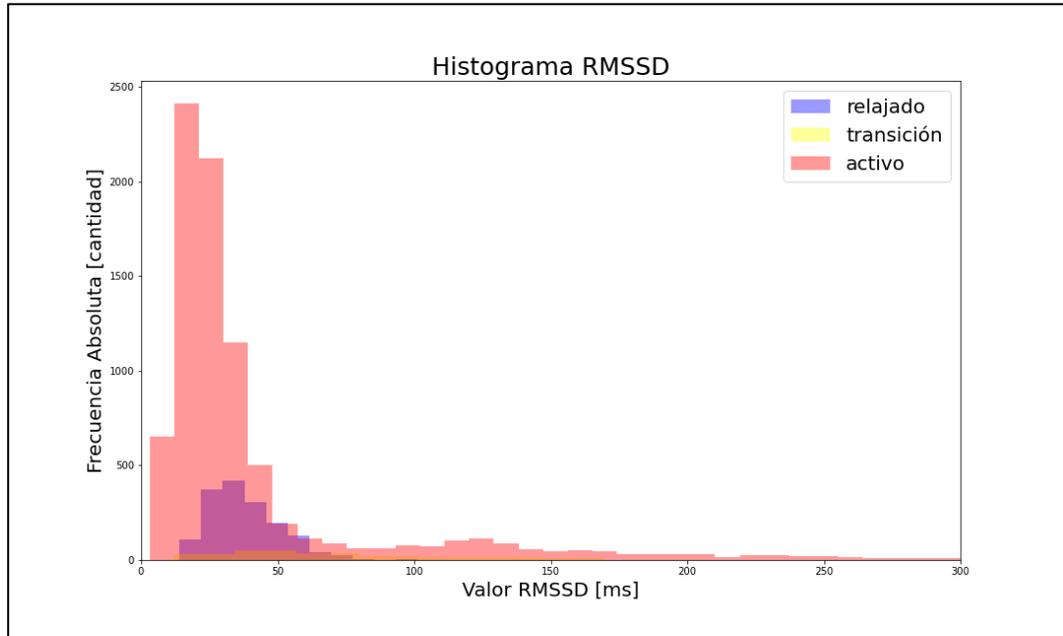


Figura 7-76: Histograma RMSSD de la clusterización de la persona número 3.

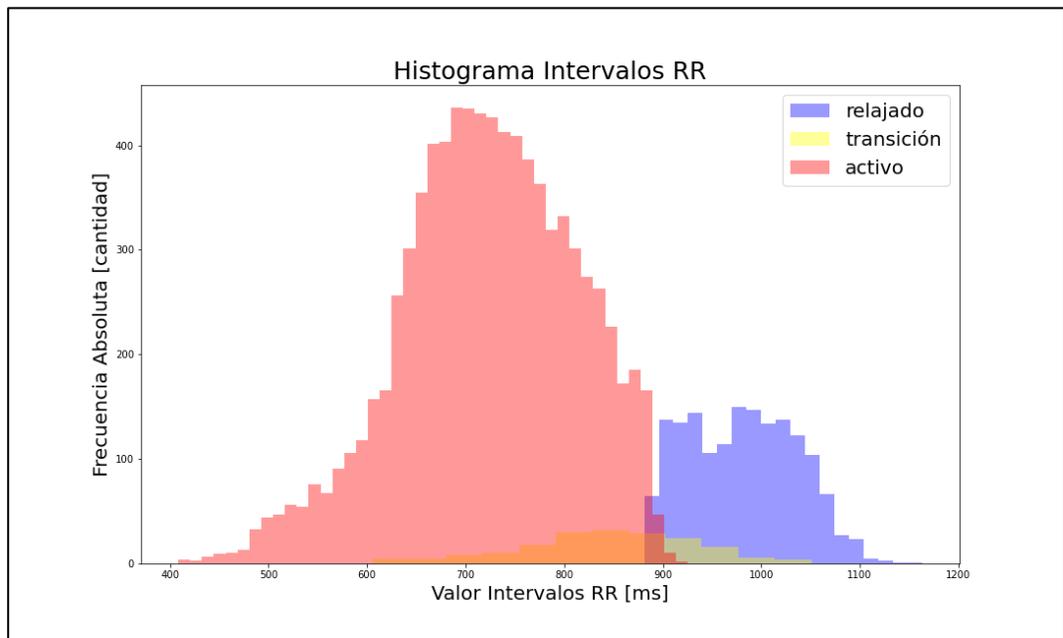


Figura 7-77: Histograma intervalos RR de la clusterización de la persona número 3.

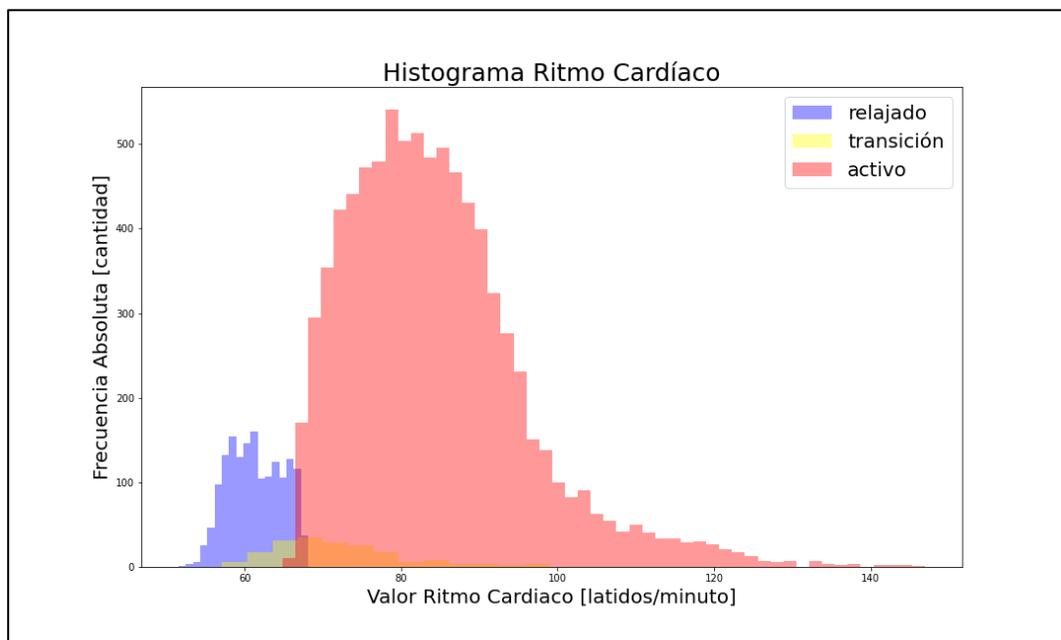


Figura 7-78: Histograma ritmo cardiaco de la clusterización de la persona número 3.

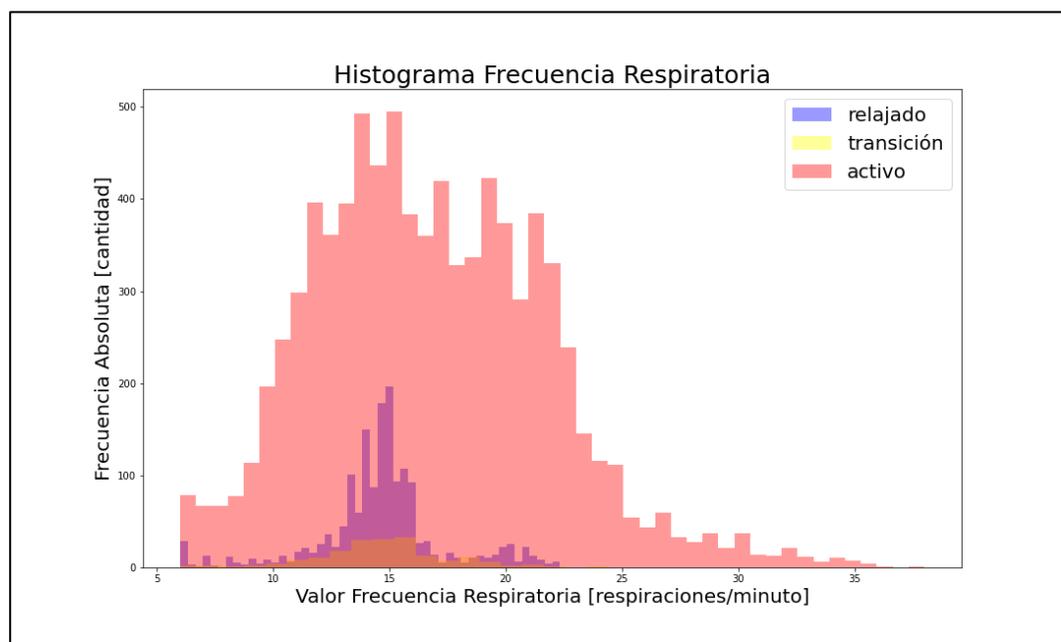


Figura 7-79: Histograma frecuencia respiratoria de la clusterización de la persona número

