

## Máquinas de soporte vectorial enpredicción de falla cardíaca

María Dolores Torres Soto<sup>1</sup>, Aurora Torres Soto<sup>2</sup>

<sup>1</sup> Universidad Autónoma de Aguascalientes,  
Sistemas de Información,  
México

<sup>2</sup> Universidad Autónoma de Aguascalientes,  
Ciencias de la Computación,  
México

{dolores.torres, aurora.torres}@edu.uaa.mx

**Resumen.** En este trabajo, se presenta un clasificador de falla cardíaca basado en máquinas de soporte vectorial cuyo objetivo fue que utilizando datos clínicos lograra una exactitud por encima del 80%. Se configuró un diseño de experimentos factorial para encontrar los mejores parámetros para la máquina de soporte vectorial haciendo modificaciones en el kernel y el parámetro C. Los resultados obtenidos superaron las expectativas, pues el modelo resultante presenta una exactitud superior al 95% y una precisión de 94.44%. En este trabajo, fue usada la base de datos “Predicción de Falla Cardíaca” del repositorio Kaggle. La falla cardíaca es una patología crónica y degenerativa, por lo que un diagnóstico temprano puede ser la diferencia entre la vida y la muerte. Contar con una herramienta de aprendizaje supervisado de diagnóstico temprano con una buena exactitud, es un paso importante hacia la prevención.

**Palabras clave:** Falla cardíaca, máquinas de soporte vectorial, aprendizaje supervisado, aprendizaje automático

### Support Vector Machines in Heart Failure Prediction

**Abstract.** In this work, a heart failure classifier based on support vector machines is presented whose objective was to achieve an accuracy above 80% using clinical data. A factorial design of experiments was configured to find the best parameters for the support vector machine by making modifications to the kernel and parameter C. The results obtained exceeded expectations, since the resulting model has an accuracy greater than 95% and precision of 94.44%. In this work, the “Heart Failure Prediction” database from the Kaggle repository was used. Heart failure is a chronic and degenerative pathology, so early diagnosis can be the difference between life and death. Having a supervised learning tool for early diagnosis with good accuracy is an important step towards prevention.

**Keywords:** Heart failure, support vector machines, supervised learning, machine learning.

## 1. Introducción

En este trabajo, se presenta un clasificador de “Falla Cardíaca” basado en máquinas de soporte vectorial. El clasificador, pronostica esta patología médica mediante datos clínicos con una exactitud por encima del 95%. En el ámbito mundial, la falla cardíaca es una condición médica importante que afecta a millones de personas y representa una carga significativa para los sistemas de salud.

Según la Organización Mundial de la Salud (OMS), se estima que más de 26 millones de personas en todo el mundo viven con falla cardíaca en alguna medida, y se prevé que esta cifra aumente debido al envejecimiento de la población y la mayor incidencia de factores de riesgo cardiovascular [1]. Una detección temprana de este tipo de patología puede ser la diferencia entre la vida y la muerte, pues cuando una falla cardíaca comienza, el organismo compensa las consecuencias por cierto tiempo, hasta el punto donde esto ya no le es posible [2].

Si se detecta de manera temprana, el paciente puede comenzar con su tratamiento y prolongar su vida de manera considerable. El objetivo principal de este trabajo, consiste en diseñar, implementar y afinar (en términos de la selección de los mejores parámetros) un algoritmo Support Vector Machine (SVM) para el pronóstico de falla cardíaca que tenga una certeza de por lo menos el 80%, basado en datos clínicos con la intención de ser aplicado a grandes conjuntos de personas para lograr una identificación temprana de esta patología.

La falla cardíaca es el tema de interés de este trabajo porque se trata de una de las enfermedades que cobra una mayor cantidad de muertes alrededor del mundo. Por tratarse muchas veces de una patología asintomática, crónica y degenerativa, es fácil que el paciente que la padece no lo sepa y no busque ayuda médica.

