

Dynamic Pain Analysis and Prediction of Chronicity Using Physiological Signals

Análisis Dinámico del Dolor y Predicción de la Cronificación mediante Señales Fisiológicas

José Manuel Moreno Loera^{* 1}, Juan Manuel López Hernández¹, José Manuel López Villagómez¹, and José Francisco Estrada Segura¹

¹ Universidad de Guanajuato, Campus Irapuato Salamanca
Avenida Universidad, S/N, Col. Yacatitas, Yuriria, Guanajuato, México, 38944.
{jm.morenoloera,jmlopez, jm.lopezvillagomez, jf.estradasegura}@ugto.mx

Abstract

This project aims to discover those characteristics that are most significant and sensitive to pain, helping to predict, with greater accuracy and low computational cost, a possible chronification of pain based on the physiological changes corresponding to different intensity levels of the acute stage, using the differences between pain levels in the BioVid Heat Pain database to simulate a chronification of pain through linear regression, and classifying them with a Random Forest to obtain the most representative features of chronic and acute pain. A prediction accuracy of 94% was obtained using only 14 features extracted from Electrocardiogram (ECG) and Galvanic Skin Response signals, thanks to the robustness against overfitting in small data samples that Support Vector Machines handle.

Keywords— Pain, GSR, Chronification

Resumen

Este proyecto pretende descubrir aquellas características más significativas y sensibles al dolor, que ayuden a predecir con más exactitud y con un bajo costo computacional, una posible cronificación de dolor basándose en los cambios fisiológicos respecto a los diferentes niveles de intensidad de la etapa aguda, utilizando las diferencias entre los niveles de dolor de la base de datos BioVid Heat pain para simular una cronificación del dolor con la regresión lineal y clasificándolas con un Random Forest para obtener las características más representativas del dolor crónico y agudo. Obteniendo una precisión del 94% de predicción mediante solo 14 características obtenidas de las señales de Electrocardiograma y de la Respuesta galvánica de la Piel, gracias a la robustez hacia el sobreajuste en pequeñas muestras de datos que las Maquinas de Soporte Vectorial manejan.

Palabras clave— Dolor, GSR, Cronificación

I. Introducción

El dolor se puede interpretar como alteraciones físicas involuntarias como movimientos repetitivos y semi-involuntarios sin un claro propósito y que pueden repetirse de manera idéntica en cada ocasión, indicando que algo se encuentra mal dentro del cuerpo

humano o fuera en el entorno de este [1]. Además, que suele ser una experiencia de carácter subjetivo dependiendo del grado de dolor que una persona puede tolerar. Sin embargo, existe la posibilidad de realizar mediciones objetivas y no tan invasivas del dolor mediante biosensores combinados con técnicas de Aprendizaje Automático (Machine Learning, ML por sus siglas en inglés) [2], utilizando las señales fisiológicas derivadas de la actividad

*Corresponding author

del corazón como lo son el electrocardiograma (ECG), la variabilidad de la frecuencia cardiaca (VFC), presión del volumen sanguíneo (PVS), fotoplethysmografía (Photoplethysmography, PPG por sus siglas en inglés) o la señal fisiológica llamada respuesta galvánica de la piel (Galvanic Sking Response, GSR por sus siglas en inglés), la cual refleja cambios en la conductancia eléctrica de la piel mediante las glándulas sudoríparas, gracias a que se sabe que el dolor implica procesos cognitivos y qué es posible medir estos con señales fisiológicas [3].

Todas estas respuestas fisiológicas son controladas por el sistema nervioso simpático, el cual se encarga de preparar al cuerpo para acciones de respuestas rápidas ante situaciones que causen estrés o se perciban como peligrosas, siendo las señales fisiológicas la manera en la que nuestro cuerpo reacciona ante los estímulos del entorno.

Nayely Vianey Salazar Trujillo, la coordinadora del Grupo de Cuidados Paliativos del Seminario de Estudios sobre la globalidad en Pregrado de la Facultad de Medicina de la UNAM [4], mencionó que existen dos categorías fundamentales de dolor: el dolor agudo y el dolor crónico. Define que el dolor agudo es consecuencia de un daño tisular específico y su duración por lo general suele ser de menos de tres meses, cesando una vez la lesión o causa que la origina deja de producirse. Mientras que el dolor crónico se extiende de tres a seis meses, volviéndose independiente de su causa, la cual surgió como un dolor agudo desde el principio, convirtiéndose en un dolor relacionado a una posible enfermedad crónica de dolor continuo, o el dolor se vuelve episódico durante lapsos largos. Durante esta transición el sistema nervioso autónomo sufre una serie de cambios neurofisiológicos y autonómicos (alteraciones en la VFC, reactividad simpática y regulación emocional). Por lo que, analizar las diferencias entre los momentos de dolor agudo y no dolor nos permite observar cómo es que el organismo responde a estímulos nociceptivos (estímulos potencialmente dañinos para los tejidos), y determinar si la respuesta muestra patrones de disfunción o desadaptación, siendo indicativos de un riesgo de cronificación.