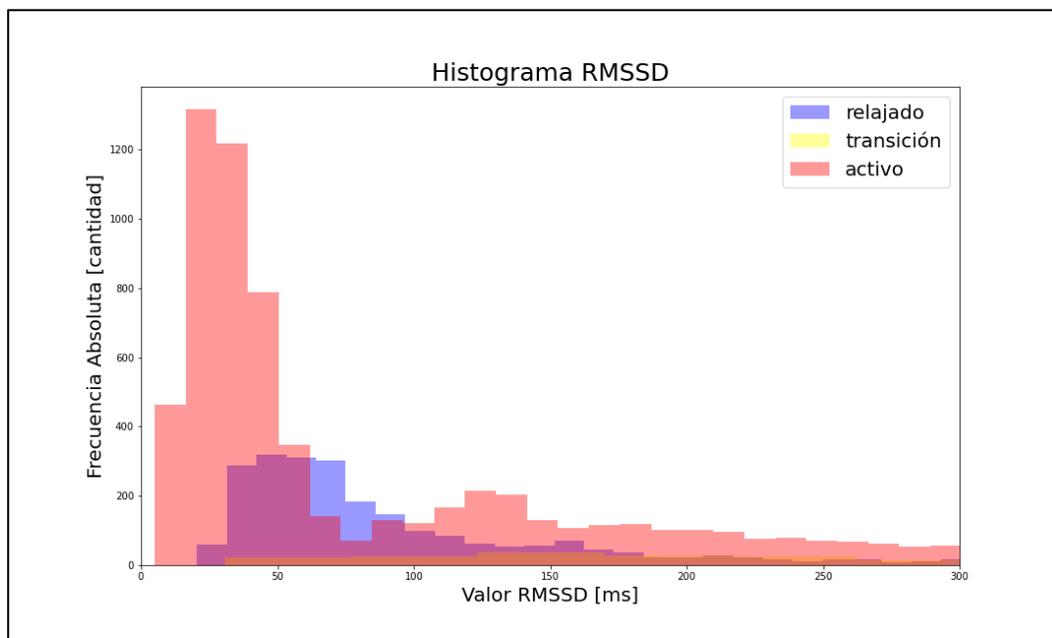


Figura 7-80: Histograma RMSSD de la clusterización de la persona número 5.

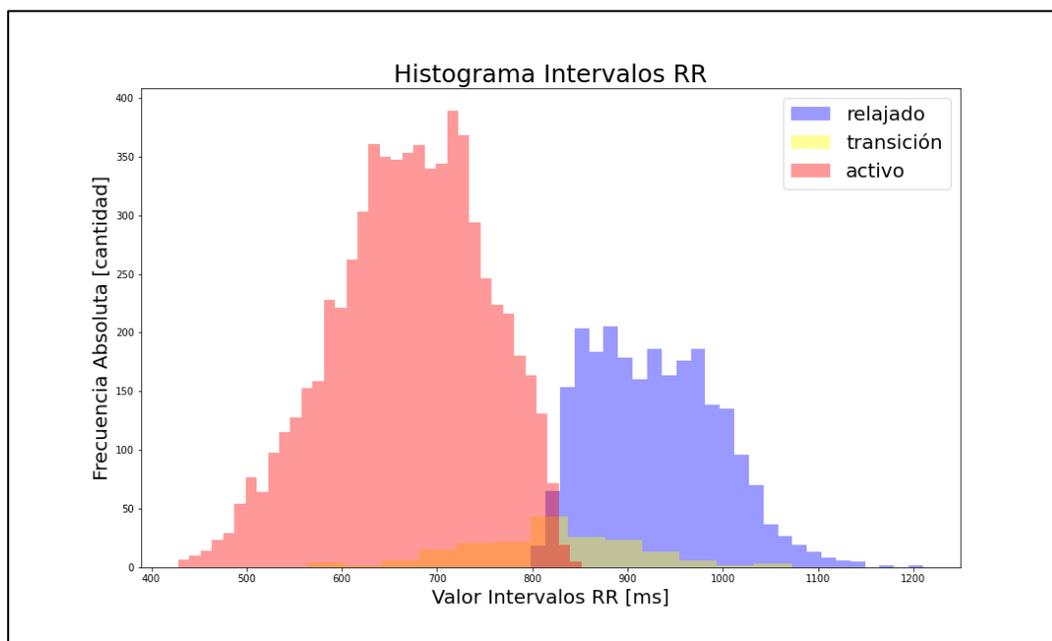


Figura 7-81: Histograma intervalos RR de la clusterización de la persona número 5.

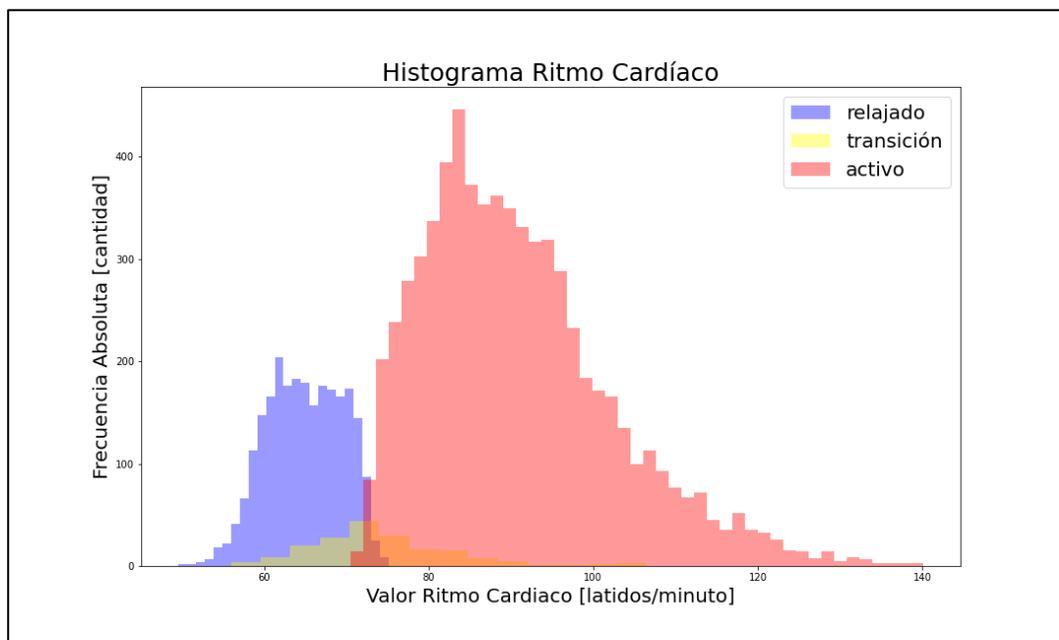


Figura 7-82: Histograma ritmo cardiaco de la clusterización de la persona número 5.

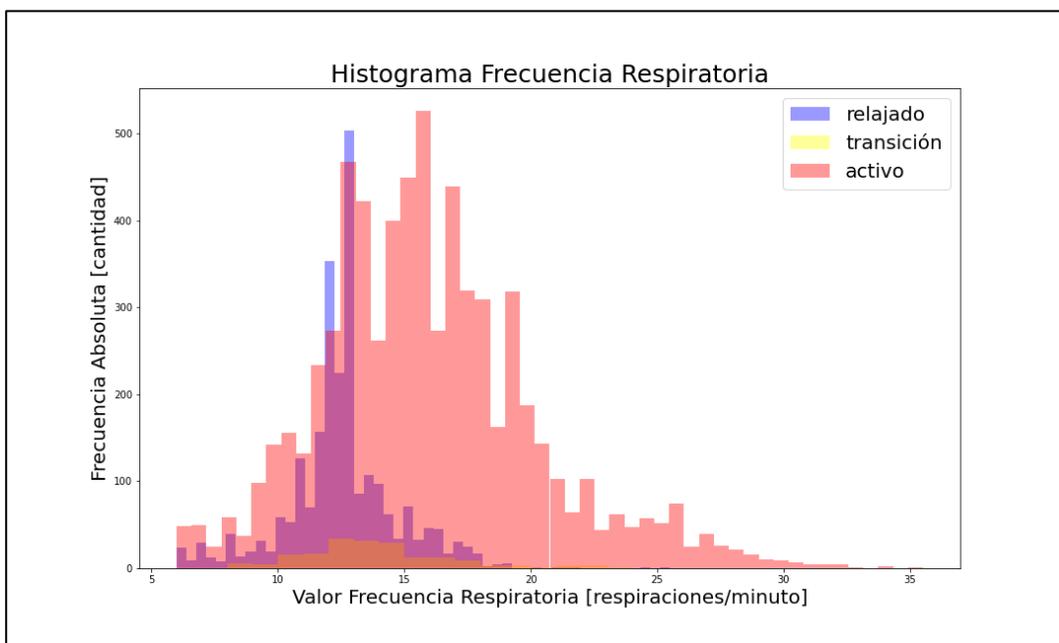


Figura 7-83: Histograma frecuencia respiratoria de la clusterización de la persona número

