

---

# PREDICCIÓN DE READMISIÓN DE PACIENTES PEDIÁTRICOS MEDIANTE APRENDIZAJE SUPERVISADO

---

PATRICIO WOLFF \*  
SEBASTIÁN A. RÍOS \*

## Resumen

La readmisión hospitalaria es un problema frecuente y costoso. El problema de predecir la readmisión pediátrica es difícil de abordar debido a que depende de múltiples factores y los datos requeridos pueden no estar disponibles. En esta investigación se abordó un problema que día a día adquiere mayor importancia, la readmisión pediátrica evitable. Para lograr el objetivo, se deben implementar una serie de operaciones, como: limpieza de datos erróneos, etiquetar casos, aplicar técnicas de balanceo de clases, probar diferentes modelos de clasificación y evaluar métricas para determinar mejores resultados. Diferentes métodos de clasificación fueron comparados en este estudio, dos métodos basados en árboles de decisión y uno en Regresión Logística (RL). Random Forest (RF) es la técnica que muestra mejores resultados con el Área bajo la curva ROC (AUC) de 0,683 y un Valor Predictivo Positivo (PPV) de 7,94. Para su evaluación, se utilizó 5-fold Cross-Validation y curvas ROC.

**Palabras Clave:** Readmisión Hospitalaria, Machine learning, Pediatría.

---

\* Centro de Investigación en Inteligencia de Negocios, Departamento de Ingeniería Industrial, Universidad de Chile

---

## 1. Introducción

---

La readmisión hospitalaria se define como la admisión no programada de un paciente a un centro de atención después de un egreso o alta, dentro de un período de tiempo, que generalmente es de 7, 30 a 90 días. La readmisión hospitalaria es un problema frecuente y costoso [11]. Este problema ha sido ampliamente estudiado en el mundo [12]. No todas las readmisiones son evitables, sin embargo, aquellas que sí lo son están relacionadas con un cuidado subóptimo y con una mala gestión del proceso de dado de alta [21]. El problema del riesgo de readmisión en la actualidad ha tomado mayor relevancia en Chile. En especial cuando se discute la posibilidad de basar el financiamiento de los hospitales públicos en base a su producción de Grupos Relacionados por el Diagnóstico (GRD)<sup>1</sup>. La experiencia de Estados Unidos es que el financiamiento hospitalario con esta característica debe ser corregido por un índice de readmisión [15] o como en el caso de Reino Unido, estableciendo penalidades financieras a los hospitales [13]. Debido a las nuevas estructuras de financiamiento de la salud en algunos países, las readmisiones hospitalarias se han convertido en un indicador central de la calidad de la atención [2]. Las readmisiones como una medida de calidad de la atención médica han sido objeto de un fuerte debate tanto en entornos hospitalarios para adultos como en pediatría [16].

El problema de la predicción de las readmisiones hospitalarias es difícil de abordar debido a que su origen se puede deber a múltiples factores y la data disponible puede ser insuficiente. La literatura científica reporta una gran cantidad de análisis cuantitativos, principalmente para pacientes adultos, incluidos enfoques predictivos basados en aprendizaje automático. Sin embargo, las readmisiones en hospitales pediátricos han recibido poca atención hasta hace poco. En el caso de la readmisión pediátrica la literatura reconoce que parece ser más difícil de resolver que en el caso de los adultos [10].

El Hospital Dr. Exequiel González Cortés (HEGC) es un centro de alta complejidad asistencial y docente que atiende a la población infantil del área sur de Santiago de Chile. En el periodo 2011 a 2017 el hospital contó con una dotación aproximada de 126 camas, pudiendo aumentar a 150 en campaña de invierno. En este periodo el hospital categorizó 56.558 egresos en su sistema

---

<sup>1</sup>Los Grupos Relacionados por el Diagnóstico (GRD) son un sistemas de clasificación de pacientes, utilizados para medir la producción hospitalaria. Se obtienen a partir de la información que se registra en la historia clínica de cada paciente, y relacionan las características clínicas de los pacientes con el uso de recursos.

de codificación GRD. El uso de sistemas de estimación de la complejidad de las hospitalizaciones como GRD que actualmente ha tenido una importante penetración en Chile ha permitido contar con un gran número de datos estandarizados y específicos. Los datos contenidos en el GRD no poseen un campo específico que detalle si un determinado egreso produjo una readmisión en un periodo de 30 días a contar del alta. Por este motivo la etiqueta específica que permite el aprendizaje supervisado debe ser generada y revisada por un equipo experto, que entre otras cosas determina: si la segunda admisión es asociable clínicamente a la primera; si es una readmisión evitable; o si es una readmisión programada.