Diferenciar entre un dolor crónico y uno agudo puede ser clave para la salud del paciente ya que, de acuerdo con el Instituto Nacional de Geriatría [5], en 2018 realizó una investigación dónde estimaron que cuatro de cada diez personas mayores en México sufren de dolor crónico y más de la mitad de las personas que fallecieron dentro del país registraron un dolor crónico en su último año de vida. Además de que un reciente estudio realizado por científicos en Reino Unido comprobó que el dolor crónico puede aumentar el riesgo de padecer presión arterial alta [6]. Analizaron casos de 206,000 adultos de entre 40 a 69 años durante 13 años, si bien las respuestas fueron mediante autoevaluación y de una sola vez, pudieron relacionar que el dolor crónico generó depresión en los

pacientes, y a su vez la depresión permitió que desarrollaran presión arterial alta, donde el 10 % de ellos desarrolló hipertensión. A su vez detectaron que el dolor afectaba de diferente manera dependiendo de su localización en el cuerpo, descubriendo que el dolor crónico distribuido por todo el cuerpo se asoció a un 75 % más de riesgo de desarrollar presión arterial alta comparado con los que no presentaron dolor, mientras que el dolor concentrado en el abdomen incrementa el riesgo solo en un 43 %.

En 2019, la Organización Mundial de la Salud (OMS) realizó la actualización de la Clasificación Internacional de Enfermedades (CIE-11), dónde el dolor crónico se clasificó en siete grupos [7]:

1. Dolor crónico primario: Se caracteriza por una dis-capacidad funcional (interferencia en las actividades de la vida diaria) o estrés emocional no explicable, planteándose como una enfermedad por sí misma.
2. Dolor crónico por cáncer: Siendo un dolor propio del cáncer o que se origina por el tratamiento para combatirlo.
3. Dolor crónico postquirúrgico o postraumático: Aparece o aumenta luego de un procedimiento quirúrgico que puede persistir más allá del proceso de curación.
4. Dolor crónico neuropático: Aparece cuando se presenta una lesión o enfermedad en el sistema nervioso somatosensorial (a nivel periférico o central). Presentando una reacción exagerada a un estímulo doloroso (hiperalgesia), o una reacción dolorante ante un estímulo que no debería causar dolor (alodinia).
5. Dolor bucofacial o cefalea: Malestares ubicados en la cara y que lastiman la cavidad oral por falta de limpieza o daños en las estructuras que conectan la mandíbula. Con una duración de al menos 2 horas por día.
6. Dolor visceral crónico: De origen dudoso y se desarrolla en los órganos internos de las cavidades torácica, abdominal y pélvica, además de la región de la cabeza o cuello.
7. Dolor crónico musculoesquelético secundario: Dolor que surge de los huesos, articulaciones, músculos, columna vertebral, tendones o tejidos blandos. Producido por espontaneidad o por un movimiento.

Tomando en cuenta el grupo 2 de la CIE-11, en otro estudio que se realizó a pacientes con cáncer [8] se demostró que, mientras la enfermedad progresaba, el dolor también lo hacía, generando un dolor constante, e irónicamente el dolor ayudaba a empeorar la salud del paciente, no solo por la enfermedad si no por el dolor en sí.

El síndrome de Takutsubo o síndrome del corazón roto es una cardiompatía aguda que se caracteriza por el repentino y temporal debilitamiento del músculo del corazón, debido a estrés emocional o físico y que causa dolor en el pecho [9], este síndrome es bastante peligroso, así

como el dolor torácico no traumático, el cual es una de las razones más frecuentes de visitas médicas de emergencia, que podría bien desencadenar en una isquemia cardíaca, la cual es causada por la reducción del suministro de sangre al corazón [10]. En este caso, el dolor torácico perteneciente al grupo 6 de la CIE-11 se caracteriza por episodios recurrentes del mismo, originando un dolor crónico conocido como angina de pecho estable, y que desaparece durante el reposo o administración de medicamentos. En casos como la isquemia cardíaca es importante el tiempo de reacción para tratarla, y para ello es preciso detectar lo antes posible sus patrones ya conocidos, dónde visualmente se sabe que durante cualquier tipo de esfuerzo físico, estrés o frío aparece el dolor torácico, mientras que mediante la señal fisiológica de ECG se pueden apreciar igualmente patrones típicos como el descenso del segmento ST (1-3 mm) de la señal durante el esfuerzo físico, o la inversión simétrica de la onda T después de la experiencia. Esto por mencionar un ejemplo de lo que el dolor crónico podría ocasionar ya que, si no se trata, el dolor agudo puede convertirse en dolor crónico.

Estudios previos han desarrollado sistemas que incorporan señales fisiológicas multimodales, incluyendo videograbs de las expresiones faciales de los participantes [11, 12], el problema de estos sistemas es su poca practicidad a la hora de implementarlos en los entornos cotidianos. Derivado de esto, se buscó una manera menos invasiva pero igualmente eficiente, destacando las señales ECG y GSR por su fácil incorporación a dispositivos portátiles más ergonómicos para el usuario como los relojes inteligentes Google Pixel Watch 2 y 3 [13], los cuales ya pueden medir el pulso cardiaco en la muñeca y la actividad electrodérmica (EDA) de la piel, la cual incluye ya a las señales GSR. Además, en [14] utilizaron las señales ECG, GSR y las Electromiografías (EMG) utilizando también la base de datos BioVid, construyeron diferentes modelos de Machine Learning, incluidos el modelo de Regresión Lineal, Regresión de Soporte Vectorial (RSV), Redes Neuronales y el de Aumento Extremo de Gradiente. Esto con el fin de seleccionar el modelo que mejor pudiera predecir la intensidad del dolor dentro de los 4 niveles que la base Biovid maneja, obteniendo los mejores resultados con el modelo de RSV utilizando solo 3 características de las señales GSR, que fueron las que más información importante proporcionaron para la estimación de los niveles de intensidad. Logrando entre todos los resultados, un error medio absoluto (Mean Absolute Error, MAE por sus siglas en inglés) de 0.93.

