



E4.3. Informe de resultados final. Versión de difusión.

S2 Grupo

Introducción

Este estudio se centra en la identificación de anomalías y variaciones estadísticas en los patrones de datos biomédicos. La detección de estas anomalías es fundamental para reconocer alteraciones significativas en los perfiles de salud de los usuarios.

Se subraya la relevancia de la detección de anomalías en la monitorización de datos biomédicos de pacientes considerados de alto riesgo. La habilidad para reconocer cambios en la salud a partir de esta información contribuye a mejorar la calidad de la atención médica y puede conducir a una gestión más efectiva de condiciones crónicas, así como a la detección precoz de enfermedades graves.

A través de la plataforma Ai3Cord se han recogido diferentes tipos de variables:

- Valoración médica mediante cuestionarios estándar para diferentes dominios (fragilidad, soledad, deterioro cognitivo, etcétera)
- Valoración hospitalaria mediante pruebas.
- Autopercepción mediante cuestionarios recogidos periódicamente a través de la aplicación móvil de Ai3Cord
- Sensorización personal mediante wearables
- Sensorización del entorno domiciliario mediante dispositivos IoT

Todo este conjunto de datos se ha analizado mediante diferentes técnicas, tratando de identificar aquellas variables que puedan aportar mayor luz a la condición de fragilidad de los pacientes, así como gracias a la IA predecir cambios en las condiciones y contribuir a la detección temprana.

Una de las fuentes de información más valiosa para este enfoque ha sido la proveniente de la sensorización individual mediante wearables, ya que ha proporcionado un gran volumen de datos, adecuado para la aplicación de las técnicas estadísticas y de aprendizaje automático comentadas anteriormente.

Tras un preprocesado de los datos, revisando los diferentes algoritmos y enfoques que pueden resultar útiles para este tipo de variables, se han adoptado diferentes enfoques:

- Análisis estadísticos univariantes y multivariantes
- Análisis de agrupación o clustering
- Análisis de series temporales tanto univariante como multivariante

A modo de ejemplo se presentan a continuación algunos resultados concretos obtenidos:

Análisis estadístico univariable

En la siguiente gráfica se observa el comportamiento de la señal de frecuencia cardíaca para un participante del estudio en un intervalo de tiempo determinado:




Figura 1: Análisis univariante. Media de latidos por minuto (BPM) del paciente 51 entre el 29 de enero y el 9 marzo de 2023. Eje X: Tiempo, Eje Y: Valores bpm

Aplicando un análisis de Kolmogorov-Smirnov se pudieron identificar determinadas anomalías que se correspondían con un cambio en su estado de salud reportado por el paciente en las entrevistas telefónicas mantenidas con los médicos.

Análisis estadístico multivariable

Otro tipo de análisis aplicado al estudio ha sido el multivariante, siempre buscando la identificación de anomalías que ayuden a determinar cambios en el estado de fragilidad de los pacientes.

Un ejemplo de utilidad de este análisis es mostrado en la siguiente figura. A través de este análisis, ha sido posible detectar un cambio significativo en la frecuencia cardíaca del participante asociado a la vuelta a la rutina después de un periodo de vacaciones. El resultado del análisis de PCA muestra que las variables más influyentes en la detección de esta anomalía son 'min_speed' (velocidad mínima), 'max_speed' (velocidad máxima), 'sum_distance' (distancia total recorrida) y 'mean_speed' (velocidad media), siendo coherente con la idea de que la disminución de la actividad física y el aumento de la ansiedad postvacacional pueden haber contribuido a esta anomalía en la frecuencia cardíaca.