La predicción de readmisión en pacientes adultos se ha abordado con diversos enfoques [12, 1], entre estos por medio del aprendizaje supervisado [9, 26, 7, 19, 25, 22, 20]. A menudo, estos modelos exhiben un rendimiento predictivo deficiente y no serían adecuados para su uso en un entorno clínico [9]. Una revisión sistemática [12] de las publicaciones en esta área informa Área bajo la curva ROC (AUC) entre 0,56 y 0,72 (ver sección 2.5). Sin embargo, este resultado puede mejorar si se considera un mayor volumen de datos, tales como: actividades de asistencia diaria post-alta, discapacidad visual y estado funcional [6]; o data longitudinal [18].

La idea de esta investigación es extender los resultados de la investigación presentada en [23], probando otros métodos de aprendizaje supervisado bien estudiados en la literatura. En esa investigación se presentaron los resultados de la predicción de readmisión hospitalaria en pacientes pediátricos mediante el uso de *Support Vector Machines* (SVM), *Naive Bayes* (NB) y Redes Neuronales Artificiales (ANN, por su sigla en inglés). En dicho estudio se utilizaron técnicas de balanceo de clases y *5-fold Cross-validation*, encontrándose que el mejor AUC ( $p < 0,001$ ) se obtuvo con el enfoque de NB (0,655). En esta investigación se busca mejorar los resultados mostrados en esa investigación por la incorporación de otros modelos no considerados en el estudio, pero conservando el diseño del estudio y aplicando la solución sobre la misma data. La utilización conjunta de las técnicas de balanceo de clases y *Cross-validation*, junto con métodos de aprendizaje supervisado como *Random Forest* han mostrado buenos resultados, en especial en problemas de riesgo clínico con data desbalanceada [24].

## 2. Materiales y Métodos

A continuación se describen los métodos utilizados los cuales se presentan en el esquema de la Figura 1.

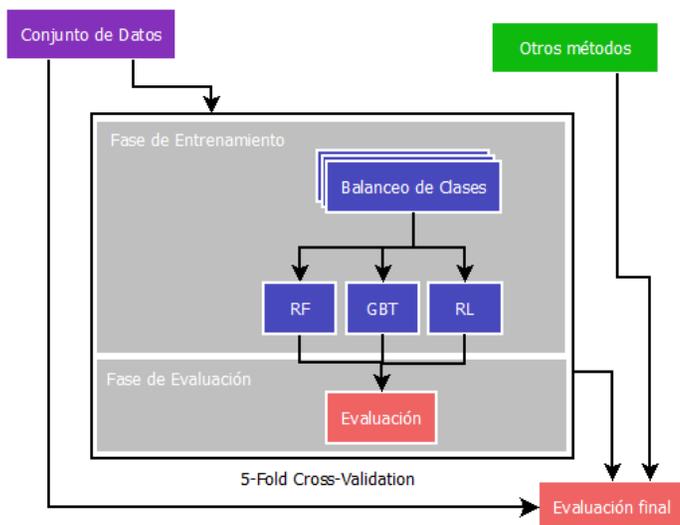


Figura 1: Diseño del estudio

### 2.1. El conjunto de datos

La data utilizada proviene del codificador GRD-IR v.3 del Ministerio de Salud, el que contiene 56.558 egresos de 35.063 pacientes del HEGC, de estos egresos 2.106 provocaron una readmisión. La información disponible corresponde a información del paciente como la fecha de nacimiento/edad, sexo, etnia, país de origen, domicilio, previsión y peso GRD al egreso, el cual contiene de forma intrínseca la complejidad del diagnóstico principal, secundario y procedimiento principal realizado. Además, esta data contiene información del ingreso del paciente al hospital como la fecha de ingreso, el servicio en el cual ingresó y su procedencia. Por otro lado, se cuenta con información de traslados internos como fecha/hora, servicio de origen y destino interno. Esta data también contiene información del alta del paciente como fecha/hora, servicio que da el alta y destino del paciente.