La mayoría de los trabajos realizan una clasificación binaria [15], es decir, dolor o no dolor, limitando el fenómeno gradual y subjetivo que es el dolor, sin capturar como es que el dolor evoluciona con el tiempo ni su posible transición hacia la cronificación. Estudios previos han

demostrado que, durante el dolor agudo, la frecuencia cardíaca aumenta y la amplitud del PPG disminuye [16], obteniendo una sensibilidad (o recall en inglés) del 60 % y en especificidad (verdaderos negativos) un 72 %.

En sujetos sin cronificación, se espera que a mayor intensidad de dolor haya un cambio fisiológico que sea proporcional, dónde el sistema nervioso reacciona a cada incremento del estímulo de dolor. Pero en el caso contrario de que una persona presente una posible cronificación, significa que los cambios fisiológicos dejaron de responder a las variaciones de intensidad, interpretándose como una desensibilización central, dónde el sistema nervioso se mantiene en un estado constante de activación, sin importar si el estímulo incrementa o no.

Por lo que en este trabajo de investigación busca encontrar las características que mejor describan la relación entre las características fisiológicas y el dolor, mediante la regresión lineal. Para posteriormente descubrir las características más determinísticas durante el proceso de dolor agudo como del dolor crónico mediante un algoritmo más complejo para características no tan lineales como lo es el Random Forest, que se ha demostrado relaciona de una manera eficiente señales fisiológicas con respuestas cognitivas [17]. Y finalmente evaluar con una Maquina de Soporte Vectorial (Support Vector Machine, SVM por sus siglas en inglés) para evitar las redundancias ya que las SVM controlan mejor el sobreajuste que se pudiera dar por la pequeña cantidad de los datos.

II. Metodología

Para el análisis de los diferentes grados de dolor, así como de la simulación de una posible cronificación, se utilizó la base de datos BioVid [18]. Este conjunto de datos se compone de 87 sujetos de entre 18 – 65 años, seleccionados mediante un proceso que contempló que cumplieran con un buen estado de salud, principalmente que no tuvieran alguna enfermedad dermatológica, neurológica y sin trastornos del dolor crónico, no tomar medicamentos que alteraran la percepción del dolor, no consumir alcohol antes de la sesión, tener piel íntegra en la zona del antebrazo donde se aplicaría el calor, y claramente ser voluntario, además de firmar en consentimiento informado aprobado por el comité de ética de la Universidad pública Alemana Ulm. Además, se excluyeron casos en dónde el sujeto padecía de diabetes, problemas cardiovasculares importantes, enfermedades psiquiátricas graves, piel sensible, problemas de termorregulación o fiebre, o que tuviera algún historial de epilepsia.

A los participantes se les indujo dolor mediante calor en el antebrazo derecho controlado por un termómetro Peltier, en este caso el Thermodate TSA-II. El protocolo consistió en identificar primeramente el nivel térmico de cada participante antes de comenzar el registro de

la base de datos, en donde cada participante evaluó el dolor que sentían en ciertas temperaturas para ajustar las mismas mediante un método de calibración adaptativa. Logrando así una compensación para la sensibilidad de cada individuo, es decir, adaptar los distintos niveles de temperatura a nivel individual para provocar la misma intensidad de dolor en todos los participantes, y así evitar un posible daño tisular en algún sujeto que soportase un menor grado de temperatura que otro. Obteniendo 4 niveles de intensidad (PA1 – PA4, y BL1) de entre 32 – 48°C dependiendo de los participantes, pero sin ser peligroso o intolerable, PA1 que representa la menor intensidad de dolor, seguido de PA2, PA3 y PA4, dónde este último representa la intensidad más alta de dolor, además cuenta con una línea base tomada como cero inducciones de dolor llamada BL1. Cada intensidad de dolor fue estimulada 20 veces durante 4 segundos de calor aplicado y pausas de 8 a 12 segundos, utilizadas para extraer BL1. La intensidad de dolor se designó a partir de una autoevaluación a los sujetos previamente, para determinar el umbral de tolerancia al dolor soportada por cada uno, evitando así daños perjudiciales. La base de datos se compone de 4 partes (A, B, C, y D), en dónde la obtención de datos que se midieron fueron las señales fisiológicas EEG, ECG, GSR, además de videogramaciones de las expresiones faciales de los sujetos, entre otras señales fisiológicas más, pero para el desarrollo de este trabajo, solo se utilizaron las señales ECG y GSR de la parte A del conjunto de datos, así como estudios previos la han utilizado [11, 19].

II.1. Extracción de características

Se extrajeron las características principales de ECG más representativas del índice parasimpático RMSSD, PNN50, SDNN [3], entre otras. Así como también de la señal GSR a cada sujeto de manera individual.