Por lo anterior, el contar con una herramienta confiable de detección temprana, puede ser de gran utilidad para combatirla a tiempo. En las siguientes secciones de este documento, se podrá revisar la justificación, algunos conceptos de interés, la metodología utilizada, los experimentos realizados, los resultados y las conclusiones de la investigación.

### 1.1. Justificación

A nivel mundial, las cardiopatías, son desde hace 20 años la causa principal de mortalidad en todo el mundo. Actualmente provocan más muertes que nunca. El número de muertes debidas a las cardiopatías ha aumentado desde 2000 en más de 2 millones de personas, hasta llegar a casi 9 millones de personas en 2019 y continúan con esta tendencia. Las cardiopatías representan en 2019, el 16% del total de muertes debidas a todas las causas médicas. Más de la mitad de los dos millones de muertes adicionales han ocurrido en la región del pacífico occidental de la OMS. [1].

En México, cerca de 220 mil personas fallecieron por enfermedades cardiovasculares en 2021, de las cuales 177 mil fueron por infarto al miocardio. Estas muertes pueden ser prevenibles al evitar o controlar los factores de riesgo como el




Fig. 1. Máquina de soporte vectorial [7].

tabaquismo, presión arterial alta, colesterol elevado y diabetes no controlada [3]. La prevención es una opción excelente para este tipo de patologías pues se trata de problemas de salud crónicos y degenerativos.

## 2. Conceptos de interés

### 2.1. Falla cardíaca

La insuficiencia cardíaca (IC) o falla cardíaca (FC), significa que el corazón no puede bombear suficiente sangre rica en oxígeno para abastecer a los órganos, músculos y tejidos del organismo [4]. El tener insuficiencia cardíaca no significa que el corazón se haya detenido o esté a punto de dejar de latir. Pero sin suficiente flujo de sangre, es posible que los órganos no funcionen bien, lo que puede causar problemas de salud graves [2].

A veces, se utiliza la palabra "falla" para describir la etapa final de la enfermedad, mientras que "insuficiencia" se usa de manera más general para describir la condición en sus diferentes etapas y grados de severidad. Por ejemplo, se puede hablar de "insuficiencia cardíaca congestiva" para referirse a la condición en la que el corazón tiene dificultad para bombear sangre y se produce una acumulación de líquido en los tejidos:

- Cuando el corazón empieza a fallar, el organismo lo detecta inmediatamente y pone en marcha ciertos mecanismos compensatorios, por lo que muchos pacientes no llegan a percibir los síntomas anormales que manifiesta el corazón. No obstante, los mecanismos compensatorios sólo son eficaces durante cierto tiempo, por lo que llega un momento en el que el organismo no puede compensar más el fallo en el bombeo del corazón.
- El síndrome de insuficiencia cardíaca es un problema sanitario de primer orden. Las causas que lo generan son muy variadas, pero en el mundo occidental las más frecuentes son las derivadas de la enfermedad isquémica, diabetes, hipertensión y miocardiopatía de diversos orígenes [5].

- La causa más común de IC es la enfermedad coronaria, como la angina de pecho y, especialmente, el infarto de miocardio. Otra causa habitual es la hipertensión arterial [4].
- Hay dos tipos de insuficiencia cardíaca:
- Insuficiencia cardíaca sistólica. Se produce cuando disminuye la capacidad de contracción del corazón. No se empuja con suficiente fuerza a la sangre hacia el resto del cuerpo y queda en la cavidad cardíaca. A causa de esto, la sangre no puede entrar en el corazón y queda acumulada en los pulmones. Es lo que se denomina congestión pulmonar.
- Insuficiencia cardíaca diastólica. El corazón no recibe la suficiente cantidad de sangre porque tiene problemas para distenderse. Esto produce acumulación de fluidos en pies, tobillos y piernas. Algunos pacientes pueden tener también congestión pulmonar [4].