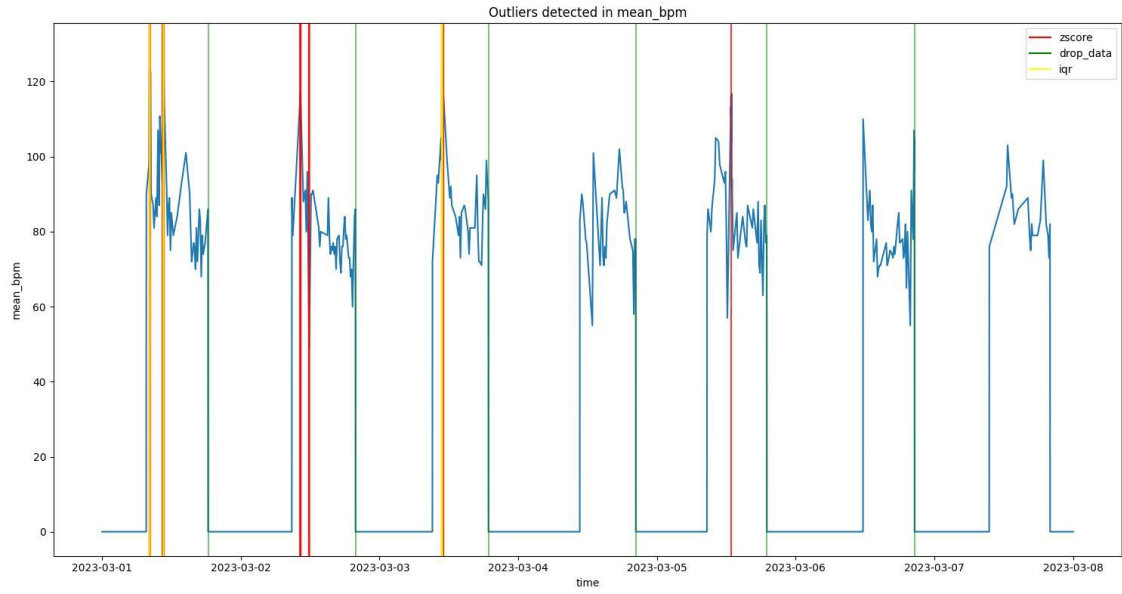


Figura 2: Anàlisi multivariante. Media de latidos por minuto (BPM) del paciente 51 entre el 1 de marzo y el 9 marzo de 2023. Eje X: Tiempo, Eje Y: Valores bpm

Resultados de los análisis estadísticos:

Análisis y detección de anomalías

En esta sección se presentan los resultados del estudio de detección de anomalías en datos biomédicos. El objetivo fue la identificación de cambios significativos en los patrones de salud de los usuarios, considerando eventos médicos y el estado de salud mental como factores influyentes.

Para ello, se aplicaron técnicas estadísticas como el test de Levene y el test de Kolmogorov-Smirnov para evaluar las diferencias en la varianza y la distribución de los valores biomédicos a lo largo del tiempo. También el Z-score y el rango intercuartílico (IQR), al análisis de variables clave. Además, se utilizó un análisis de componentes principales (PCA) para identificar las variables más relevantes en la detección de anomalías.

A continuación, se resumen los resultados más significativos:

1. **Cambios Posteriores a las Vacaciones:** Se detectaron cambios significativos en la distribución de las pulsaciones cardíacas (bpm) después de que un usuario regresara de unas vacaciones. Este cambio en las bpm se correlacionó con un aumento en la ansiedad postvacacional, lo que sugiere una conexión entre el estrés y las pulsaciones cardíacas.
2. **Molestias en Miembros Inferiores:** Se observó una disminución en la actividad física del usuario, caracterizada por una menor distancia recorrida y una velocidad de paso más lenta. Estos cambios estuvieron relacionados con las molestias en los miembros inferiores.
3. **Dolores Cervicales:** Un usuario previamente diagnosticado con protrusiones y hernias en la columna vertebral experimentó un aumento en las pulsaciones cardíacas. Esto podría estar vinculado al dolor cervical y las respuestas al estrés asociadas.
4. **Infección Dentaria y Extracción de Piezas Dentarias:** Se registró un aumento en las pulsaciones cardíacas después de una infección dentaria y la extracción de piezas dentarias. La relación entre el dolor y el estrés con las pulsaciones cardíacas fue evidente.
5. **Problemas Estomacales:** Los síntomas estomacales de un usuario se reflejaron en un aumento de las pulsaciones cardíacas y una disminución de la actividad física.
6. **Empeoramiento de la Salud Mental:** El empeoramiento de la salud mental de un paciente, marcado por un ataque de ansiedad y un aumento en la medicación ansiolítica, se asoció con un aumento en las pulsaciones cardíacas y cambios en la actividad física.
7. **Colonoscopia y Ciática:** La realización de una colonoscopia y un episodio de ciática impactaron en los patrones de actividad física, con una caída notable en la distancia recorrida y la velocidad.

Este estudio demuestra cómo los eventos médicos, las condiciones de salud y el estado de salud mental pueden tener un impacto significativo en las mediciones biomédicas, especialmente en las pulsaciones cardíacas y la actividad física. La aplicación de técnicas estadísticas y análisis de componentes principales permitió identificar patrones y variables clave relacionadas con estas anomalías.

Análisis mediante agrupación (clustering)

Para llevar las agrupaciones se han procesado los datos teniendo en cuenta variables explicativas, como el índice de fragilidad obtenido mediante los diferentes cuestionarios pasados durante el ensayo. A partir de las variables físicas, agrupadas mediante el algoritmo no supervisado K-Means se ha tratado de determinar si las clasificaciones iniciales y autopercibidas son coherentes con las variables físicas medidas.