Además, se utilizaron las 22 características canónicas de series de tiempo llamadas Catch22 [20], extraídas de una librería extensa llamada hctsa con 7,658 características de series de tiempo posibles, siendo las 22 características más relevantes que capturan las propiedades más importantes de datos temporales, como la autocorrelación, distribución de valores y patrones de fluctuación. Utilizando estas características para representar de manera más compacta y útil para tareas de clasificación, agrupamiento o detección de anomalías, además de que genera un menor coste computacional. Evaluaron el desempeño individual de cada característica de que tan bien permite distinguir clases, evaluadas en 93 conjuntos de datos diferentes de la base UEA/UCR obteniendo así un criterio general.

Las señales GSR, a diferencia de las señales ECG tienen una dinámica lenta y transitoria, es perfecta para aplicarse directamente las 22 características canónicas de

series de tiempo por lo que se ha decidido utilizar estas características específicamente para esta señal.

II.2. Regresión Lineal Y Random Forest

Puesto que se quiere observar si el modelo es capaz de detectar una posible falta de adaptabilidad al dolor (cronificación), se utiliza un método de regresión lineal entre las derivadas temporales (deltas) de los 4 niveles de dolor principales (PA1, PA2, PA3 y PA4), esto con el fin de simular una tendencia a una posible cronificación.

Debido a que la ausencia de la relación lineal entre los incrementos de la intensidad del dolor y las variaciones fisiológicas, se interpretan como una disminución de la sensibilidad del sistema nervioso autónomo ante los estímulos nociceptivos. Por lo que el patrón plano con tendencia a cero que se aprecia en la Figura 1, sugiere una posible cronificación del proceso de dolor, ya que las respuestas fisiológicas dejan de ajustarse ante la percepción del dolor.

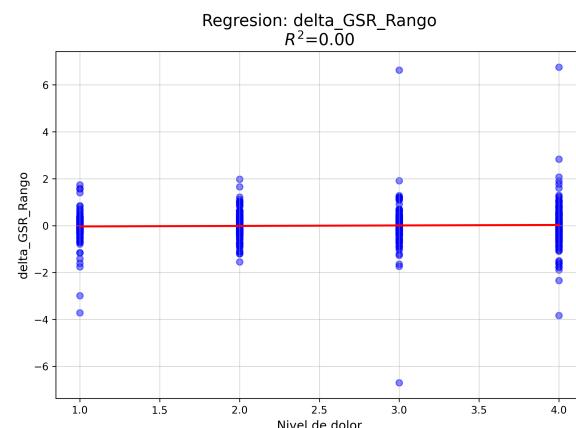


Figura 1: Regresión Lineal aplicada a las diferencias entre los niveles de dolor (PA4-PA3, PA3-PA2, PA2-PA1, PA1-BL), determinando no linealidad, es decir igual a falta de adaptabilidad al dolor.

Todas las características utilizadas, sin excepción demostraron estar tendencia a cero, sin embargo, como se aprecia en la Figura 2, se obtuvo una lista de características de las señales más sensibles al dolor mediante el método de la Importancia basada en Reducción de Impureza de Random Forest, el cual toma cada característica (RMSSD, SDNN, etc) por separado en sus nodos, las divide utilizando la medida Gini Impurity determinando que tantas mezclas de clases o impurezas hay en el nodo, para conseguir el nodo más puro posible o que separe mejor las clases con cada división. A pesar de no representar una importancia bastante alta (el valor 1.0 se toma como el más alto en la gráfica y por ende significa que hay una relación bastante directa, pero en la Figura 2 se aprecia que el valor máximo alcanzado es 0.04), aún logran captar diferencias sutiles en las etapas de dolor.

Otorgando la mayor información posible dentro de un sistema con poca variabilidad fisiológica.

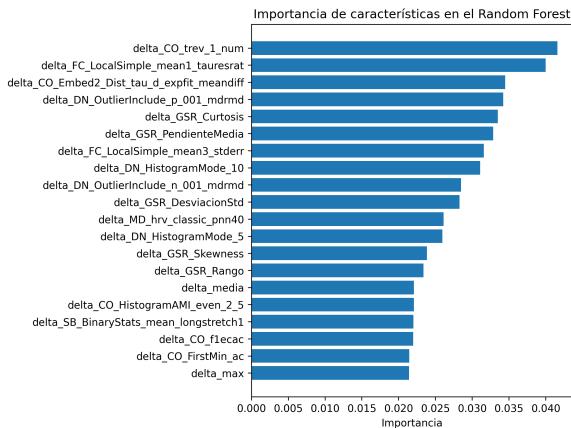


Figura 2: Lista de características más sensibles al dolor crónico.

El mismo procedimiento se realizó con las diferencias entre los niveles de dolor y no dolor (baseline). Detectando una tendencia entre cada uno, mostrado en la Figura 3.