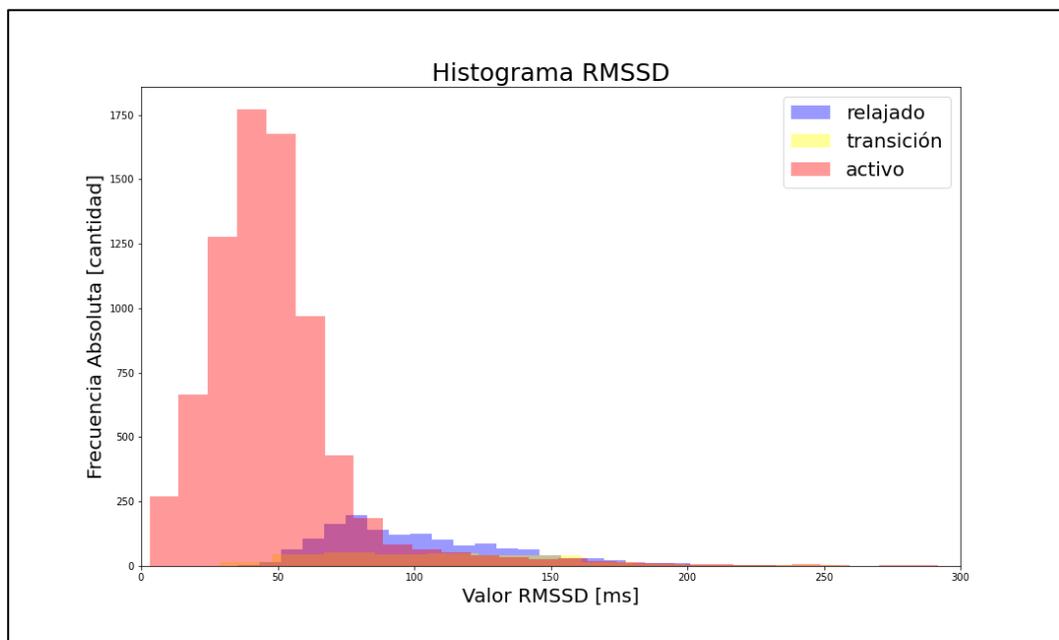


Figura 7-84: Histograma RMSSD de la clusterización de la persona número 7.

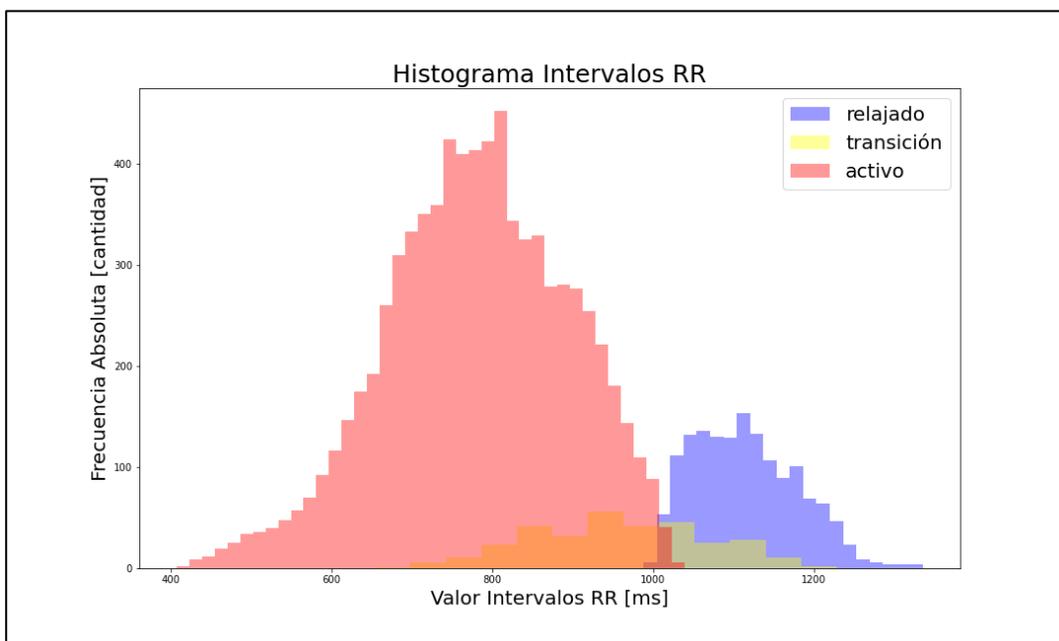


Figura 7-85: Histograma intervalos RR de la clusterización de la persona número 7.

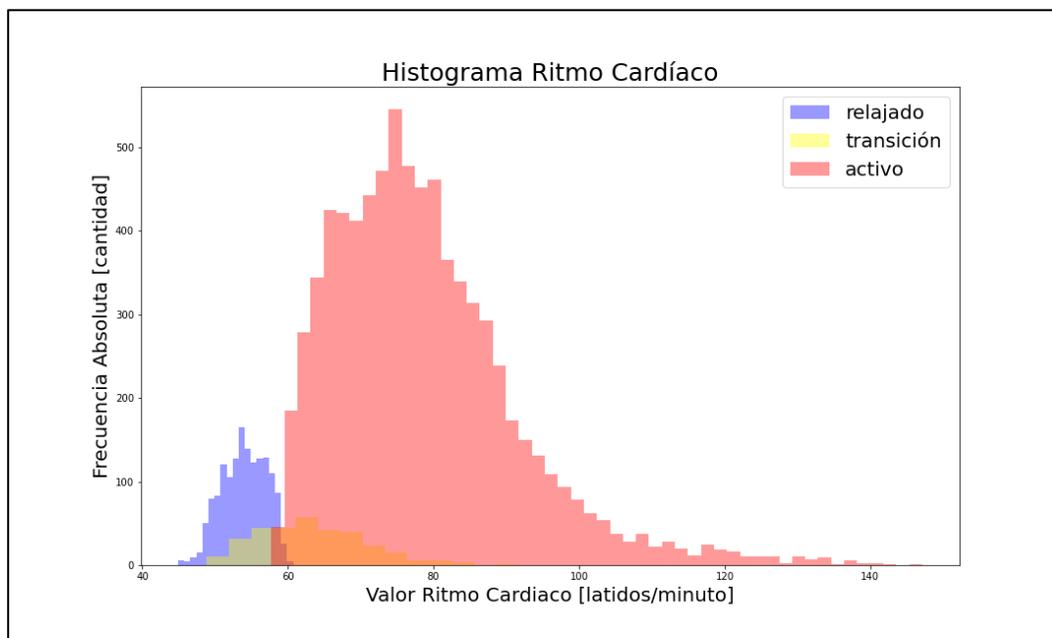


Figura 7-86: Histograma ritmo cardiaco de la clusterización de la persona número 7.

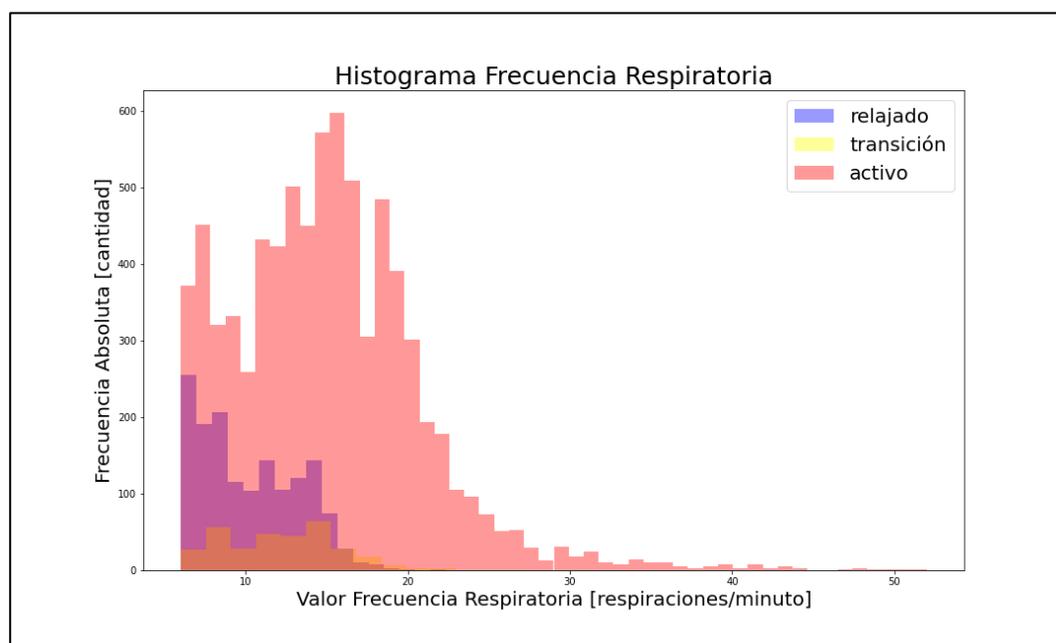


Figura 7-87: Histograma frecuencia respiratoria de la clusterización de la persona número