	mean_bpm_2023-02-05 00:00:00+00:00	mean_bpm_2023-02-12 00:00:00+00:00	mean_bpm_2023-02-19 00:00:00+00:00	mean_bpm_2023-02-26 00:00:00+00:00	mean_bpm_2023-03-05 00:00:00+00:00	mean_bpm_2023-03-12 00:00:00+00:00	mean_bpm_2023-03-19 00:00:00+00:00	mean_bpm_2023-03-26 00:00:00+00:00	mean_bpm_2023-04-02 00:00:00+00:00	mean_bpm_2023-04-09 00:00:00+00:00	mean_bpm_2023-04-16 00:00:00+00:00	mean_bpm_2023-04-23 00:00:00+00:00	mean_bpm_2023-04-30 00:00:00+00:00
0	104.190089	104.773364	104.519739	102.507837	104.292819	105.820882	105.547786	105.377843	109.206689	108.284598	108.457582	113.556478	104.998337
1	111.210504	121.949231	113.076231	89.010373	92.672758	95.846797	114.335416	98.200184	106.231704	110.644727	113.898514	111.983666	98.153077
2	99.353115	110.760279	nan	76.961089	94.855940	101.394129	98.367916	97.118407	101.374529	100.203673	79.294118	89.680577	101.632303
3	70.260870	73.762887	78.314961	89.714286	74.443857	84.123810	102.429170	77.816576	101.840273	90.056183	100.176442	103.515575	96.648248
4	108.762901	96.930445	110.582940	89.083864	107.926511	71.441879	99.595090	81.102239	90.953984	102.240662	94.296416	97.865193	98.489433
5	66.650000	67.098160	87.568871	94.397211	88.354045	nan	72.060925	88.642501	82.265916	95.806287	87.528528	90.865919	94.161192
6	75.104167	73.846154	73.978947	76.434263	74.073746	76.289157	73.228228	75.233716	76.082397	75.927083	93.696845	83.755274	79.617450
7	77.837838	103.941721	100.458705	100.937281	98.435479	101.565634	103.703112	101.678669	99.970043	102.645920	101.277615	96.130124	96.363025
8	nan	60.238372	95.246921	76.128426	75.205822	89.068451	63.392241	101.469344	79.495975	nan	nan	62.196078	76.696165
9	74.615206	87.147170	102.940410	102.445450	96.950884	99.477489	91.309793	96.223799	97.578462	nan	nan	81.503891	86.572639
10	77.774869	71.280000	79.020555	84.557860	85.304758	91.146006	80.935584	87.049704	85.480590	85.727473	88.304137	88.899083	95.585724
11	72.605882	72.106383	71.481728	69.889241	72.775510	75.273682	71.253061	82.673096	87.230917	75.636917	74.466405	83.201042	72.866019
12	94.606589	nan	64.809524	nan	65.995614	67.560976	98.044255	69.783920	nan	nan	67.798561	61.703170	67.050075
13	80.501946	79.852113	79.304348	77.983356	104.581600	78.718812	77.271347	79.438889	77.288998	87.905378	76.369767	76.724074	76.088050
14	99.900749	89.637758	100.488386	93.968245	98.354076	94.598729	104.251101	92.959802	95.478697	nan	nan	nan	67.249284
15	76.013889	96.431234	100.535689	104.101794	100.531567	98.696723	99.097682	103.674925	95.880590	98.259578	95.192749	89.516516	87.840293
16	84.181618	106.956911	110.882177	82.438202	116.159516	114.576777	118.000000	107.140176	113.203199	81.027778	112.512135	104.796543	108.788813
17	100.788520	82.272723	104.090355	103.084929	98.851500	99.394909	98.548400	79.230548	102.063311	107.195792	103.884380	105.325368	103.292488
18	nan	66.710000	98.605068	95.285680	91.337041	nan	nan	83.836066	95.797134	95.168793	92.840447	94.085792	99.239583
19	nan	104.398305	104.876759	97.247776	96.178609	95.264464	96.256312	92.488315	97.184369	104.176658	93.992228	97.208331	96.832803
20	nan	nan	nan	nan	103.412963	92.422330	95.254289	95.326790	103.441711	96.880329	97.415916	101.851806	97.383561
21	nan	74.959322	113.812410	108.693817	93.500000	97.356406	103.593734	73.041298	96.569280	89.043919	94.935582	103.158771	100.732400
22	nan	88.013527	90.722716	85.367999	84.983072	84.855968	82.107173	89.009968	86.091294	84.018854	88.532937	83.483351	100.403134

Figura 3: Muestra de datos recopilados por paciente, con los valores de las características físicas agrupadas por semanas.

Sobre este conjunto de datos se ha aplicado los algoritmos de agrupación tratando de determinar si las clasificaciones iniciales son consistentes con las variables físicas medidas, tal como se ve en las siguientes gráficas:




Figura 4: Scores de los pacientes representados en las dos primeras componentes principales del PCA, a partir únicamente de los datos medidos con el reloj. El color representa el grupo de fragilidad asociado según el test de FRIED.




Figura 5: Scores de los pacientes representados en las dos primeras componentes principales del PCA, a partir únicamente de los datos medidos con el reloj. El color representa el grupo de fragilidad asociado según el test de FRAIL.

Podemos observar que las agrupaciones no parecen corresponderse con grupos claros de puntos. Ahora, se aplica el algoritmo K-Means a los datos originales escalados, con $k=3$. Tal y como se observa en la Figura 6 y en la **¡Error! No se encuentra el origen de la referencia.**, no coinciden los grupos obtenidos mediante el algoritmo con los grupos de fragilidad predefinidos.