## 2.2. Etiquetas

No todo egreso hospitalario con reingreso posterior es considerado como un egreso que generó una readmisión (etiqueta positiva en el problema de aprendizaje supervisado) en este problema particular. Esto se debe a que existen casos que corresponden a reingresos programados, fuera del periodo de 30 días o no asociados al egreso anterior. Para obtener las etiquetas se analizaron: (1) readmisiones en periodos menores a 30 días desde el alta anterior; (2) se eliminaron tratamientos programados como quimioterapias; (3) se eliminaron ingresos al hospital por otros servicios que no son la urgencia o cuya estadía fue menor a un día; finalmente, (4) se revisaron las etiquetas por medio de un comité experto para corroborar que efectivamente correspondieran a un reingreso. La data y las etiquetas utilizadas en este estudio son exactamente las mismas que la utilizadas en el estudio anterior [23], por lo que los resultados obtenidos en estas dos publicaciones son comparables.

## 2.3. Métodos de Clasificación

En este estudio se entrenaron y probaron dos modelos basados en árboles de decisión (*Random Forest* y *Gradient Boosted Trees*) y uno basado en Regresión Logística.

Los árboles de decisión fueron introducidos en la comunidad científica por primera vez en en 1984 [4] y reconocidos en la literatura de Aprendizaje de Maquinas en 1986 [17]. *Random Forest* (RF) [3] son un tipo de métodos basados en el ensamblaje de un conjunto de árboles de decisión entrenados en base a subconjuntos aleatorios del conjunto de datos original, cada uno de los cuales se entrena de forma independiente. Cada nodo de un árbol representa una regla de división para un atributo específico donde la cantidad de variables de cada árbol es menor al numero total de variables del modelo completo, que se seleccionan de forma aleatoria. Luego, estos arboles se combinan con la finalidad de reducir la varianza a través de la combinación de los resultados de varios clasificadores débiles (Bagging).

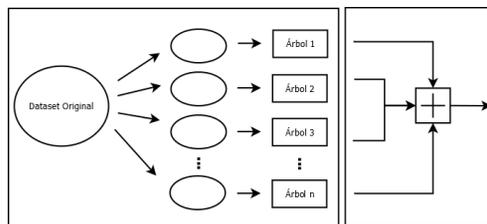


Figura 2: *Bagging* en RF

La profundidad máxima de los árboles utilizada en el caso de RF fue de 8 y se probaron bosques de 10, 100 y 1000 árboles, encontrándose un mejor resultado utilizando 100 árboles.

Los *Gradient Boosting Trees* (GBT) son considerados unos de los modelos más poderosos y mayormente utilizados para problemas de aprendizaje supervisado. Al igual que en el caso de los RF este modelo se basa en árboles de decisión débiles, que son agregados al modelo, con la finalidad de construir un modelo más preciso en cada iteración. Los parámetros de los árboles de decisión que son agregados al modelo se determinan mediante el cálculo del gradiente descendiente que minimiza la función de pérdida (que es predefinida). La principal diferencia con *Bagging* es que la secuencia de construcción de árboles de *Boosting* se adapta el predictor a distintos segmentos del conjunto de entrenamiento de forma secuencial.

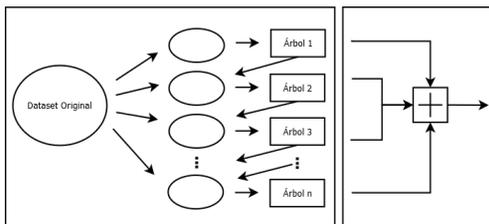


Figura 3: *Boosting*

La Regresión Logística es un método estadístico ampliamente utilizado en problemas de clasificación dicotómica. Este método pretende encontrar la probabilidad de ocurrencia  $y \in [0, 1]$  de un evento en base a regresores  $x \in \mathbb{R}^n$ . El modelo utiliza la función logística (1) para estimar la probabilidad de ocurrencia de la readmisión, en base al vector de datos de entrada  $x_i$  con  $i \in \{1, \dots, N\}$  con sus respectivas etiquetas  $y_i \in \{1, 0\}$ .

$$p(x_i) = \frac{1}{1 + e^{-\beta_0 - \sum_{j=1}^V \beta_j x_{ij}}} \tag{1}$$

El proceso de estimación de los parámetros utiliza la función de máxima verosimilitud [8], el que busca maximizar la probabilidad de obtener los resultados etiquetados en base a  $y_i$ . Esto permite obtener estimadores asintóticamente eficientes, insesgados y distribuidos normalmente.