## 2.2. Máquinas de soporte vectorial

Una Máquina de Soporte Vectorial (SVM por las siglas de Support Vector Machine), es un conjunto de algoritmos de aprendizaje supervisado desarrollado por Vladimir Vapnik y sus colaboradores en los laboratorios AT&T. Una SVM mapea los puntos de entrada a un espacio de características de una dimensión mayor a la que representa el problema original, (i.e., si los puntos de entrada están en  $\mathbb{R}^2$ , entonces son mapeados a  $\mathbb{R}^3$ ) [6], y la SVM encuentra un hiperplano (HSO) que separe los objetos que pertenecen a clases distintas y que maximice el margen de separación entre clases, como se aprecia en la Fig. 1.

Una máquina de soporte vectorial puede modificar su comportamiento de acuerdo con la modificación de ciertos ajustes de componentes de la misma. Entre los principales parámetros que pueden configurarse en una SVM se encuentran: el kernel, el parámetro  $C$  y el parámetro gamma ( $\gamma$ ) [8]. El Kernel permite determinar el tipo de transformación que se aplica a los datos de entrada para separar las diferentes clases. Los tipos comunes de kernel incluyen el lineal, polinómico y radial (RBF). El kernel lineal se utiliza para datos linealmente separables, mientras que los kernels polinómicos y radiales son útiles para datos de carácter no lineal [8].

El parámetro  $C$  controla el número y severidad de las violaciones del margen (y del hiperplano) que se toleran en el proceso de ajuste. Si  $C = \infty$ , no se permite ninguna violación del margen y por lo tanto, el resultado es equivalente al clasificador de margen maximal (teniendo en cuenta que esta solución solo es posible si las clases son perfectamente separables). Cuando  $C$  se aproxima a cero, los errores se penalizan menos y más observaciones pueden estar en el lado incorrecto del margen o incluso del hiperplano.  $C$  es, a fin de cuentas, el hiperparámetro encargado de controlar el balance entre bias (sesgo) y la varianza del modelo.

El bias es el sesgo del modelo, es un parámetro adicional en una SVM que permite desplazar la frontera de decisión para mejorar la capacidad de ajuste del modelo a los datos de entrenamiento. El proceso de optimización de una SVM tiene la peculiaridad de que solo las observaciones que se encuentran justo en el margen o que lo violan influyen sobre el hiperplano de separación.

A estas observaciones se denomina vectores soporte y son las que definen el clasificador obtenido. Esta es la razón por la que el parámetro  $C$  controla el balance entre bias y varianza. Cuando el valor de  $C$  es pequeño, el margen es más ancho, y más observaciones violan el margen, convirtiéndose en vectores soporte. El hiperplano está, por lo tanto, sustentado por más observaciones, lo que aumenta el bias pero reduce la varianza. Cuando mayor es el valor de  $C$ , menor el margen, menos observaciones son vectores soporte y el clasificador resultante tiene menor bias pero mayor varianza. [8]. El lector interesado, podrá encontrar mayor detalle en [9, 10].

Por otro lado, gamma ( $\gamma$ ) es un parámetro que se aplica específicamente en kernels no lineales como el RBF. Gamma controla la influencia de cada punto de entrenamiento en la definición de la frontera de decisión. Un valor pequeño de gamma indica un alcance más amplio de influencia y un modelo más suave, mientras que un valor alto de gamma da como resultado un modelo más ajustado a los datos de entrenamiento. En esta sección, se ha enfatizado la manera teórica en la que una máquina de soporte vectorial responde ante cambios en los parámetros kernel,  $C$  y gamma porque estos parámetros son los que ajustamos para el mejor funcionamiento del clasificador desarrollado como podrá ser revisado en el apartado de “Experimentos” de este documento.

### **3. Metodología**

En este espacio, el lector podrá revisar la base de datos utilizada para la realización de este estudio, definición operacional y conceptual de las características, el preprocesamiento realizado y el detalle de la metodología empleada. A continuación, se presenta el conjunto de datos empleado para la prueba de los algoritmos.