Figura 6: Scores de los pacientes representados en las dos primeras componentes principales del PCA, a partir únicamente de los datos medidos con el reloj. El color representa el grupo asociado por el algoritmo K-Means ($k=3$).

A la vista de estos resultados, se ha tratado de dejar que sea el algoritmo el que agrupe de la manera más eficiente los conjuntos de datos obtenidos. En primer lugar es necesario determinar el número de grupos óptimo para este conjunto de datos.




Figura 7: Método del Elbow ajustado sobre los datos escalados a partir de las métricas extraídas del reloj.

Tal y como se observa en la Figura 7, el valor de k=8 es el más adecuado para el modelo K-Means en este conjunto de datos, y con esta información se realiza de nuevo la agrupación.




Figura 8: Scores de los pacientes representados en las dos primeras componentes principales del PCA, a partir únicamente de los datos medidos con el reloj. El color representa el grupo asociado por el algoritmo K-Means (k=8).

Analizando los resultados obtenidos (**¡Error! No se encuentra el origen de la referencia.**), se puede observar que los pacientes agrupados con las etiquetas 0, 1 y 6 coinciden con los grupos de fragilidad asignados por los test de FRAIL y FRIED. Aun así, el modelo de clustering separa a los pacientes clasificados como “pre-frágiles” en 2 subgrupos, a uno les asigna la etiqueta 1 y al otro la etiqueta 6. Por otro lado, el algoritmo deja aislados a los pacientes 53, 47 y 70 (clúster 2, 4 y 5) y agrupa el resto de pacientes en los grupos 3 y 7, donde parece que hay más discrepancia en cuanto a la clasificación de FRAIL y FRIED.

Se consiguen resultados similares al incluir los cuestionarios de autopercepción.

Evolución temporal del clustering con variables físicas y cuestionarios

Se ha efectuado el análisis también desde la perspectiva de la evolución temporal de los clusters y su relación con las agrupaciones iniciales y las autopercepciones recogidas durante el ensayo.

Estos resultados se pueden observar en la siguiente tabla:

Test_FRIED_SCORE	Test_FRAIL_SCORE_H	patientCode	kmeans_feb	dist_feb	kmeans_mar	dist_mar	kmeans_abr	dist_abr	kmeans_may	dist_may
robusto	pre-fragil	39	0	0.121547	0	0.000000	4	0.175673	9	0.391703
robusto	pre-fragil	58	0	0.116384	6	0.406187	6	0.001764	9	0.008498
fragil	pre-fragil	47	1	0.000000	3	0.546325	10	0.000000	9	0.254784
fragil	fragil	46	2	0.269980	2	0.167587	2	0.072534	9	0.149976
pre-fragil	fragil	34	2	0.285015	6	0.287996	6	0.000368	9	0.016593
fragil	fragil	36	2	0.281111	6	0.623479	6	0.220422	9	0.177232
pre-fragil	pre-fragil	41	3	0.311022	3	0.163379	4	0.047815	9	0.007557
pre-fragil	pre-fragil	45	3	0.386747	3	0.310547	3	0.003797	9	0.005938
pre-fragil	pre-fragil	33	3	0.614708	6	0.296995	6	0.012490	9	0.003597
pre-fragil	pre-fragil	37	3	0.377907	8	0.085667	8	0.001950	9	0.007934
pre-fragil	pre-fragil	32	4	0.000000	3	0.237761	3	0.013497	9	0.009186
fragil	fragil	35	5	0.000000	2	0.110635	5	0.000000	9	0.015777
pre-fragil	pre-fragil	51	6	0.446453	6	0.428122	6	0.000023	9	0.002155
pre-fragil	pre-fragil	49	6	0.587299	6	0.228742	1	0.000000	9	0.004842
pre-fragil	pre-fragil	50	6	0.302262	6	0.386477	6	0.009061	9	0.011450
pre-fragil	pre-fragil	52	6	0.439936	6	0.267707	3	0.020212	0	0.002473
pre-fragil	pre-fragil	48	7	0.000000	6	0.643297	6	0.083553	9	0.122416
pre-fragil	pre-fragil	31	8	0.000000	8	0.119504	8	0.003091	9	0.009334
pre-fragil	pre-fragil	30	9	0.000000	6	0.282939	6	0.001106	2	0.000000
fragil	fragil	72	10	0.165413	6	0.540628	2	0.008845	9	0.002274
pre-fragil	pre-fragil	53	10	0.335106	4	0.000000	6	0.036964	0	0.017169
pre-fragil	pre-fragil	73	10	0.246181	6	0.294698	6	0.013319	9	0.008344

Tabla 1: Comparación de los grupos de fragilidad predefinidos por los test de FRIED y FRAIL y los grupos obtenidos con el algoritmo K-Means ($k=11$) para cada uno de los meses analizados, a partir de los datos medidos con el reloj y de los cuestionarios respondidos por los pacientes.