### 2.4. Balanceo de clases

Una de las primeras dificultades al enfrentar problemas de este tipo es que el conjunto de datos están intrínsecamente muy desbalanceados. Esto se debe

principalmente a que los eventos de alto riesgo no son tan frecuentes. Esto genera conjuntos de datos con clases de bajo riesgo formadas por numerosos casos y clases de alto riesgo con muy pocos casos. En la actualidad existen una serie de técnicas que permiten en enfrentar el problema del desbalanceo de clases [14]. La literatura muestra una amplia utilización de estas técnicas en diferentes problemas. Específicamente, se utilizó *Synthetic Minority Over-sampling Technique* (SMOTE) [5] para aumentar las clases minoritarias. En el algoritmo SMOTE, las nuevas muestras de la clase minoritaria se generan por interpolación aleatoria entre  $k$  vecinos seleccionados al azar de la clase minoritaria. La interpolación aleatoria se realiza dentro de la envolvente convexa de las muestras de referencia, como se observa en la Figura 4.

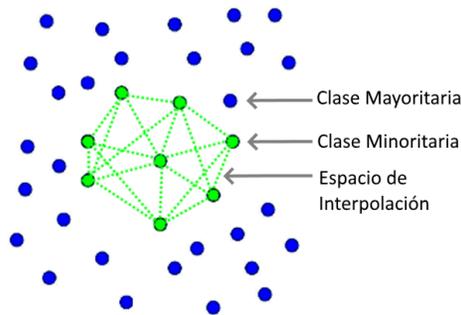


Figura 4: *Algoritmo SMOTE*

## 2.5. Métricas de Evaluación

En cada iteración de la validación cruzada se calculó la matriz de confusión y las métricas de rendimiento derivadas de él, finalmente reportando la media aritmética de estos resultados y su desviación estándar (SD). Definamos TP, TN, FP y FN como verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos respectivamente. Entonces calculamos el *recall* o sensibilidad como:

$$recall = \frac{TP}{TP + FN}, \quad (2)$$

el Valor Predictivo Positivo (PPV) como:

$$PPV = \frac{TP}{TP + FP}, \quad (3)$$

el  $f - score$  se define como:

$$f - score = \frac{2}{1/R + 1/PPV} \quad (4)$$

Cuando las clases están fuertemente desbalanceadas estas métricas son más informativas de la detección exitosa de la clase minoritaria en comparación al Ajuste (Acc) definido como:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

El análisis utilizando las curvas *Receiver Operating Characteristic* (ROC) se han utilizado ampliamente para comparar diferentes clasificadores del estado del arte en clasificación binaria. La curva ROC es una representación gráfica de la sensibilidad frente a 1-especificidad, según se varía el umbral de discriminación. La curva se gráfica para diferentes resultados de modelos y permite comparar de forma gráfica la respuesta de estos. El Área Bajo la Curva ROC (AUC), o también conocido como estadístico C una prueba no paramétrica aplicada a dos muestras independientes. El AUC representa numéricamente el área entre la curva ROC y la horizontal y es equivalente a la prueba de Mann-Whitney. El AUC toma valores entre 0 y 1 y a medida que el AUC de un clasificador se acerca al valor 1 (clasificador perfecto), mayor será su capacidad discriminativa. Además, se debe notar que valores menores o iguales a 0,5 corresponden a clasificadores con nula o mala capacidad discriminativa. El AUC se reporta a menudo para medir la calidad del resultado en estudios sobre la predicción de readmisión en pacientes adultos [1].

*Cross-Validation* es una técnica ampliamente utilizada para evitar el sobreajuste de los modelos y garantizar que los resultados son independientes de una partición arbitraria entre datos de entrenamiento y prueba. La técnica consiste en repetir y calcular la media aritmética de los resultados obtenidos por el modelo en diferentes particiones de los datos, en este caso cinco particiones (5-fold). Los valores obtenidos en este conjunto de pruebas son los que se utilizan para la comparación entre los diferentes modelos.

---

### 3. Resultados

---

En la Tabla 1 se presentan los resultados obtenidos con los 3 modelos utilizados en este trabajo e incluyendo el mejor de los resultados mostrado en el trabajo anterior.