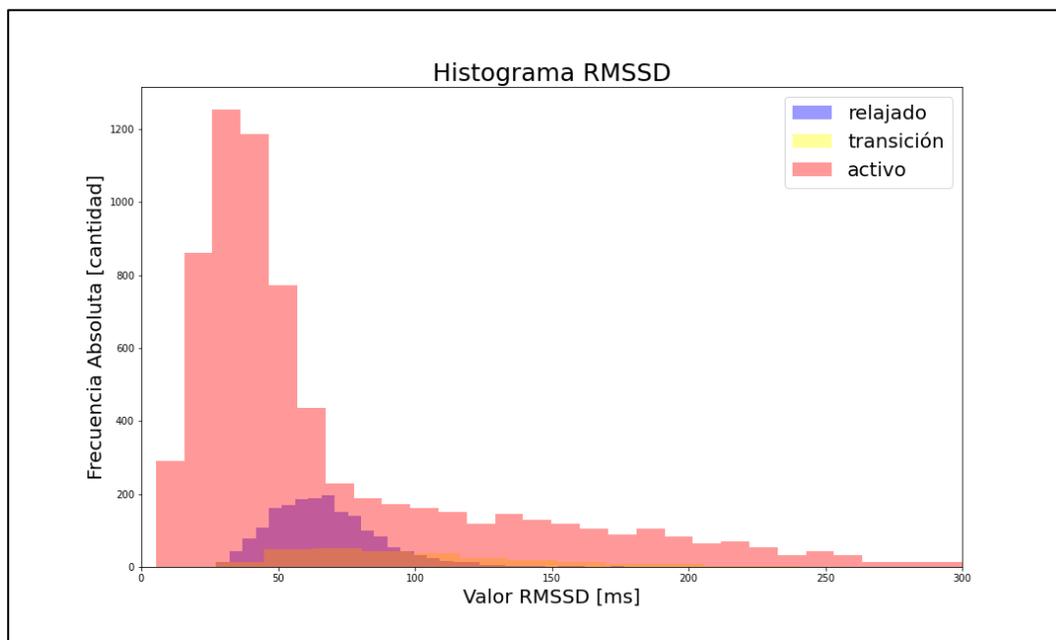


Figura 7-88: Histograma RMSSD de la clusterización de la persona número 8.

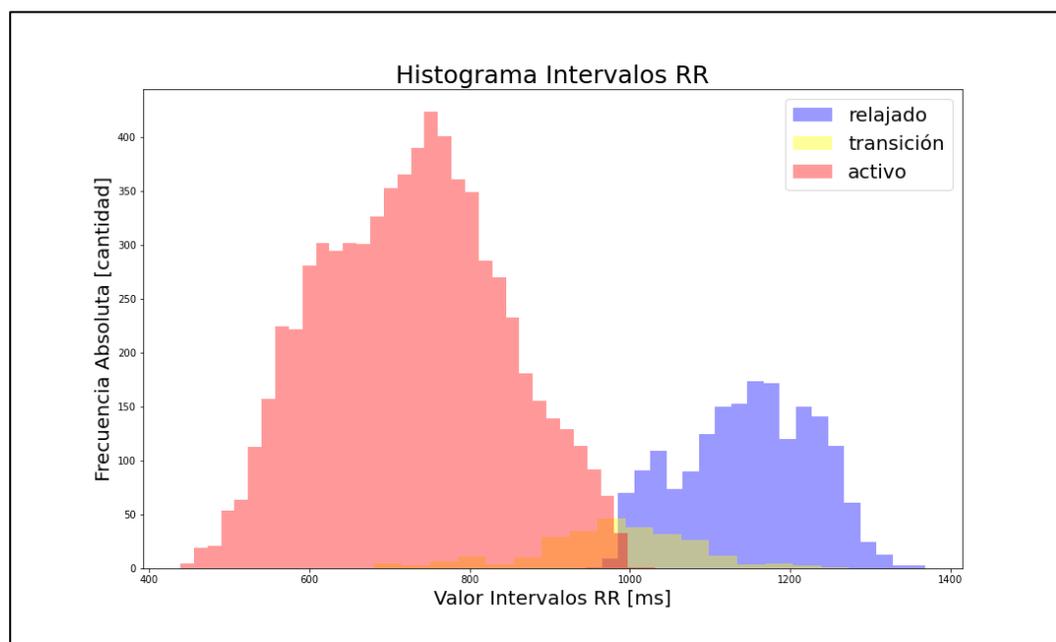


Figura 7-89: Histograma intervalos RR de la clusterización de la persona número 8.

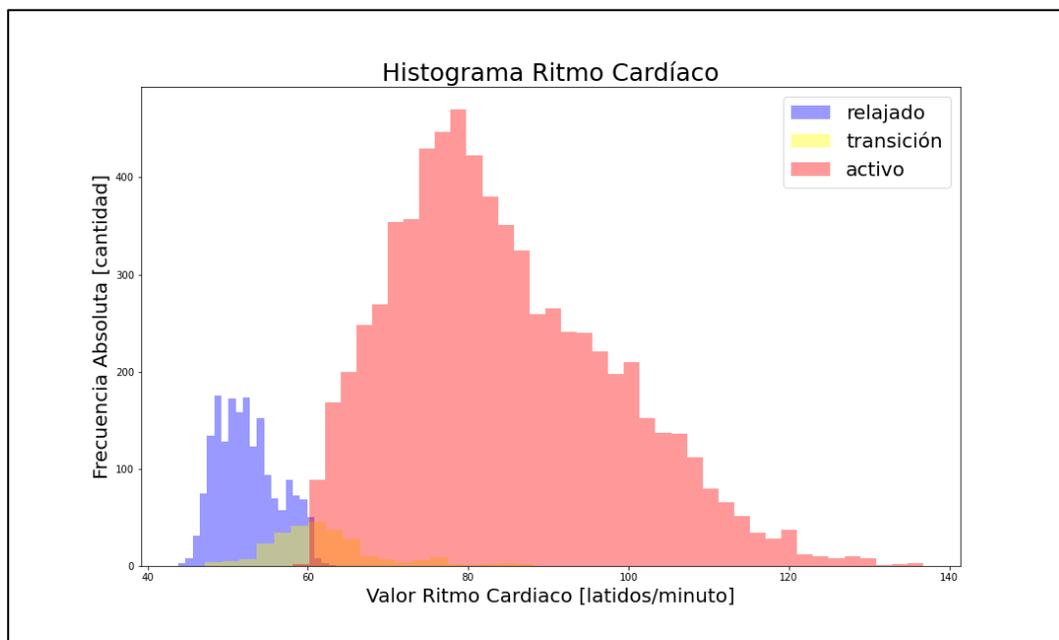


Figura 7-90: Histograma ritmo cardiaco de la clusterización de la persona número 8.

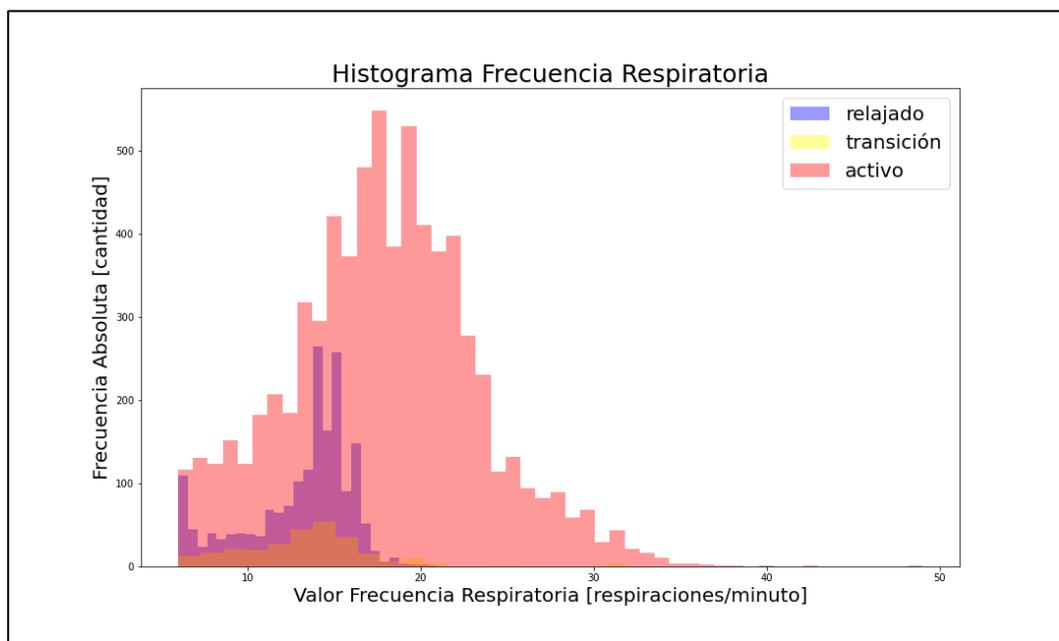


Figura 7-91: Histograma frecuencia respiratoria de la clusterización de la persona número

8.