Tal y como ocurría en el apartado anterior, la mayoría de los clústeres creados (1, 4, 5, 7, 8 y 9) tienen un único elemento durante la mayoría de los meses estudiados. Como excepciones podrían estar los clústeres 8 y 9. El clúster 8 ya en marzo amplía su número de elementos, incluyendo al paciente 37 junto con el 31, que es el que estaba en febrero. Por su parte, el clúster 9 pasa de tener un único elemento en febrero, a desaparecer durante los meses de marzo y abril y, en mayo, incluye a la mayoría de pacientes analizados. Sin duda, los datos recopilados en este estudio también tienen una alta variabilidad mes a mes, lo que explica estos cambios tan usuales de pertenencia a los grupos.

CONCLUSIONES GENERALES CLUSTERING

Los resultados obtenidos al aplicar el algoritmo de clustering a los datos recopilados por los pacientes ponen de manifiesto que no coinciden los grupos asociados de fragilidad mediante los test de FRAIL y FRIED con los grupos que crea el algoritmo K-Means. Esto sucede tanto al incluir únicamente los datos objetivos extraídos del reloj, como al incluir también los resultados de los cuestionarios contestados por los pacientes.

En general se aprecia que, con los datos de los pacientes estudiados, hay más de 3 grupos de fragilidad y, dentro de ellos, sería posible dividir a los pacientes agrupados como “pre-fragil” en varios subgrupos más homogéneos. También se ha puesto de manifiesto que los pacientes clasificados como “robusto” según el test de FRIED se agrupan objetivamente en base a sus datos con otros pacientes etiquetados como “pre-fragil”, por lo que habría que reconsiderar, en base a los resultados obtenidos y a los análisis de los expertos sanitarios, estas etiquetas asociadas a cada paciente según su estado de fragilidad.

Mediante la aplicación de las técnicas descritas, se puede detectar cuándo un paciente perteneciente a un determinado clúster está relativamente cerca de otro compuesto por pacientes etiquetados como “frágiles” o donde un clúster con un paciente “robusto” estaba relativamente cerca de otro que contenía pacientes “pre-frágiles”.

Esto permitiría crear una alerta que haga que los profesionales sanitarios hagan un seguimiento más continuo a este paciente que está en “riesgo” de formar parte de un grupo de pacientes frágiles, e intentar evitarlo.

En cuanto a los resultados obtenidos en los estudios de evolución temporal se observa una alta variabilidad de los datos recopilados de cada paciente mes a mes lo que hace que, sobre todo en el estudio que incluye las variables físicas y los resultados de los cuestionarios, las pertenencias a los diferentes clústeres de cada paciente sean también muy variables.

En el caso de los pacientes en los que se observa una menor variabilidad en los datos mes a mes, se aprecia que los cambios de pertenencia a los clústeres varían en torno a uno o dos tipos de clústeres a lo largo del tiempo. Esto también se ha visto que está relacionado con la cercanía de los centroides de dichos clústeres durante ese periodo de tiempo. Por tanto, se podrían unificar los clústeres percibidos como similares según la distancia del coseno entre sus centroides y así tener un menor número de grupos y que estos no sean tan homogéneos y restrictivos.

Análisis de series temporales univariable

Tras el preprocesado adecuado para poder tratar los datos con estas técnicas, se ha llevado a cabo una revisión de los datos considerando su evolución temporal.

Un ejemplo de los datos recogidos y analizados con este enfoque se puede ver en las siguientes gráficas:

A continuación, en la Figura 9, Figura 10 y Figura 11 se muestran capturas de la actividad de los latidos medios, mínimos y máximos para cada intervalo de 30 minutos a lo largo de una semana, entre el 13 y el 20 de febrero.




Figura 9: Media de latidos por minuto (BPM) cada 30 minutos del paciente 30 entre el 13 y el 20 de febrero de 2023. Eje X: Tiempo, Eje Y: BPM medio por 30 minutos