Tabla 1: Resultados

	AUC (SD)	recall (SD) [%]	f-score (SD) [%]	PPV (SD) [%]
Trabajo Anterior [23]	0,653 (0,014)	69,80 (4,97)	9,83 (0,53)	5,29 (0,31)
<i>Random Forest</i>	0,683 (0,009)	24,07 (1,67)	11,94 (0,90)	7,94 (0,62)
<i>Gradient Boosted Trees</i>	0,682 (0,013)	57,65 (5,52)	11,56 (0,60)	6,43 (0,31)
Regresión Logística	0,668 (0,010)	68,90 (1,65)	10,27 (0,17)	5,55 (0,09)

En el Figura 5 se presenta la curva ROC obtenida por los 3 modelos presentados en este trabajo, en conjunto con el mejor resultado obtenido en el trabajo anterior, el cual corresponde a *Naive Bayes*.

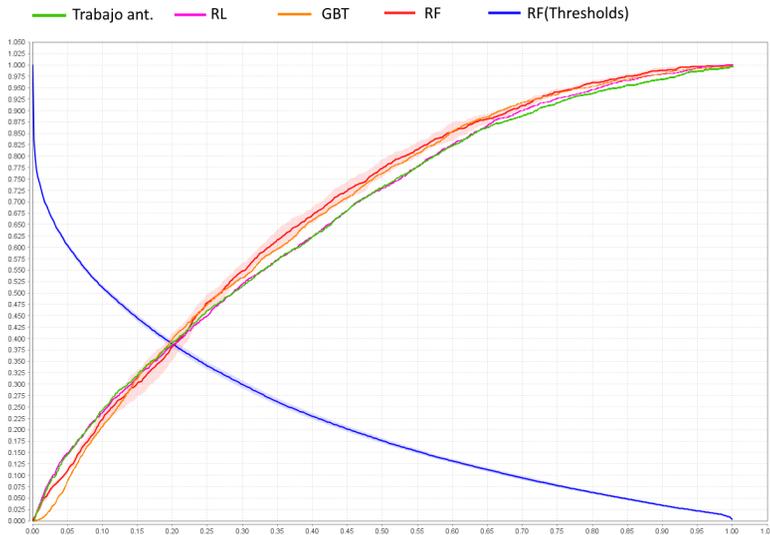


Figura 5: Curva ROC

---

## 4. Discusión

---

Los valores de AUC obtenidos en este trabajo para RF muestran un comportamiento de clasificación superior (*Pairwise t-test*  $p < 0,004$ ) al resultado obtenido en el trabajo anterior. En el caso de GBT el resultado en AUC es superior, pero menos significativo (*Pairwise t-test*  $p < 0,008$ ) debido a la variabilidad del resultado expresado en una desviación estándar mayor que en el caso de RF. Tanto RF como GBT muestran mejores resultados ( $p < 0,025$  y  $p < 0,07$ ) en AUC respecto de LR. Una métrica que es presentada en [23] y que resulta interesante de analizar en este caso es la sensibilidad (o *recall*), esta métrica muestra que el resultado del trabajo anterior es superior ( $p < 0,005$ )

a los resultados obtenidos con los modelos basados en árboles de decisión. Por otro lado, el resultado obtenido en PPV muestra que el modelo RF es significativamente superior al resultado mostrado por NB ( $p < 0,0002$ ) y GBT ( $p < 0,003$ ).

La curva ROC muestra gráficamente un resultado levemente superior de los modelos basados en árboles de decisión con respecto a la curva ROC anteriormente obtenida para la predicción de readmisiones. Al presentarse en este trabajo curvas ROC por sobre la mejor curva ROC presentada anteriormente, intrínsecamente se observa que los resultados basados en árboles de decisión, en este problema particular muestran mejor comportamiento que SVM y ANN.

---

## 5. Conclusiones

---

Por lo que sabemos, este es el segundo estudio de este tipo en Chile, y entre los primeros a nivel mundial, centrados en la predicción readmisiones pediátricas. Además, los resultados obtenidos con los modelos utilizados en este trabajo sobrepasan a los resultados obtenidos en el único trabajo anterior de predicción de readmisión hospitalaria pediátrica en 30 días conocido por los autores (utilizando la misma data).