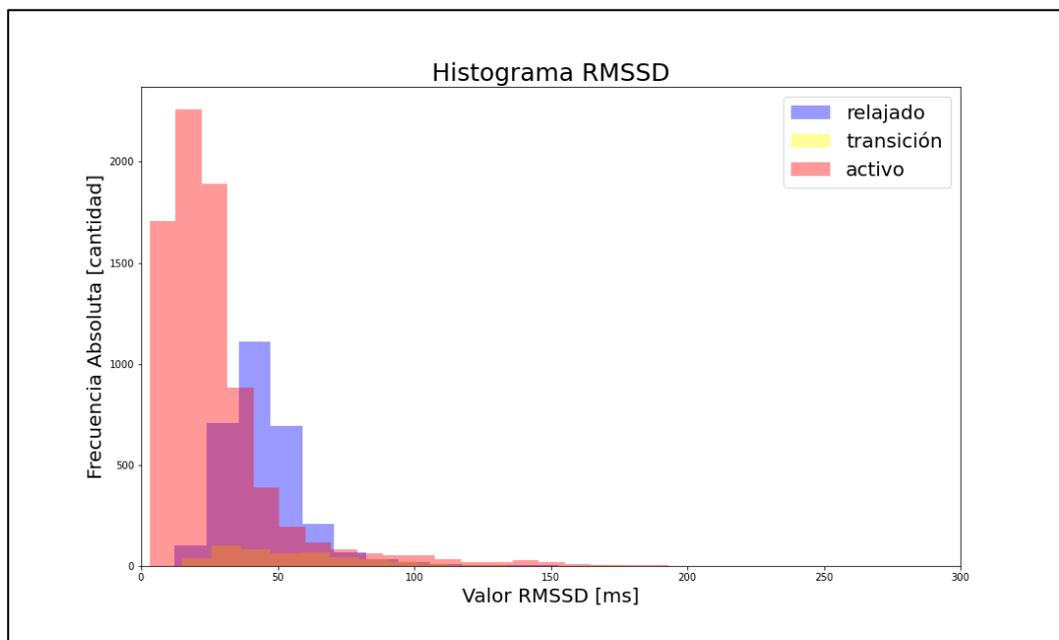


Figura 7-92: Histograma RMSSD de la clusterización de la persona número 9.

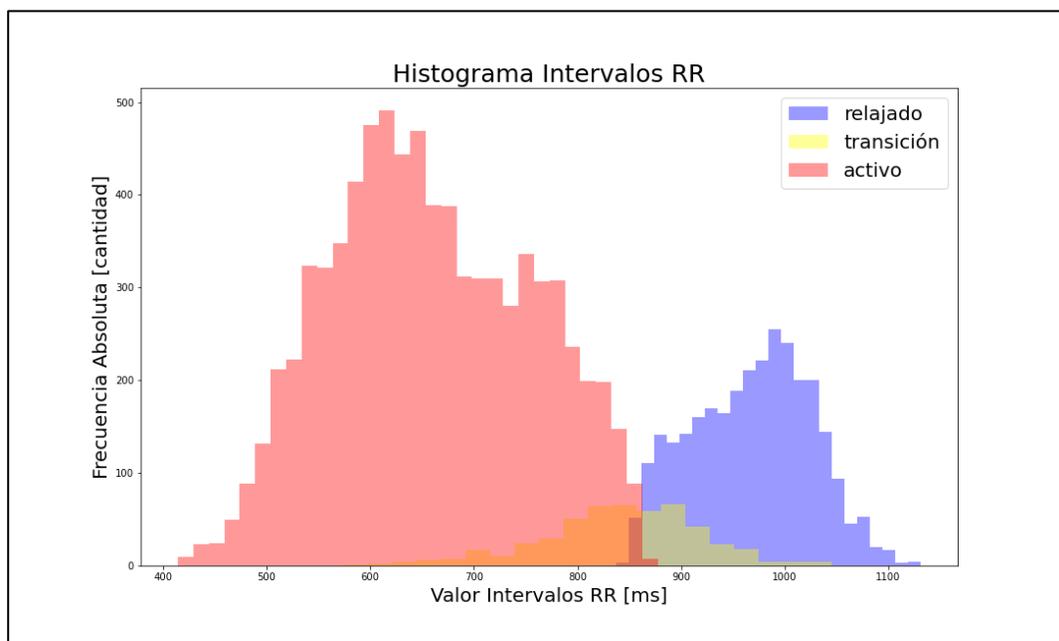


Figura 7-93: Histograma intervalos RR de la clusterización de la persona número 9.

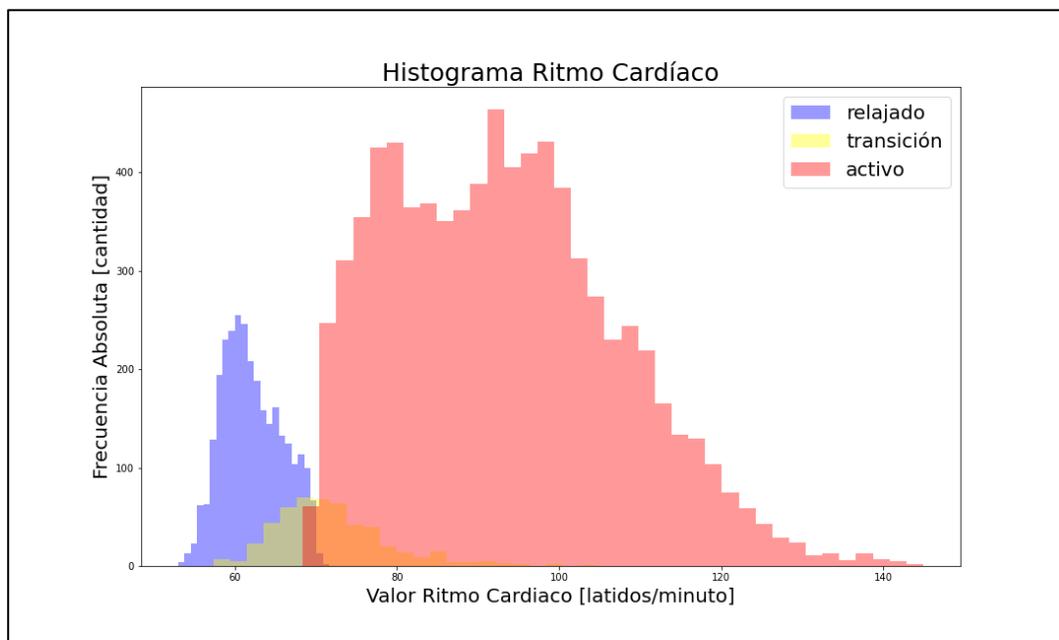


Figura 7-94: Histograma ritmo cardiaco de la clusterización de la persona número 9.

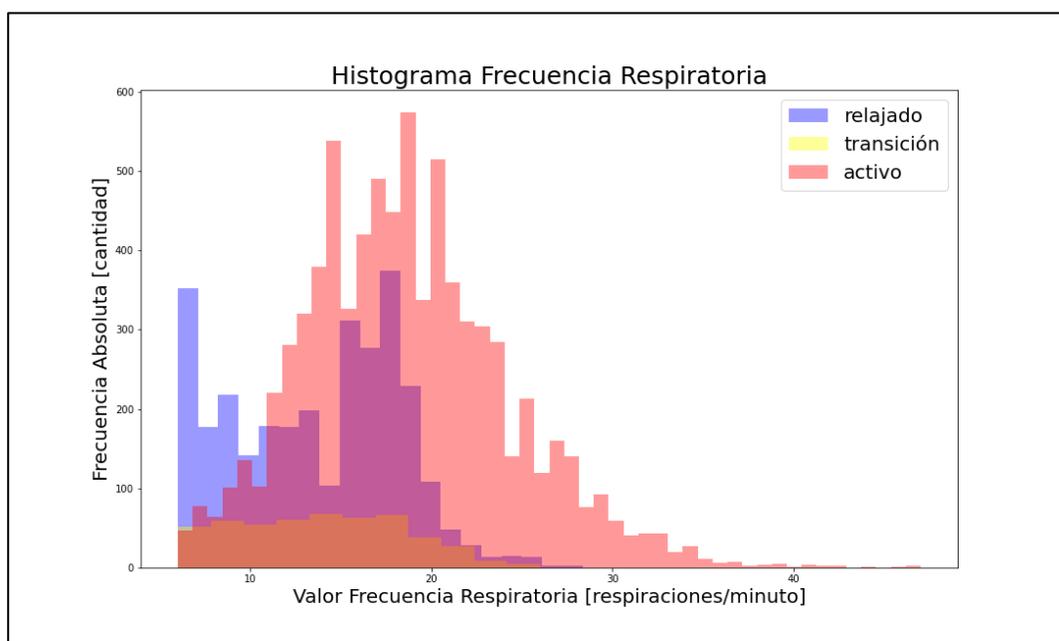


Figura 7-95: Histograma frecuencia respiratoria de la clusterización de la persona número

Tabla 7-1: Valores de medidas fisiológicas persona número 3.