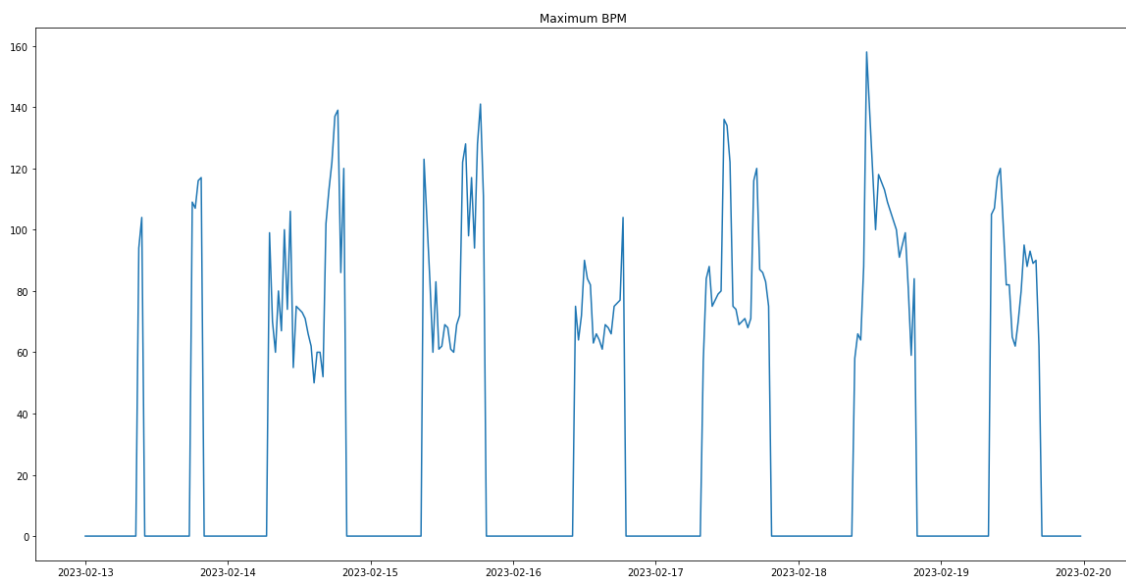


Figura 10: Valor máximo de latidos por minuto (BPM) cada 30 minutos del paciente 30 entre el 13 y el 20 de febrero de 2023. Eje X: Tiempo, Eje Y: BPM máximo por 30 minutos




Figura 11: Valor mínimo de latidos por minuto (BPM) cada 30 minutos del paciente 30 entre el 13 y el 20 de febrero de 2023. Eje X: Tiempo, Eje Y: BPM mínimo por 30 minutos

Se han aplicado, a estos conjuntos de datos diferentes modelos y redes neuronales (SARIMA, LSTM) para tratar de predecir el comportamiento.

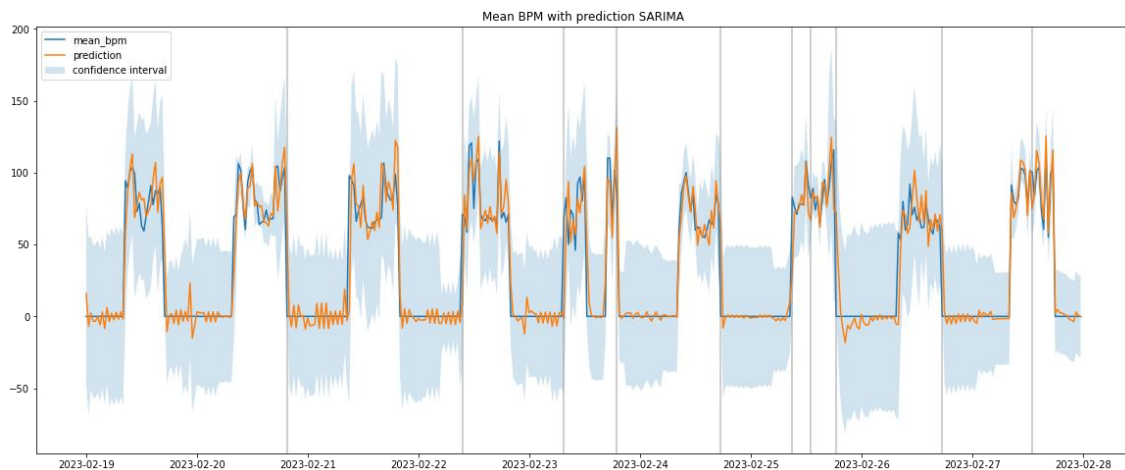


Figura 12: Media de latidos por minuto (BPM) cada 30 minutos del paciente 30 entre el 19 y el 28 de febrero de 2023. Eje X: Tiempo, Eje Y: BPM medio por 30 minutos (azul), predicción de SARIMA (naranja) e intervalo de confianza de SARIMA (sombreado). Las líneas verticales corresponden a las anomalías detectadas.




Figura 13: Media de latidos por minuto (BPM) cada 30 minutos del paciente 30 entre el 19 y el 28 de febrero de 2023. Eje X: Tiempo, Eje Y: BPM medio por 30 minutos (azul), predicción de LSTM (naranja). Las líneas verticales corresponden a las anomalías detectadas

Como se puede observar, los modelos de aprendizaje automático son capaces de predecir con alta precisión los comportamientos esperados y en consecuencia, determinar cuando se produce una situación anómala.

No obstante, y debido a la alta variabilidad de los datos, no se ha podido identificar una causa significativa de las anomalías.

Análisis de series temporales multivariable

Para el análisis de series temporales multivariables, tratando de determinar las correlaciones esperadas entre diferentes variables, se ha seguido un enfoque similar al anterior.

La correlación entre estas series es presumiblemente muy alta en todas las ventanas temporales dado que se extraen de una misma medida que es el ritmo cardíaco. Por esta razón, utilizando medidas estadísticas se podrán capturar los momentos en los que esta correlación disminuye significativamente. Se pueden analizar así los cambios inesperados en las series correspondientes con el objetivo de encontrar si puede haberse producido un comportamiento del paciente que deba ser motivo de alerta.