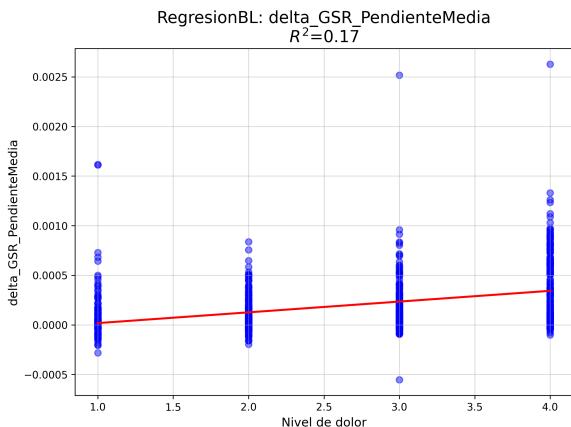


Figura 3: Regresión Lineal aplicada a los niveles de dolor respecto al baseline (PA4-BL1, PA3-BL1, PA2-BL1, PA1-BL1) demostrando la linealidad de cero dolor a las diferentes intensidades, demostrando el dolor agudo.

En esta etapa si existe una relación lineal clara, demostrando la diferencia de cada nivel de dolor, posteriormente se aplicó un Random Forest para obtener las características de manera no lineal que mejor representan esta etapa, buscando las mismas o la mayoría de las características que se obtuvieron en la Figura 2. Obteniendo las siguientes características de la Figura 4.

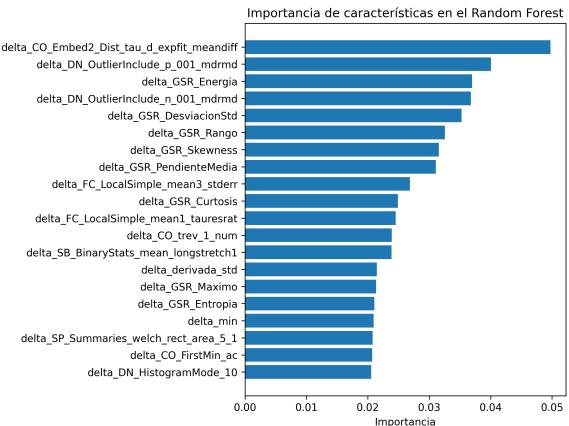


Figura 4: Lista de características más sensibles al dolor agudo.

III. Resultados

Se puede apreciar que tanto en la Figura 2 como en la Figura 4 existen ciertas características similares dentro de las 20 más relevantes, aunque con diferente nivel de importancia. En la Tabla 1 se colocaron las características compartidas por ambas clases de dolor que se encuentran tanto en la Figura 2 como en la Figura 4, con el fin de utilizar esas características para clasificar correctamente ambas clases de dolor, ya que son las que presentaron un nivel de sensibilidad más alto.

Tabla 1: Características compartidas

Num	Agudo y Cronificación
1	delta_CO_trev_1_num
2	delta_FC_LocalSimple_mean1_tauresrat
3	delta_CO_Embed2_Dist_tau_d_expfit_meandiff
4	delta_DN_OutlierInclude_p_001_mdrmd
5	delta_GSR_Curtosis
6	delta_GSR_PendienteMedia
7	delta_FC_LocalSimple_mean3_stderr
8	delta_DN_HistogramMode_10
9	delta_DN_OutlierInclude_n_001_mdrmd
10	delta_GSR_DesviacionStd
11	delta_GSR_Skewness
12	delta_GSR_Rango
13	delta_SB_BinaryStats_mean_longstretch1
14	delta_CO_FirstMin_ac

El comportamiento de las 14 características en ambos estados es diferente, en el dolor agudo, suelen comportarse con transiciones rápidas y asimétricas, picos altos, varianza elevada. Mientras que en el dolor crónico son fluctuaciones más lentas y menos asimétricas, de activación sostenida, presenta menos picos, períodos planos más largos y patrones repetitivos.

Dando la pauta para analizar específicamente esas listas y determinar si existe cronificación o no. Además de demostrar que la señal GSR es mucho más relevante que la ECG, por lo que el sistema puede simplemente

utilizar la señal GSR, reduciendo el costo computacional de manera eficiente.

Por lo tanto, al encontrar las mismas características con valores distintivos cuando es un dolor agudo o cuando es un dolor crónico, se obtiene la ventaja de que, al analizar las características, estas serán las mismas siempre, por ello se tomaron las 14 características compartidas de la Tabla 1 para evaluar su predicción a pesar de sus bajos puntajes de importancia.

En [15] se realizó un marco de trabajo multimodal utilizando también solo señales EDA y ECG, el cual incluye un proceso combinado de los modelos de Redes Convolucionales Completas y Memoria a Corto y Largo plazo (Long Short-Term Memory, LSTM por sus siglas en inglés) con mecanismo de atención. Consiguiendo una precisión del 87.52 % utilizando la base Biovid, pero solo comparando de manera binaria entre No dolor y Dolor intenso. Si bien no se menciona las características que los llevaron a obtener esos resultados, [14] analizó las 3 mejores características de EDA o GSR que le otorgaron su mejor predicción otorgándole un 83.30 % de precisión, las cuales también obtuvimos dentro de las más importantes:

1. delta_CO_EMBED2_Dist_tau_d_expfit_meandiff.
2. delta_DN_OutlierInclude_p_001_mdrmd.
3. delta_DN_OutlierInclude_n_001_mdrmd.