#### **3.1. Conjunto de datos**

El conjunto de datos empleado para la investigación se denomina: “Predicción de Falla Cardíaca” [11]. Recuperada del repositorio Kaggle. Se trata de una base de datos proporcionada por Diego Vergara en 2022, que contiene información de 1190 casos de pacientes de Cleveland, Suiza, Hungría, Long Beach entre otros y de los cuáles hay 272 duplicados, por lo que el conjunto final utilizado es de 918 casos.

De éstos, el 80% (734) forman el conjunto de entrenamiento y el 20% (184) se usan para validación. De los 918 casos, (508) el 55,34% son pacientes con falla cardíaca y (410) el 44.66% son sanos. Por supuesto, un criterio de exclusión fue la repetición del caso. En el conjunto resultante, se tienen pacientes con o sin falla cardíaca sin repetición. Las características de los casos, su definición conceptual y operacional respectivamente son:

1. Edad. Edad del paciente en años.
2. Género. Género del paciente [M: Masculino, F: Femenino] . Valores 0-1 en ese orden.
3. Tipo de Dolor de Pecho. [TA: Angina Típica, ATA: Angina Atípica, NAP: Dolor no anginal, ASY: Asintomático]. Valores de 0–3 en ese orden.
4. Presión Arterial en Reposo. Se mide en milímetros de mercurio [mm Hg]




Fig. 2. Metodología.

5. Colesterol. Nivel de colesterol sérico [mm/dl]
6. Glucemia en Ayunas. Se presenta como: [1: Si FastingBS > 120 mg/dl, 0: de lo contrario]
7. Resultados de Electrocardiograma en Reposo. Puede ser: [Normal: Normal, ST: anomalía en onda ST-T (inversión en onda T y/o elevación o depresión de la onda ST > 0.05 mV), LVH: que muestra hipertrofia ventricular izquierda probable o definitiva según los criterios de Estes]. Valores 0-3 en ese orden.
8. Frecuencia cardíaca máxima. [Valor numérico entre 60 y 202].
9. Angina inducida por ejercicio. Puede ser: [Y: Si, N: No]. 0 y 1 en ese orden.
10. Oldpeak ó depresión del segmento ST en un ECG especialmente durante el ejercicio = ST [Valor numérico].
11. Pendiente del segmento ST de ejercicio máximo. Puede ser: [Up: ascendente, Flat: plana, Down: descendente]. Valores 0-2 en ese orden.
12. Enfermedad Cardíaca: Es la clase, y puede ser: [1: enfermedad cardíaca, 0: Normal].

### 3.2. Metodología utilizada

En la fig.2, se presenta el detalle de la metodología general de esta investigación. El lector podrá ver que la primera fase consiste en la obtención de la base de datos, que fue descargada del repositorio Kaggle [11].

Posteriormente, se prepararon los conjuntos de entrenamiento y validación con un 80% y un 20% respectivamente. Como tercera etapa, una máquina de soporte vectorial fue diseñada e implementada en lenguaje Python 3.7 con apoyo de las librerías Pandas

**Tabla 1.** Niveles de parámetros para experimentación.

Parámetro	Valor
Kernel	Lineal
	Poly
	RBF
C	1.2
	4.0
	6.0
Gamma	0.09

y sklearn. Como cuarta etapa de la metodología y con la intención de contar con un mejor desempeño para la máquina de soporte vectorial, se trabajó en un diseño factorial de 30 réplicas para cada grupo de combinación de parámetros. Contando con este diseño factorial, se comenzó a hacer el análisis de resultados para completar la fase cinco. Finalmente, como última etapa, se obtienen las principales conclusiones del estudio y se considera el trabajo futuro.

## 4. Experimentación

En esta sección, se presentan los detalles del experimento factorial diseñado para seleccionar los mejores parámetros de la máquina de soporte vectorial.