Como ejemplo de este enfoque podemos centrarnos en el ritmo cardiaco mínimo y medio como se ve en las siguientes gráficas:

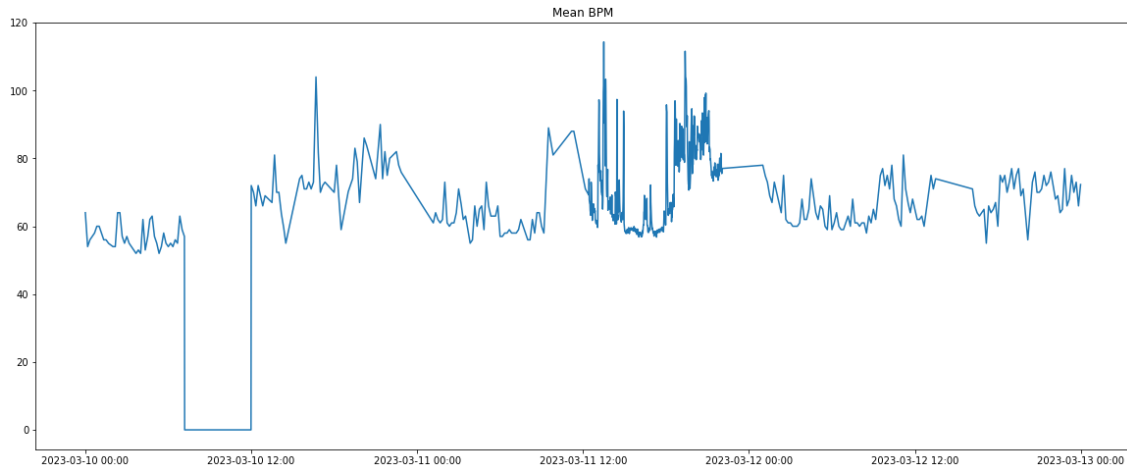


Figura 14: Media de latidos por minuto (BPM) cada minuto del paciente 34 entre el 10 y el 13 de febrero de 2023. Eje X: Tiempo, Eje Y: BPM medio por minuto




Figura 15: Valor mínimo de latidos por minuto (BPM) cada minuto del paciente 34 entre el 10 y el 13 de febrero de 2023. Eje X: Tiempo, Eje Y: BPM mínimos por minuto

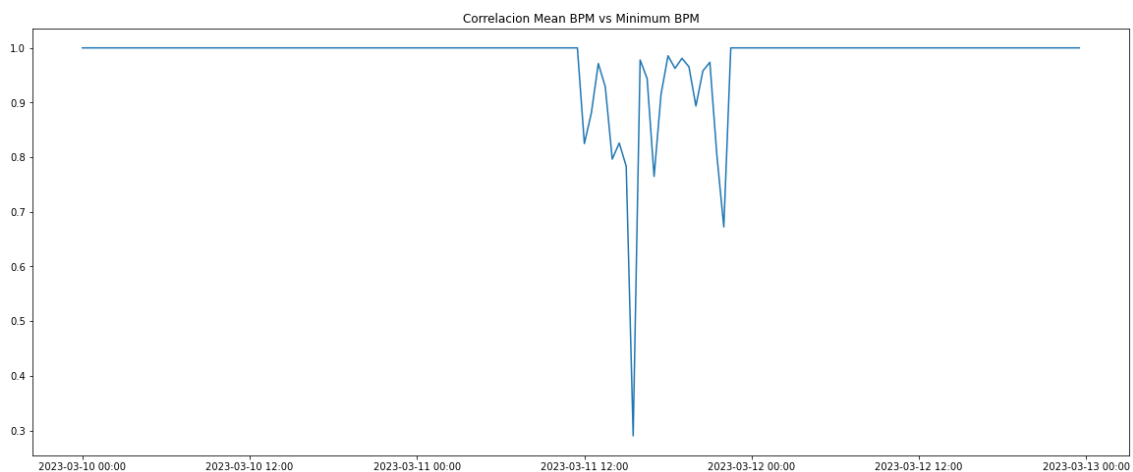


Figura 16: Correlación entre las variables BPM Medio y BPM Mínimo. Dichas variables, procesadas por minuto, se han dividido en segmentos de 30 minutos y se ha calculado la correlación entre cada par de esos segmentos, dando lugar a la serie de correlación que se muestra en la imagen. La correlación toma valor 1 cuando las series se comportan exactamente de la misma forma, -1 cuando el comportamiento es exactamente inverso, y 0 cuando no existe relación entre el comportamiento de ambas.

Al ver la comparación entre las diferentes series temporales, podemos identificar una pérdida de correlación no esperada, y que puede resultar significativa a la hora de identificar determinadas condiciones.

Resultados de los análisis en series temporales

Al analizar las series temporales desde la perspectiva univariadas, observamos que el comportamiento de las series que se intentan modelizar es altamente variable y, aunque sí que se pueda observar cierta periodicidad en sus valores, los mencionados cambios notables entre días afectarán negativamente a la capacidad de aprendizaje de los modelos, propiciando que las posibles alertas extraíbles se deban más a esta variabilidad que a posibles comportamientos que conlleven algún riesgo, aunque es posible que los modelos utilizados lleguen a predecir el comportamiento con bastante precisión, la variabilidad hace que no se pueda asociar las desviaciones a situaciones concretas que deban ser tratadas de alguna forma especial.