REPORTE ESTADOS FISIOLÓGICOS DE ENTRENAMIENTO			
	Clúster Relajado	Clúster Transición	Clúster Activo
Variabilidad Ritmo Cardíaco RMSSD [ms]			
Promedio	39.08	83.54	43.55
Desv Estandar	19.99	69.99	53.24
Mínimo	14.05	11.97	3.17
Máximo	410.42	439.52	453.26
Intervalos R-R [ms]			
Promedio	980.79	844.47	722.71
Desv Estandar	54.73	89.50	89.47
Mínimo	881.18	605.90	408.30
Máximo	1163.42	1050.85	925.78
Ritmo Cardíaco [latidos/minuto]			
Promedio	61.37	71.91	84.41
Desv Estandar	3.41	8.19	11.45
Mínimo	51.57	57.10	64.81
Máximo	68.09	99.03	146.95
Frecuencia respiratoria [respiraciones/minuto]			
Promedio	14.62	14.79	16.77
Desv Estandar	2.78	2.76	4.98
Mínimo	6.00	6.00	6.00
Máximo	22.33	24.40	38.00

Tabla 7-2: Valores de medidas fisiológicas persona número 5.

REPORTE ESTADOS FISIOLÓGICOS DE ENTRENAMIENTO			
	Clúster Relajado	Clúster Transición	Clúster Activo
Variabilidad Ritmo Cardíaco RMSSD [ms]			
Promedio	106.54	198.56	89.82
Desv Estandar	89.13	105.51	91.95
Mínimo	20.53	30.84	5.02
Máximo	522.45	493.79	573.63
Intervalos R-R [ms]			
Promedio	929.19	817.57	671.06
Desv Estandar	67.55	91.23	79.88
Mínimo	798.50	563.48	428.25
Máximo	1210.30	1072.13	851.43
Ritmo Cardíaco [latidos/minuto]			
Promedio	64.91	74.36	90.77
Desv Estandar	4.62	8.85	11.60
Mínimo	49.57	55.96	70.47
Máximo	75.14	106.48	140.11
Frecuencia respiratoria [respiraciones/minuto]			
Promedio	12.56	13.69	15.95
Desv Estandar	2.18	2.90	4.30
Mínimo	6.00	8.00	6.00
Máximo	25.50	24.00	35.50

Tabla 7-3: Valores de medidas fisiológicas persona número 7.

REPORTE ESTADOS FISIOLÓGICOS DE ENTRENAMIENTO			
	Clúster Relajado	Clúster Transición	Clúster Activo
Variabilidad Ritmo Cardíaco RMSSD [ms]			
Promedio	101.82	112.36	49.04
Desv Estandar	33.86	55.83	29.79
Mínimo	35.66	29.15	3.11
Máximo	279.94	501.45	537.38
Intervalos R-R [ms]			
Promedio	1115.83	958.16	780.95
Desv Estandar	64.01	108.56	113.33
Mínimo	988.53	654.30	407.82
Máximo	1335.80	1228.52	1039.20
Ritmo Cardíaco [latidos/minuto]			
Promedio	53.95	63.45	78.63
Desv Estandar	3.04	7.44	12.70
Mínimo	44.92	48.84	57.74
Máximo	60.70	91.70	147.12
Frecuencia respiratoria [respiraciones/minuto]			
Promedio	10.13	12.18	15.00
Desv Estandar	3.15	3.48	5.79
Mínimo	6.00	6.00	6.00
Máximo	22.40	23.00	52.00

Tabla 7-4: Valores de medidas fisiológicas persona número 8.

REPORTE ESTADOS FISIOLÓGICOS DE ENTRENAMIENTO			
	Clúster Relajado	Clúster Transición	Clúster Activo
Variabilidad Ritmo Cardíaco RMSSD [ms]			
Promedio	68.14	100.85	73.24
Desv Estandar	22.29	51.12	68.49
Mínimo	27.40	26.96	5.30
Máximo	267.71	473.81	521.77
Intervalos R-R [ms]			
Promedio	1148.16	978.35	729.12
Desv Estandar	81.72	102.29	112.94
Mínimo	945.17	680.57	438.77
Máximo	1368.62	1273.57	1031.37
Ritmo Cardíaco [latidos/minuto]			
Promedio	52.53	62.05	84.37
Desv Estandar	3.81	7.02	13.63
Mínimo	43.84	47.11	58.18
Máximo	63.48	88.16	136.75
Frecuencia respiratoria [respiraciones/minuto]			
Promedio	13.02	13.42	17.86
Desv Estandar	3.05	3.87	5.46
Mínimo	6.00	6.00	6.00
Máximo	21.00	32.00	49.00

Tabla 7-5: Valores de medidas fisiológicas persona número 9.

REPORTE ESTADOS FISIOLÓGICOS DE ENTRENAMIENTO			
	Clúster Relajado	Clúster Transición	Clúster Activo
Variabilidad Ritmo Cardíaco RMSSD [ms]			
Promedio	45.46	61.62	28.02
Desv Estandar	23.93	50.27	27.95
Mínimo	12.26	15.13	3.11
Máximo	597.35	553.98	477.88
Intervalos R-R [ms]			
Promedio	968.07	840.30	658.24
Desv Estandar	57.37	76.61	96.13
Mínimo	837.25	573.95	414.10
Máximo	1131.18	1045.12	877.42
Ritmo Cardíaco [latidos/minuto]			
Promedio	62.20	72.04	93.16
Desv Estandar	3.72	7.03	13.94
Mínimo	53.04	57.41	68.38
Máximo	71.66	104.54	144.89
Frecuencia respiratoria [respiraciones/minuto]			
Promedio	13.64	13.95	18.61
Desv Estandar	4.66	4.59	5.67
Mínimo	6.00	6.00	6.00
Máximo	28.33	26.00	47.00

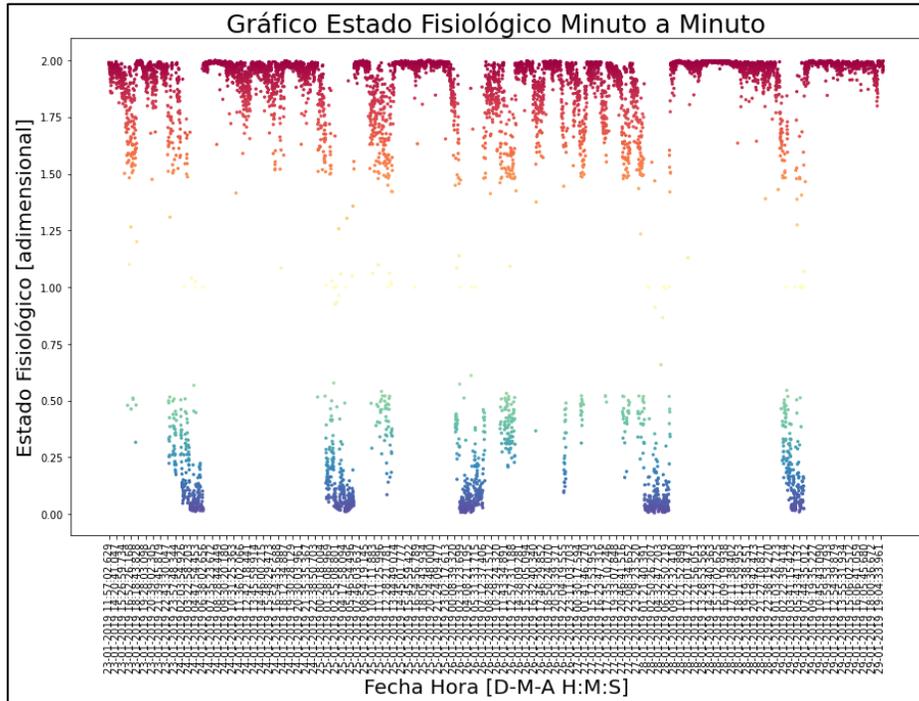


Figura 7-96: Estado fisiológico minuto a minuto persona número 3.

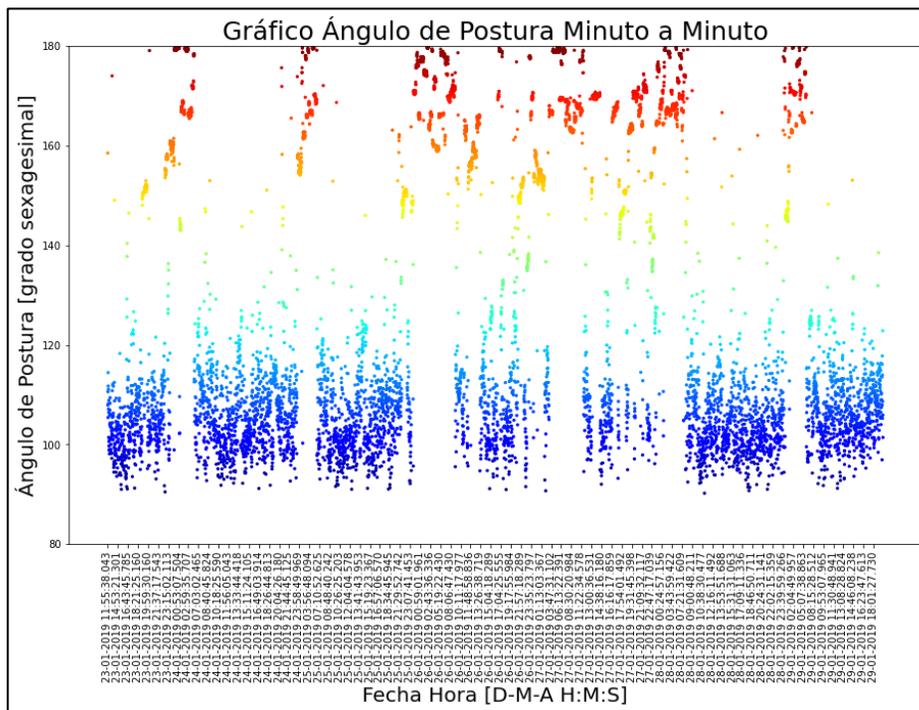


Figura 7-97: Ángulo de postura minuto a minuto persona número 3.