En este documento, se presentan los resultados de un estudio que utilizó un conjunto de datos anonimizados recopilados durante seis años de operación en un hospital pediátrico público en Santiago, Chile. La cantidad de datos recopilados es grande para un estudio de un solo sitio (56.558 altas y 2.106 readmisiones). Hemos aplicado adicionalmente tres métodos predictivos sobre los datos administrativos utilizados para la estimación del costo del paciente por medio del codificador GRD. Los resultados son buenos, logrando un alto rendimiento predictivo ( $AUC = 0,683$ ) que es comparable a otros estudios sobre datos de pacientes adultos.

La aplicación de estos modelos en ambientes clínicos reales puede variar. La predicción de las readmisiones tiene como objetivo central evitar que estas ocurran, por medio del soporte a la decisión clínica. En el proceso de alta de un paciente se cuenta con toda la información que es requerida para la predicción de estos modelos. Es en ese instante cuando la predicción puede apoyar al personal del hospital, recomendando por ejemplo: cuidados especiales post alta, educación al cuidador o postergación del alta.

Existen diferentes estrategias para evitar una readmisión no planificada como Telemonitoreo y visitas programadas a los pacientes, además de estrategias como educación para los tutores respecto de los cuidados del paciente, etc.

Si bien, estas estrategias han mostrado ser efectivas tienen un costo elevado para el hospital. En este sentido, se requieren modelos que permitan predecir los pacientes que tienen un mayor riesgo de ser readmitidos y focalizar los recursos en estos pacientes. Mejorar la capacidad predictiva permitirá centrar los recursos en los pacientes de mayor riesgo, lo que mejorará el resultado sanitario, sin incrementar significativamente los costos.

La readmisión hospitalaria evitable es un evento específico objetivo, que revela un resultado clínico no deseado. Esta tiene la característica de ser un punto de intersección de dos áreas de la investigación, como la medicina basada en evidencia y la ciencia de los datos. En este sentido los trabajos que basan en resultados clínicos permiten avanzar en técnicas de aprendizaje supervisado, así como discutir el potencial clínico de las aplicaciones realizadas. La etiqueta experta limita el número de casos en estudio, principalmente porque el proceso de etiquetado puede tomar mucho tiempo para su realización y/o estar sujeto a errores. Se requiere avanzar en determinar un mayor número de resultados clínicos con estas características y el estudio de modelos de aprendizaje supervisado que robustezcan los Sistemas de Apoyo a las Decisiones Clínicas (CDSS, por su sigla en inglés).

*Agradecimientos:* Los autores desean agradecer a la Dra. María Begoña Yarza y al Profesor PhD. Manuel Graña por su cooperación en esta investigación. Esta investigación es parcialmente financiada por CONICYT, Programa de Formación de Capital Humano avanzado (CONICYT-PCHA/Doctorado Nacional/2015-21150115).

## Referencias

- [1] A. Artetxe, A. Beristain, y M. Graña. Predictive models for hospital readmission risk: A systematic review of methods. *Computer Methods and Programs in Biomedicine*, 164:49 – 64, 2018.
- [2] N. S. Bardach, E. Vittinghoff, R. Asteria-Peñaloza, J. D. Edwards, J. Yazdany, H. C. Lee, W. J. Boscardin, M. D. Cabana, y R. A. Dudley. Measuring hospital quality using pediatric readmission and revisit rates. *Pediatrics*, 132(3):429–436, 2013.
- [3] L. Breiman. Random forests. *Machine Learning*, 45(1):5–32, Oct 2001.
- [4] L. Breiman, J. H. Friedman, R. A. Olshen, y C. J. Stone. Classification and regression trees. *Cole Publishing, Monterey*, 535:358, 1984.