En el caso de las series temporales multivariadas, atendiendo a la correlación entre ambas, se observan momentos en los que esta correlación disminuye muy significativamente. Haciendo un estudio de la toma de datos del smartwatch en esos instantes, observamos que las caídas más pronunciadas en la correlación corresponden con momentos en los que la función de actividad del smartwatch está activada. Esta función hace que la toma de datos pase a ser de menos de una medida por minuto a aproximadamente una por segundo, lo cual genera una variabilidad mucho mayor en los datos que cuando no está activada.

Dado este comportamiento, los posibles cambios en la correlación entre los BPM medios, mínimos y máximos, que podrían ser motivo de alerta en algunos contextos, quedan enmascarados. No obstante, se observa que dentro del tiempo en el que dura la caída en la correlación, el decrecimiento más pronunciado coincide con el cambio más notable entre las series de BPM medios y mínimos.

Este estudio queda así limitado por la alta variabilidad en la toma de datos entre diferentes instantes. Siendo cierto que los momentos en los que se tienen muchos datos proporcionan una mayor información, para la realización de este análisis interesaría que la toma de datos tuviese un carácter más constante, disminuyendo el tiempo entre medidas cuando no está activada la función de actividad, para ser capaces de observar los cambios en la correlación también en esos momentos. De este modo, se tendría una descripción uniforme y constante del estado de cada paciente, pudiendo así mejorar la detección de cambios significativos en el comportamiento para prevenir o detectar prematuramente empeoramientos en la salud.

Conclusiones y futuras líneas de trabajo

La aplicación de diferentes técnicas de aprendizaje automático y de análisis estadístico avanzado de datos de personas frágiles obtenidos de fuentes heterogéneas, tales como valoraciones clínicas, cuestionarios de autopercepción o wearables y dispositivos IoT puede producir resultados que ayuden a predecir situaciones anómalas en la condición de fragilidad de las personas y colaborar en la prevención del empeoramiento.

En este sentido, los análisis estadísticos uni- y multivariantes han sido capaces de detectar condiciones que, efectivamente eran reportadas por los pacientes como empeoramiento de su condición o la aparición de determinadas condiciones (dolores físicos, ataques de ansiedad, vacaciones, ...)

Por otro lado, los análisis de series temporales no arrojan grandes resultados debido a la gran variabilidad observada. No obstante, sí parece necesario un análisis más detallado de las pérdidas de correlación entre variables, ya que puede ser un indicador de alguna condición reseñable.

Finalmente, el análisis por agrupación nos indica que los grupos resultados de los test estándar no se identifican fácilmente con las agrupaciones de variables físicas medidas. Esto puede deberse tanto a la variabilidad como al tamaño de la muestra, que no permite una agrupación más clara, dejando en muchas ocasiones clústeres de un único miembro.

Limitaciones

Los datos biomédicos provienen de un smartwatch, que generalmente opera como una "caja negra" en términos de su funcionamiento interno. Esto significa que no se tiene un control directo sobre la calidad y precisión de las mediciones, ni se pueden realizar ajustes o calibraciones específicas. La exactitud de las mediciones biomédicas del smartwatch puede variar según la marca y el modelo, lo que introduce una fuente futura de riesgo.

Debido a la falta de acceso a los algoritmos y procesos internos del smartwatch, no es posible verificar o ajustar los métodos utilizados para recopilar y procesar los datos biomédicos. Esto puede influir en la fiabilidad y consistencia de los datos.

Los smartwatches a menudo recopilan datos biomédicos de manera intermitente o en intervalos irregulares, en lugar de proporcionar mediciones continuas. Esta falta de uniformidad en la frecuencia de las mediciones puede limitar la precisión de la detección de cambios y dificultar la interpretación de los resultados. La falta de mediciones continuas puede hacer que se pierdan eventos o cambios importantes en los valores biomédicos. Esto puede llevar a la incapacidad de correlacionar los cambios detectados con eventos clínicos específicos.

Aunque se utilizan notas escritas de revisiones médicas para validar las anomalías detectadas, la falta de datos contextuales detallados sobre el estado de salud general del paciente y su historia clínica puede limitar la interpretación de los resultados. La información sobre eventos no registrados en las notas médicas podría pasar desapercibida. Además, las notas médicas pueden estar sujetas a sesgos, omisiones o inconsistencias en la documentación de los eventos de salud. La calidad y la cantidad de información en las notas médicas pueden variar entre pacientes y profesionales de la salud.

Dado que el estudio se basa en observaciones y análisis retrospectivos de datos, es difícil establecer una relación causal definitiva entre los cambios en los valores biomédicos y los eventos de salud del paciente. Otros factores no observados podrían contribuir a las anomalías detectadas.