III.1. Evaluación con SVM

Para determinar si las características pueden separar de manera correcta el dolor agudo del dolor crónico, se propuso como evaluador el modelo de SVM, separando los datos de entrenamiento a 80 % y prueba 20 %, específicamente con las 14 características de la Tabla 1. Para ello las diferencias obtenidas previamente en la regresión lineal se juntaron en un mismo conjunto, conformando dos grupos compuestos por los mismos sujetos, unos pertenecientes al dolor crónico simulado y otros pertenecientes al dolor agudo detectado, tal como se muestra en el ejemplo de la Tabla 2.

Tabla 2: Conjunto de datos de dolor crónico y dolor agudo para entrenar el modelo SVM

Sujeto	Tipo
Sujeto01	Agudo
Sujeto01	Crónico
Sujeto02	Agudo
Sujeto02	Crónico

Al probar el rendimiento de la SVM se obtuvo un resultado bastante alto con el conjunto de pruebas del 20 %, que en este caso fueron 18 sujetos evaluados, resultando

en la matriz de confusión de la Figura 5, donde las filas conforman las clases verdaderas y las columnas las clases clasificadas, demostrando que el modelo logró clasificar 16 de 18 casos de dolor agudo correctamente y en el dolor crónico identificó correctamente a los 18 sujetos. Demostrando una sensibilidad del 88.9 % y especificidad del 100 % en la clase de dolor agudo y en la clase del dolor crónico se logró una sensibilidad del 100 % pero una especificidad del 88.9 % debido a los 2 falsos negativos que presentó la clase del dolor agudo. Los cuales pueden deberse a que las señales fisiológicas de esos dos participantes presenten picos fuera de lo común (outliers) y por ello sus respuestas no son similares a las del resto del grupo, tal como se mostró en la Figura 3, donde se puede apreciar que en los Niveles 1.0, 3.0 y 4.0 la característica GSR_PendienteMedia presenta una actividad más alta de un sujeto.

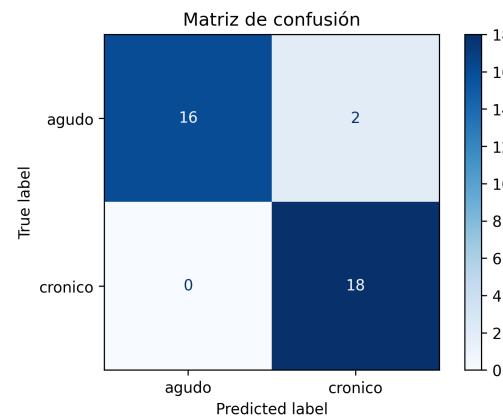


Figura 5: Matriz de confusión del desempeño del modelo SVM

En la Tabla 3 se muestra un desglose más específico de las métricas de nuestro modelo. Obteniendo una precisión de clasificación del modelo en general (accuracy) del 94 %.

Tabla 3: Desglose de las métricas que evaluan el desempeño del modelo SVM en el conjunto de prueba

Nombre	precision	Sensibilidad	Especificidad	F1-Score
Agudo	1.00	0.89	1.0	0.94
crónico	0.90	1.00	0.89	0.95
accuracy	0.94			

Mientras que en la Tabla 4 se comparan con los trabajos que mejores resultados han obtenido utilizando la base de datos Biovid para la detección del dolor agudo. En el

caso de [14], sus resultados no se dividen en Especificidad y Sensibilidad, por lo que solo podemos comparar la precisión (accuracy), además [15] realiza una comparación de otros modelos en su trabajo, siendo el suyo el que mejor resultados da con la combinación de señales ECG y GSR. Y en dónde nuestro modelo logró superarlo en el desempeño de predicción del dolor agudo.

Tabla 4: Comparación de resultados de trabajos

Referencia	Método	Accuracy	Sensibilidad	Especificidad	F1 Score
Pouromran	SVR	0.83			
Farmani	CrossMod Transformer	0.87	0.84	0.89	0.87
Este trabajo	SVM	0.94	0.89	1.0	0.94

IV. Conclusiones y Discusión

Se observó una mayor respuesta a la sensibilidad del dolor con las señales GSR, predominando más que las señales ECG, al igual que los trabajos presentados en la Tabla 4, dónde se utilizaron casi las mismas características, solo que en nuestro caso utilizamos 14 y no solo 3 lo que nos aportó más información a la hora de realizar la clasificación.

La regresión lineal nos permitió comprender y obtener de una manera más entendible la relación que las características desempeñan en cada etapa de dolor, además nos permitió crear un entorno de simulación para experimentar una cronificación simulada sin exponer a pacientes que sufren de dolor crónico real. Aunque en este trabajo no se realizó una discriminación por tipo de enfermedad crónica, es importante mencionar algunas de las relaciones que las características obtenidas tienen con algunas enfermedades, para tomar en cuenta en un posible trabajo futuro (Nota: el nombre de las características se sustituyó por el orden numérico de la Tabla 1):

1. Fibromialgia: Trastorno crónico que se caracteriza por el dolor muscular generalizado y la fatiga; los patrones que se presentan en algunas de las 14 características de acuerdo con [21] son:

- a) (10): variabilidad alta.
- b) (11): distribución menos simétrica.
- c) (1): asimetría en transiciones.

2. Artritis reumatoide: Enfermedad donde el sistema inmune ataca a las articulaciones; los patrones que

se presentan en algunas de las 14 características de acuerdo con [22] son:

- a) (6): tendencia estable pero sostenida.
- b) (8): valores basales elevados.
- c) (14): autocorrelación mayor (patrones repetidos).
- d) (13): segmentos largos estables.