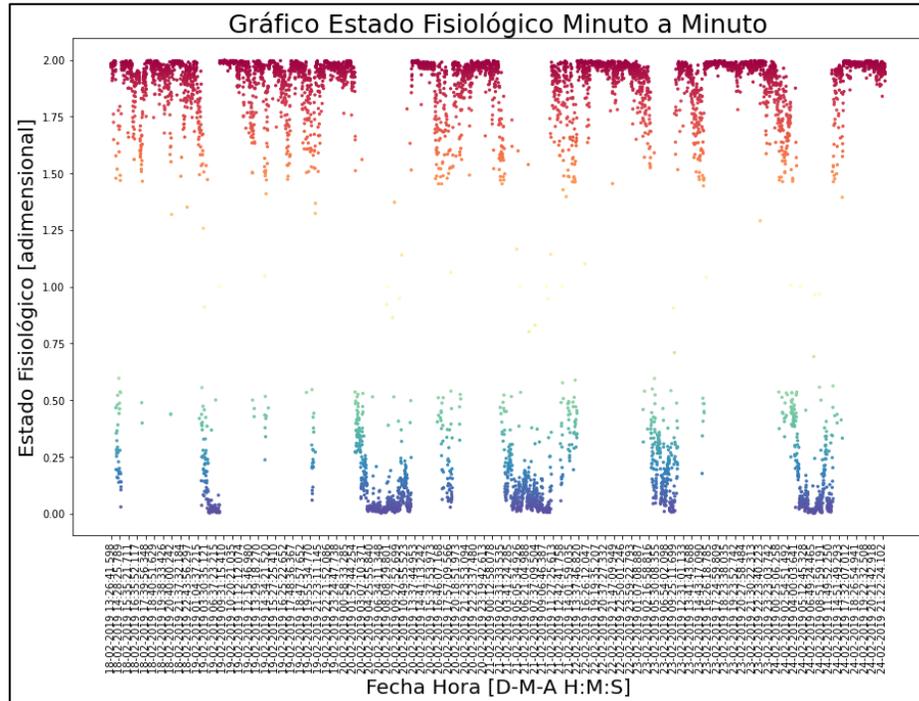


Figura 7-98: Estado fisiológico minuto a minuto persona número 5.

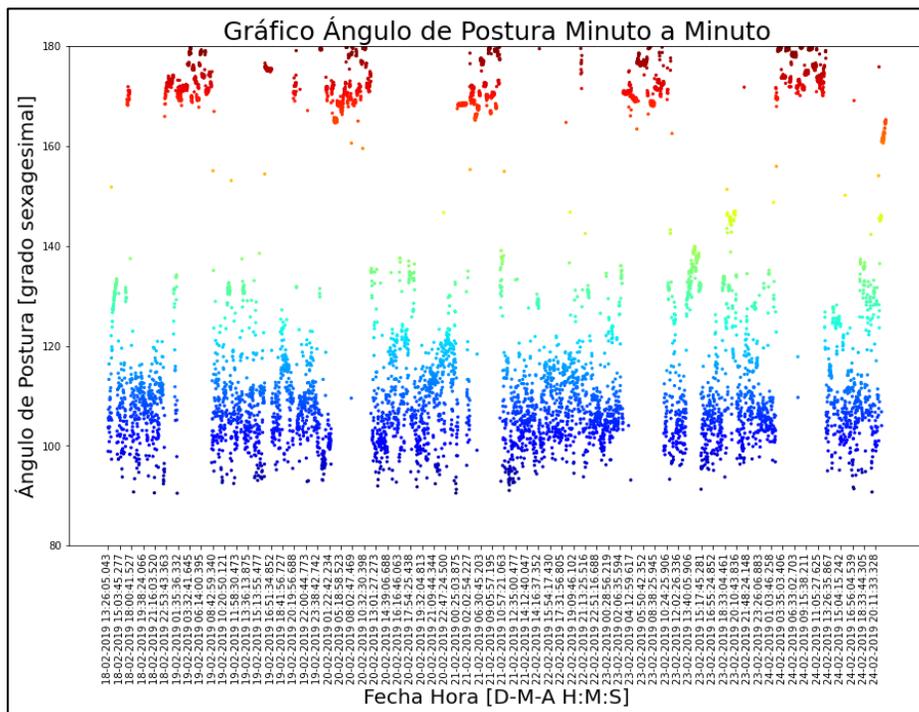


Figura 7-99: Ángulo de postura minuto a minuto persona número 5.

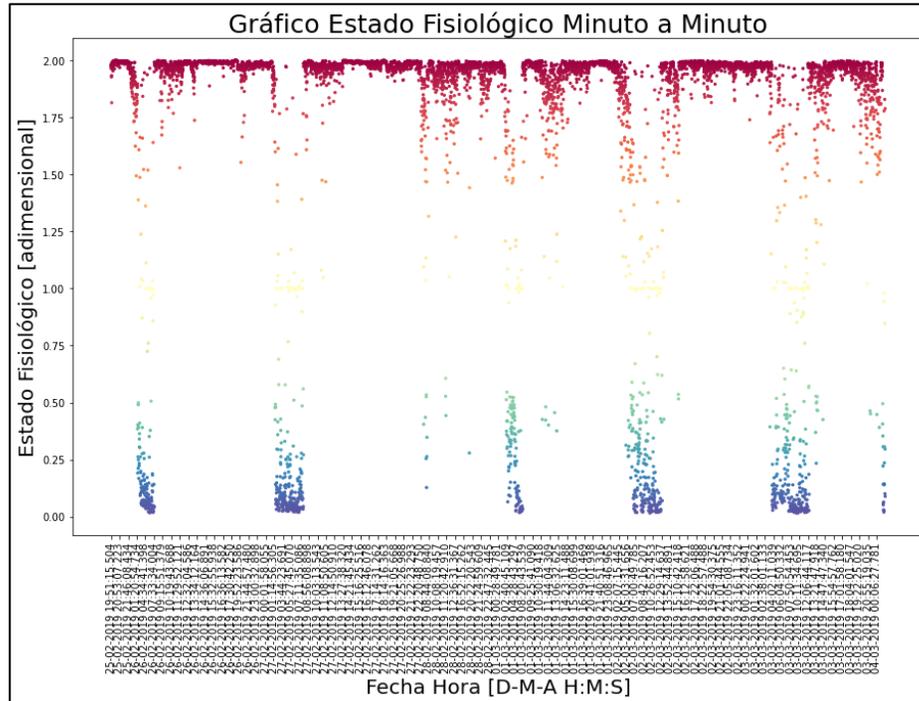


Figura 7-100: Estado fisiológico minuto a minuto persona número 7.

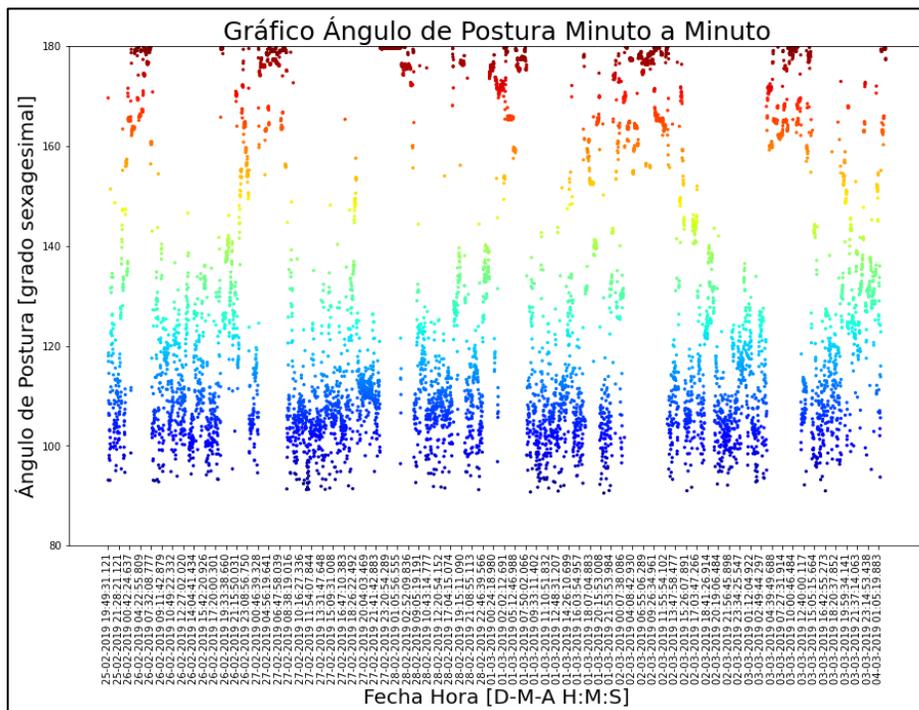


Figura 7-101: Ángulo de postura minuto a minuto persona número 7.