### 4.1. Experimentos con la máquina de soporte vectorial

Como primer conjunto de experimentos, se corrieron pruebas empíricas en la máquina de soporte vectorial para conocer de manera aproximada los valores de los parámetros a configurar. En este sentido, se trabajó con 3 parámetros: Kernel,  $C$  y gamma. Recordemos que el parámetro  $C$ , en una SVM controla la penalización por errores en la clasificación. Un valor de  $C$  bajo permite una mayor flexibilidad en la selección del hiperplano de separación, lo que puede resultar en un margen más amplio, pero también en una mayor tolerancia a errores de clasificación en el conjunto de entrenamiento.

Un valor del parámetro  $C$  bajo puede llevar a un modelo con alta capacidad de generalización, pero mayor susceptibilidad al sobreajuste, mientras que un valor alto para  $C$ , puede resultar en un modelo con menor capacidad de generalización, pero mayor capacidad para ajustarse a los datos de entrenamiento.

Por otro lado, un valor alto de  $C$  impone una mayor penalización por errores, lo que conduce a un hiperplano de separación más ajustado y posiblemente más sensible a ruido en los datos. En cuanto al kernel seleccionado, éste permite la transformación de un problema a un espacio  $n$ -dimensional por encima del espacio de datos original para lograr la separación lineal de las clases.

El kernel lineal es adecuado para conjuntos de datos linealmente separables, mientras que los kernels polinómicos y radiales son más adecuados para conjuntos de datos no lineales. Es conocido que el kernel radial (RBF) es especialmente versátil y

**Tabla 2.** Grupos de parámetros para experimentación.

Grupo	Kernel	C	Gamma
1-3	RBF	1.2	0.09
	Lineal		
	Poly		
4-6	RBF	4.0	0.09
	Lineal		
	Poly		
7-9	RBF	6.0	0.09
	Lineal		
	Poly		

puede manejar relaciones no lineales de manera efectiva [8]. Con respecto del parámetro gamma, recordemos que este parámetro controla la influencia de cada punto de entrenamiento en la definición de la frontera de decisión.

Un valor pequeño de gamma indica un alcance más amplio de influencia y un modelo más suave, mientras que un valor alto de gamma da como resultado un modelo más ajustado a los datos de entrenamiento. Por defecto, gamma es  $1/n$  establecido por scikit-learn [8], donde  $n$  es el número de característica que se utilizan para la clasificación.

Tomando en consideración el efecto teórico de los parámetros y el resultado deseado del modelo clasificador, los valores para los parámetros mostrados en la Tabla 1, fueron seleccionados después de un análisis empírico inicial: Como se trata de dos parámetros con tres niveles de valor para cada uno, se crearon 9 grupos de parámetros para la experimentación como puede observarse en la Tabla 2.

Aunque se probaron 2 valores de gamma, (0.009 y 0.09), se observó que, en todos los casos, los mejores resultados corresponden a 0.09, que es el valor recomendado por Scikit-learn. Por tal motivo, esta parte se descartó de los experimentos y se fijó gamma en 0.09. Se desarrollaron 30 réplicas con cada uno de los grupos de parámetros y los resultados fueron analizados con el software estadístico SPSS versión 20.

Como puede verse en la tabla 2. El grupo 1 tiene en el mismo orden de aparición de la tabla los parámetros: kernel = rbf,  $C = 1.2$ , Gamma = 0.09, el segundo grupo tiene: Kernel = lineal,  $C = 1.2$ , Gamma = 0.09, el grupo 3 tiene kernel = poly,  $C = 1.2$  y Gamma = 0.09. De esta misma manera el grupo 4 tiene kernel = rbf,  $C = 4$  y Gamma = 0.09, el grupo5 tiene kernel = lineal,  $C = 4$  y Gamma = 0.09, el grupo 6 tiene kernel = poly,  $C = 4$  y Gamma = 0.09, ocurriendo en el mismo orden para los grupos 7, 8 y 9 con  $C = 6.0$  y kernels rbf, lineal y poli respectivamente.