3. Dolor lumbar crónico: Dolor que persiste en la parte baja de la espalda por más de 3 meses; los patrones que se presentan en algunas de las 14 características de acuerdo con [23] son:

- a) (10): variabilidad moderada.
- b) (11): distribución más simétrica (pocos picos).
- c) (6): tendencia suave.
- d) (1): transiciones menos abruptas.

Posteriormente al utilizar Random Forest, se logró una mejor clasificación de las características, ya que estas al provenir de sistemas biológicos regulados por retroalimentaciones múltiples, es decir, fluctuaciones caóticas causadas por variaciones de los latidos, ruido por movimiento o respiración de los participantes, no son lineales y son muy complejas, por lo que el modelo de Random Forest fue perfecto para este caso ya que cada árbol de decisión crea divisiones del espacio de las características basándose en umbrales. Lo que lo convierte en un método bastante robusto al ruido fisiológico.

Finalmente la inclusión de la SVM maximizó el margen entre las dos diferentes clases de dolor manejadas con las pocas características utilizadas, ayudando a identificar los cambios más sutiles de cada característica y evitando el sobre ajuste que se pudiera dar si se utilizaran otros modelos de clasificación que requieren de más muestras como el Random Forest, al cual se le entrenó con el conjunto de datos completo y nos simplificó a las pocas características que posteriormente la SVM se encargó de evaluar, esto con el fin de evitar posibles redundancias.

Si bien los resultados en general, son buenos, la muestra de 86 sujetos y el corto tamaño de las ventanas de tiempo de 5.5 segundos que nos proporciona la base de datos Biovid no son suficiente para poder generalizar características que son bastante subjetivas, por depender de la persona, su actividad física, su alimentación, su edad (ya que tanto la actividad cardíaca como la electrodérmica tienden a responder más lento a mayor edad), su temperamento, su resistencia mental al dolor, que si bien el rango de edad es bastante amplio (18 — 65 años) son muchas las variables que pueden influir en cada persona de cada edad, y tomando en cuenta que solo se obtuvieron datos de 86 sujetos, eso quiere decir que si se tuviera que tomar mínimo una persona de cada edad, máximo solo podrían evaluar a 2 personas por edad.

Aunado a lo anterior, también se tiene que tomar en cuenta que la muestra es obtenida de personas completamente sanas, por lo que un reto sería determinar a una persona con alguna enfermedad como diabetes, que suelen tener la presión alta.

Por lo que la propuesta a futuro sería utilizar este modelo entrenado en hospitales o clínicas particulares aprovechando el equipo de registro de señales ECG y GSR que manejan, para corroborar si el algoritmo detecta correctamente la clase a la que el paciente pertenece, pero enfocándonos en aquellos con un diagnóstico de dolor crónico, y dependiendo de la evaluación determinar si el modelo funciona, mediante el diagnóstico previo del propio paciente.

Si el modelo predice correctamente la presencia del dolor crónico, el siguiente paso consistiría en almacenar esas características extraídas del paciente para analizarlas más clínicamente y observar los cambios específicos en cada una de ellas, ampliando así el modelo para lograr predecir qué tipo de enfermedad crónica es la presentada, y no solo demostrar si existe cronificación o no. Sin embargo, en el caso de que el modelo no lograse detectar con precisión si se trata de un dolor crónico o agudo, se tendrá que contemplar crear una base de datos nueva ahora sí con pacientes reales que sufren de algún dolor crónico. Claramente se tendría que realizar un protocolo donde solo se monitorearán señales ECG y GSR, el cual contemplará realizar el proceso de obtención de datos mediante los propios instrumentos de las clínicas o mediante un reloj inteligente como el Google Pixel Watch, sin estímulos inducidos de manera artificial, solo realizar movimientos o acciones que, de ser posible, le intensifiquen el dolor y tomar esas muestras por un lapso de 10 minutos máximo dentro de la clínica o de ser posible, tomar una muestra de 24 horas de su día cotidiano para obtener más robustez y posteriormente presentar el protocolo ante un comité de ética, en el cual estos mismos pacientes que fueron evaluados erróneamente por el modelo puedan participar de manera voluntaria. En la Figura 6 se muestra a manera de diagrama de flujo, el procedimiento a llevarse a cabo para el posible trabajo a futuro.

Referencias

[1] P. Silva y R. Sebastião, «Using the Electrocardiogram for Pain Classification under Emotional Contexts,» Sensors, vol. 23, p. 1443, January 2023.

[2] B. D. Winslow, R. Kwasinski, K. Whirlow, E. Mills, J. Hullfish y M. Carroll, «Automatic detection of pain using machine learning,» Frontiers in Pain Research, vol. 3, November 2022.

[3] P. Nicolini, G. Malfatto y T. Lucchi, «Heart Rate Variability and Cognition: A Narrative Systematic Review

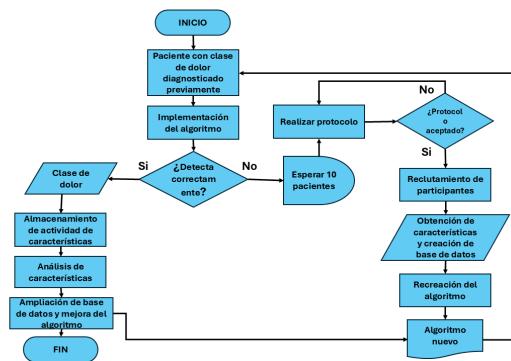


Figura 6: Diagrama de flujo de un posible trabajo futuro

of Longitudinal Studies,» Journal of Clinical Medicine, vol. 13, p. 280, January 2024.