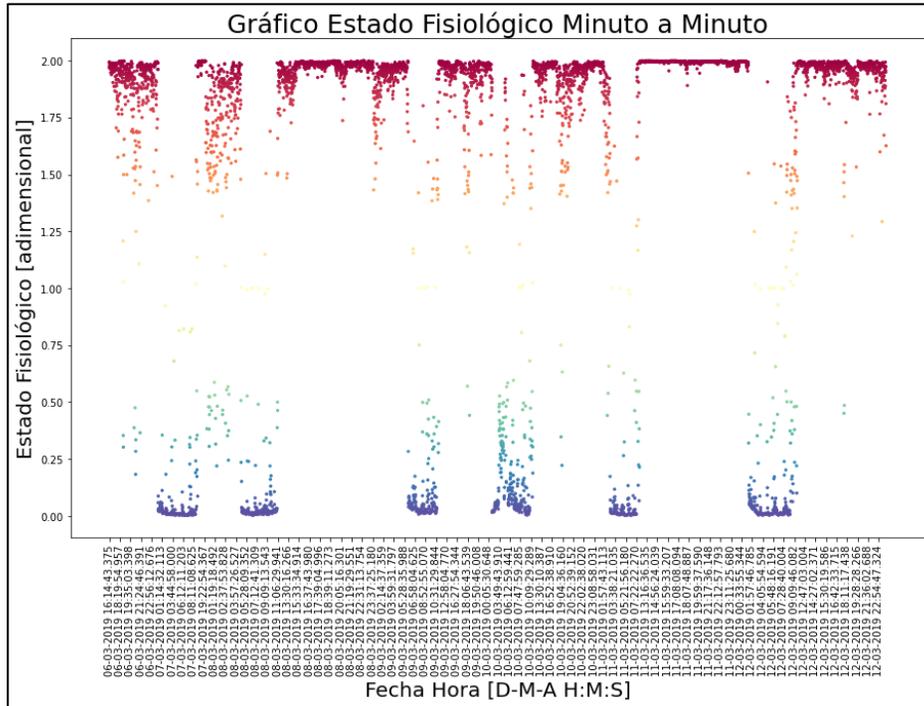


Figura 7-102: Estado fisiológico minuto a minuto persona número 8.

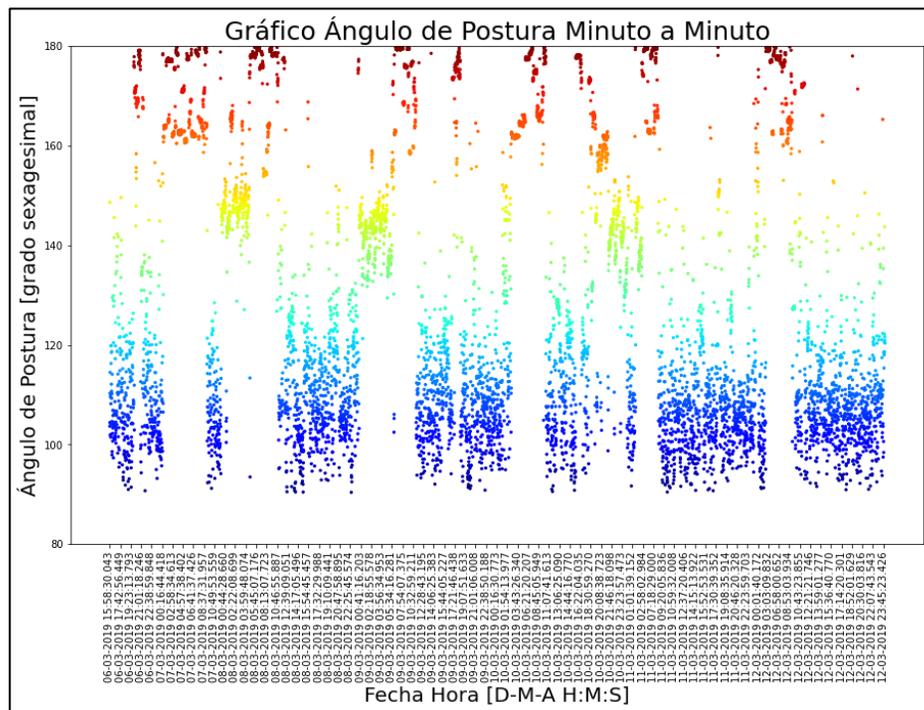


Figura 7-103: Ángulo de postura minuto a minuto persona número 8.

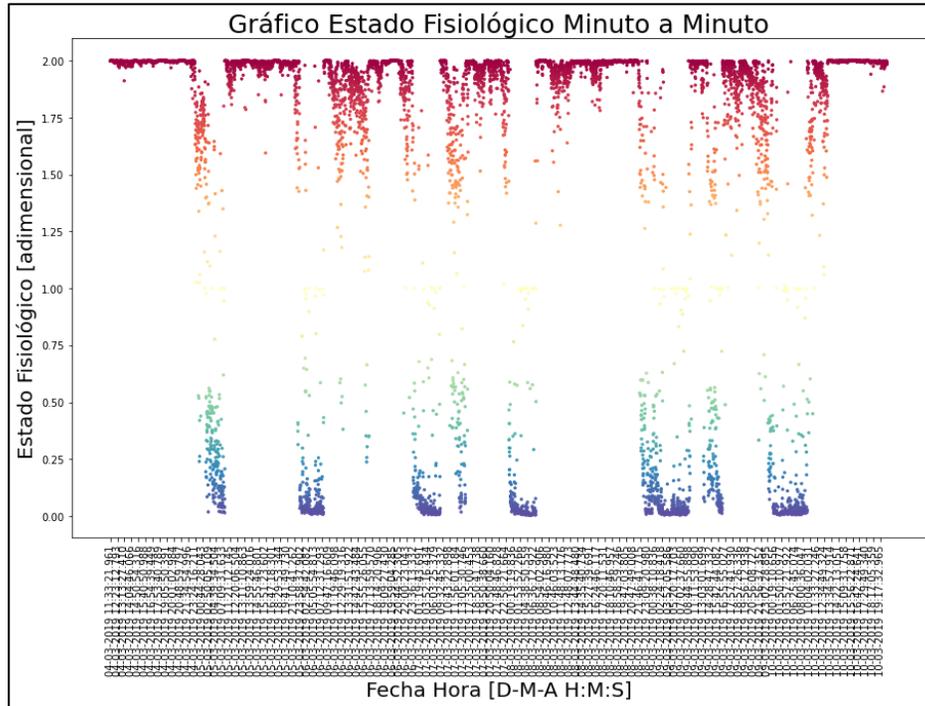


Figura 7-104: Estado fisiológico minuto a minuto persona número 9.

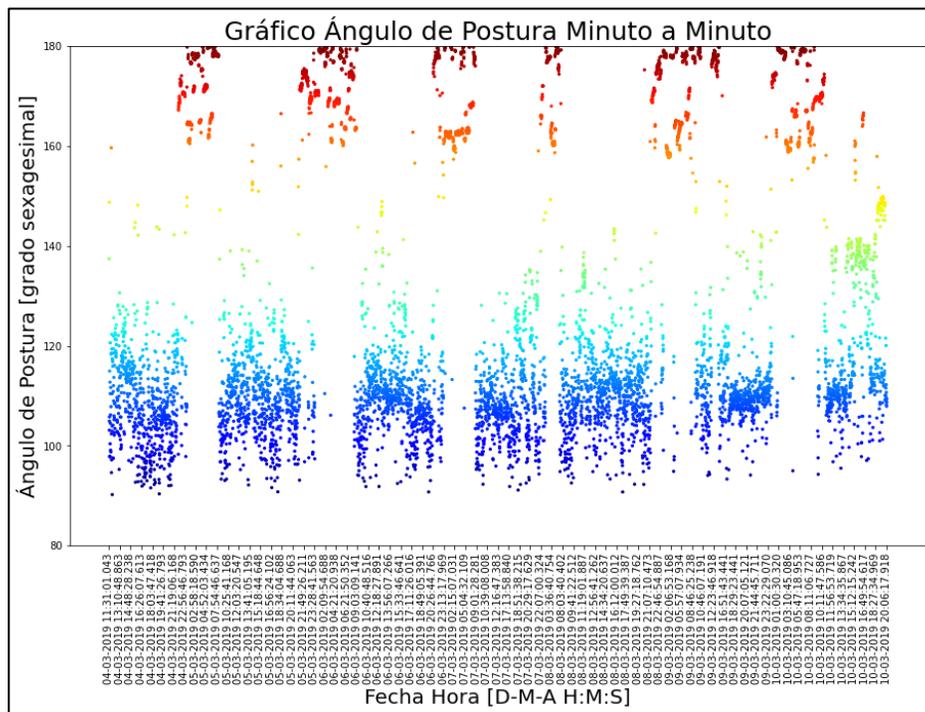


Figura 7-105: Ángulo de postura minuto a minuto persona número 9.