Las variables de desempeño consideradas para el algoritmo fueron: exactitud del modelo en validación (E), tiempo en segundos (T), verdaderos positivos (VP), verdaderos negativos (VN), falsos positivos (FP) y falsos negativos (FN).

Utilizando estas características de desempeño, se establecieron los mejores valores de los parámetros y se procedió a la obtención de resultados y conclusiones de la investigación.



**Tabla 3.** Resultados de la experimentación.

Grupo	Exactitud Modelo	Tiempo (seg)	Verdaderos Positivos (VP)	Verdaderos Negativos (VN)	Falsos Positivos (FP)	Falsos Negativos (FN)
1	0.955434783	0.027	103.7	72.1	6.1	2.1
2	0.851086957	4.379	87.5	69.1	13.3	14.1
3	0.736956522	0.0233	83.3	52.3	20.6	27.8
4	0.744565217	0.0281	76.3	60.7	24.2	22.8
5	0.873369565	18.013	91.6	69.1	11.8	11.5
6	0.741847826	0.0275	81.9	54.6	23	24.5
7	0.745652174	0.0272	78.6	58.6	23.5	23.3
8	0.858695652	25.894	89.6	68.4	12.5	13.5
9	0.759782609	0.0316	81.7	58.1	19.1	25.1

## 5. Resultados

Como puede observarse en la Tabla 3. Los resultados apuntan a la combinación de parámetros correspondiente al grupo 1, como la mejor en términos de exactitud del modelo.

En cuanto al tiempo en segundos, también se encuentra como una de las mejores combinaciones de parámetros y respecto de verdaderos positivos, verdaderos negativos, falsos positivos (error tipo I) y falsos negativos (error tipo II), es la mejor tanto empírica como estadísticamente. Cada grupo corresponde con los primeros parámetros mostrados en la Tabla 2.

En el caso del grupo 1, usa un kernel = *RBF*,  $C = 1.2$  y  $\gamma = 0.09$ . Los grupos se conforman en el mismo orden de aparición de los parámetros en la Tabla 2.

El único criterio de desempeño del modelo que presentó una distribución normal y homocedástica fue el tiempo, la exactitud, VP, VN, FP, FN no cumplen con los criterios de normalidad y homocedasticidad, por tal motivo, se realizó la prueba de Kruskal Wallis con el fin de encontrar si las diferencias en los grupos de parámetros eran estadísticamente significativas.

Los resultados estadísticos mostraron que, en efecto, existe diferencia entre los grupos de combinaciones variando el kernel y el parámetro  $C$ . Como puede verse en la Tabla 3, el grupo 1 de parámetros tuvo los mejores resultados para la máquina de soporte vectorial.

Así pues, los mejores resultados promedio se obtuvieron con un kernel *RBF* y una  $C = 1.2$  logrando una exactitud del modelo en validación del 95.54%, una precisión del 94.44%, un tiempo en segundos de 0.027, 103.7 VP, 72.1 VN, un error tipo I de 6.1 y un error tipo II de 2.1.

De estos resultados podemos concluir que, en efecto, vale la pena dedicar tiempo a la configuración de los parámetros de cualquier algoritmo de aprendizaje. Cabe mencionar que, con el mejor modelo, se realizó una validación cruzada de 5 pliegues obteniendo un promedio de exactitud 95.02%. Los valores de los 5 pliegues fueron: 94.3, 94.2, 95.4, 95.7 y 95.5 respectivamente.

## 6. Conclusiones y discusión

Aunque inicialmente se buscaba diseñar e implementar un clasificador de falla cardíaca que alcanzara una exactitud del 80%, este objetivo se mejoró por más de 15 puntos porcentuales alcanzando una exactitud de más del 95%. El ejercicio de diseño y desarrollo de un clasificador de falla cardíaca con datos reales de pacientes de Cleveland, Suiza, Hungría, Long Beach entre otros, es un paso importante que permite ver los resultados de un buen ajuste de parámetros en algoritmos de aprendizaje automático como es el caso de las máquinas de soporte vectorial. Es importante enfatizar que, para este problema, el kernel que mejores resultados proporciona es el rbf y el que peores resultados tuvo fue el poly. Por otro lado, un valor de  $C=1.2$  proporcionó buenos resultados en contraposición con los demás valores probados (4.0 y 6.0).