[4] P. Herrera y D. Rojas, Dolor crónico, un problema subestimado - UNAM Global — unamglobal.unam.mx, 2024.

[5] «Boletín INGER - Diciembre 2018,» calameo.com. [Online]. Available: <https://www.calameo.com/read/00547996024f658fa5fec>

[6] P. Qin, F. K. Ho, C. A. Celis-Morales y J. P. Pell, «Chronic Pain and Hypertension and Mediation Role of Inflammation and Depression,» Hypertension, November 2025.

[7] OMS, Clasificación Internacional de Enfermedades Undécima Revisión (CIE-11), Ginebra: Organización Mundial de la Salud, 2022.

[8] S. Moscato, P. Cortelli y L. Chiari, «Physiological responses to pain in cancer patients: A systematic review,» Computer Methods and Programs in Biomedicine, vol. 217, p. 106682, April 2022.

[9] G. La Vecchia, L. Leo, A. M. Leone y R. A. Montone, «When chest pain is not what it seems: time for right diagnosis and right treatment—a case report,» European Heart Journal - Case Reports, vol. 9, August 2025.

[10] C. A. Swenne y C. C. ter Haar, «Context-independent identification of myocardial ischemia in the prehospital ECG of chest pain patients,» Journal of Electrocardiology, vol. 82, p. 34–41, January 2024.

[11] P. Werner, A. Al-Hamadi, R. Niese, S. Walter, S. Gruss y H. Traue, «Automatic Pain Recognition from Video and Biomedical Signals,» 2014.

[12] M. Kächele, P. Thiam, M. Amirian, P. Werner, S. Walter, F. Schwenker y G. Palm, «Multimodal Data Fusion for Person-Independent, Continuous Estimation of Pain Intensity,» de Engineering Applications of Neural Networks, Springer International Publishing, 2015, p. 275–285.

[13] Especificaciones técnicas de Pixel Watch 3, modelos de 45 mm y 41 mm. [Online]. Available: https://store.google.com/es/product/pixel-watch_3_specs?hl=es

- [14] F. Pouromran, S. Radhakrishnan y S. Kamarthi, «Exploration of physiological sensors, features, and machine learning models for pain intensity estimation,» PLOS ONE, vol. 16, p. e0254108, July 2021.
- [15] J. Farmani, G. Bargshady, S. Gkikas, M. Tsiknakis y R. F. Rojas, «A CrossMod-Transformer deep learning framework for multi-modal pain detection through EDA and ECG fusion,» Scientific Reports, vol. 15, August 2025.
- [16] D. F. Jhang, Y. S. Chu, J. H. Cai, Y. Y. Tai y C. C. Chuang, «Pain Monitoring Using Heart Rate Variability and Photoplethysmograph-Derived Parameters by Binary Logistic Regression,» Journal of Medical and Biological Engineering, September 2021.
- [17] T. Boljanić, N. Miljković, L. B. Lazarević, G. Knezević y G. Milašinović, «Relationship between electrocardiogram-based features and personality traits: Machine learning approach,» Annals of Noninvasive Electrocardiology, vol. 27, November 2021.
- [18] S. Walter, S. Gruss, H. Ehleiter, J. Tan, H. C. Traue, S. Crawcour, P. Werner, A. Al-Hamadi y A. O. Andrade, «The biovid heat pain database data for the advancement and systematic validation of an automated pain recognition system,» de 2013 IEEE International Conference on Cybernetics (CYBCO), 2013.
- [19] P. Werner, A. Al-Hamadi y S. Walter, «Analysis of facial expressiveness during experimentally induced heat pain,» de 2017 Seventh International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW), 2017.
- [20] C. H. Lubba, S. S. Sethi, P. Knaute, S. R. Schultz, B. D. Fulcher y N. S. Jones, «catch22: CAnonical Time-series CHaracteristics: Selected through highly comparative time-series analysis,» Data Mining and Knowledge Discovery, vol. 33, p. 1821–1852, August 2019.
- [21] G. A. Reyes del Paso y P. de la Coba, «Reduced activity, reactivity and functionality of the sympathetic nervous system in fibromyalgia: An electrodermal study,» PLOS ONE, vol. 15, p. e0241154, October 2020.
- [22] R. Badry, R. M. Gamal, M. M. Hassanien, M. A. El Hamed, N. Hammam y B. M. El Fawal, «Sympathetic skin response in patients with systemic sclerosis and rheumatoid arthritis,» The Egyptian Journal of Neurology, Psychiatry and Neurosurgery, vol. 54, November 2018.
- [23] A. Bonnet y J. Naveteur, «Electrodermal Responses to Words in Chronic Low Back Pain Patients: A Comparison Between Pain Descriptors, Other Emotional Words, and Neutral Words,» The Clinical Journal of Pain, vol. 22, p. 686–691, October 2006.