La falla cardíaca es una patología crónica y degenerativa, por lo que un diagnóstico temprano puede ser la diferencia entre la vida y la muerte. Contar con una herramienta de aprendizaje supervisado de diagnóstico temprano con una buena exactitud (mayor al 95%), es un paso importante hacia la prevención de este tipo de enfermedades. Los resultados de la experimentación empírica presentaban una exactitud promedio del 80% que fue superada por mucho en los experimentos finales. El ajuste de parámetros puede significar la diferencia entre contar con un modelo adecuado y tener un excelente modelo para el pronóstico de una de las enfermedades que a nivel mundial representa la principal causa de muerte en el mundo y en México.

## 7. Trabajo futuro

Con los resultados obtenidos en esta investigación, se pretende entrenar una red neuronal artificial, someterla a un diseño factorial para escoger los mejores parámetros y contrastar sus resultados contra la máquina de soporte vectorial. Posteriormente, se ejecutarán ambos clasificadores con datos reales mexicanos obtenidos en colaboración con médicos expertos del sector salud del estado de Aguascalientes, México. Con estos modelos adaptados para la población mexicana, se llevarán a cabo aplicaciones masivas en el sector salud del Estado de Aguascalientes.

## Referencias

1. WHO: Organización Mundial de la Salud: La OMS revela las principales causas de muerte y discapacidad en el mundo: 2000-2019. [www.who.int/es/news/item/09-12-2020-who-reveals-leading-causes-of-death-and-disability-worldwide-2000-2019](http://www.who.int/es/news/item/09-12-2020-who-reveals-leading-causes-of-death-and-disability-worldwide-2000-2019) (2020)
2. American Heart Association: ¿Qué es la insuficiencia cardíaca? [www.heart.org/en/health-topics/heart-failure/what-is-heart-failure](http://www.heart.org/en/health-topics/heart-failure/what-is-heart-failure) (2016).
3. Gobierno Federal: Comunicado de Salud. Secretaría de Salud (2021)
4. Colomer-Carretero, M.: Insuficiencia cardíaca tratamiento con agentes sensibilizadores del calcio. *Offarm Farmacia y Sociedad*, vol. 25, no. 7, pp. 87–87 (2006)
5. Imizcoz, M.Á.: Insuficiencia cardíaca: Definición, fisiopatología y cambios estructurales. *Cirugía Cardiovascular*, vol. 15, no. 1, pp. 15–20 (2008). DOI: 10.1016/s1134-0096(08)70220-1.

6. Betancourt, G.: Las máquinas de soporte vectorial (SVMs). *Scientia et Technica*, vol. XI, no. 27, pp. 67–72 (2005)
7. González, R., Barrientos, A., Toapanta, M., del-Cerro, J.: Aplicación de las máquinas de soporte vectorial (SVM) al diagnóstico clínico de la enfermedad de párkinson y el temblor esencial. *Revista Iberoamericana de Automática e Informática Industrial (RIAI)*, vol. 14, no. 4, pp. 394–405 (2017). DOI: 10.1016/j.riai.2017.07.005.
8. Scikit-learn: sklearn.svm.SVC. Scikitlearn. <http://scikit-learn.org/0.15/modules/generated/sklearn.svm.SVC.html> (2019)
9. Vapnik, V.N.: *The Nature of Statistical Learning Theory*. Springer New York (2000). DOI: 10.1007/978-1-4757-3264-1.
10. Cristianini, N., Shawe-Taylor, J.: *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press (2000). DOI: 10.1017/CBO9780511801389.
11. Vergara, D.: Predicción de falla cardíaca. Kaggle. <http://kaggle.com/competitions/prediccin-de-falla-cardiaca> (2022)