- [5] N. V. Chawla, K. W. Bowyer, L. O. Hall, y W. P. Kegelmeyer. Smote: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16:321–357, 2002.
- [6] E. A. Coleman, S.-j. Min, A. Chomiak, y A. M. Kramer. Posthospital care transitions: patterns, complications, and risk identification. *Health Serv Res*, 39(5):1449–1465, Oct 2004. 15333117[pmid].
- [7] S. Cui, D. Wang, Y. Wang, P.-W. Yu, y Y. Jin. An improved support vector machine-based diabetic readmission prediction. *Computer Methods and Programs in Biomedicine*, 166:123 – 135, 2018.
- [8] S. R. Eliason. Maximum likelihood estimation. 1993.
- [9] J. Futoma, J. Morris, y J. Lucas. A comparison of models for predicting early hospital readmissions. *Journal of Biomedical Informatics*, 56:229–238, 2015.
- [10] A. Garmendia, M. Graña, J. M. Lopez-Guede, y S. Rios. Predicting patient hospitalization after emergency readmission. *Cybernetics and Systems*, 48(3):182–192, 2017.
- [11] S. F. Jencks, M. V. Williams, y E. A. Coleman. Rehospitalizations among patients in the medicare fee-for-service program. *New England Journal of Medicine*, 360(14):1418–1428, 2009. PMID: 19339721.
- [12] D. Kansagara, H. Englander, A. Salanitro, D. Kagen, C. Theobald, M. Freeman, y S. Kripalani. Risk prediction models for hospital readmission. *JAMA*, 306(15):1688, Oct 2011.
- [13] Z. Kmietowicz. Hospitals will be fined for emergency readmissions, says lansley. *BMJ*, 340, 2010.
- [14] V. López, A. Fernández, S. García, V. Palade, y F. Herrera. An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics. *Information Sciences*, 250:113–141, 2013.
- [15] C. K. McIlvennan, Z. J. Eapen, y L. A. Allen. Hospital readmissions reduction program. *Circulation*, 131(20):1796–1803, May 2015.
- [16] M. M. Nakamura, S. L. Toomey, A. M. Zaslavsky, J. G. Berry, S. A. Lorch, A. K. Jha, M. C. Bryant, A. T. Geanacopoulos, S. S. Loren, D. Pain, y M. A. Schuster. Measuring pediatric hospital readmission rates to drive quality improvement. *Academic Pediatrics*, 14(5, Supplement):S39 – S46,

2014. Advances in Children's Healthcare Quality: The Pediatric Quality Measures Program.
- [17] J. R. Quinlan. Induction of decision trees. *Machine Learning*, 1(1):81–106, 1986.
- [18] A. Rajkomar, E. Oren, K. Chen, A. M. Dai, N. Hajaj, M. Hardt, P. J. Liu, X. Liu, J. Marcus, M. Sun, P. Sundberg, H. Yee, K. Zhang, Y. Zhang, G. Flores, G. E. Duggan, J. Irvine, Q. Le, K. Litsch, A. Mossin, J. Tansuwan, D. Wang, J. Wexler, J. Wilson, D. Ludwig, S. L. Volchenbom, K. Chou, M. Pearson, S. Madabushi, N. H. Shah, A. J. Butte, M. D. Howell, C. Cui, G. S. Corrado, y J. Dean. Scalable and accurate deep learning with electronic health records. *npj Digital Medicine*, 1(1):18, 2018.
- [19] B. K. Reddy y D. Delen. Predicting hospital readmission for lupus patients: An rnn-lstm-based deep-learning methodology. *Computers in Biology and Medicine*, 101:199 – 209, 2018.
- [20] K. Shameer, K. W. Johnson, A. Yahi, R. Miotto, L. Li, D. Ricks, J. Jebarakan, P. Kovatch, P. P. Sengupta, S. Gelijns, A. Moskovitz, B. Darrow, D. L. David, A. Kasarkis, N. P. Tatonetti, S. Pinney, y J. T. Dudley. Predictive modeling of hospital readmission rates using electronic medical record-wide machine learning: A case-study using mount sinai heart failure cohort. In *Pacific Symposium on Biocomputing 2017*, páginas 276–287, 2017.
- [21] M. J. Swain y H. Kharrazi. Feasibility of 30-day hospital readmission prediction modeling based on health information exchange data. *International Journal of Medical Informatics*, 84(12):1048 – 1056, 2015.
- [22] M. Vukicevic, S. Radovanovic, A. Kovacevic, G. Stiglic, y Z. Obradovic. Improving hospital readmission prediction using domain knowledge based virtual examples. In L. Uden, M. Heričko, y I.-H. Ting, editors, *Knowledge Management in Organizations*, páginas 695–706, Cham, 2015. Springer International Publishing.
- [23] P. Wolff, M. Graña, S. A. Ríos, y M. B. Yarza. Machine Learning Readmission Risk Modeling: A Pediatric Case Study. *BioMed Research International*, 2019:9, 2019.
- [24] P. Wolff, S. A. Ríos, y M. Graña. Setting up standards: A methodological proposal for pediatric triage machine learning model construction based on clinical outcomes. *Expert Systems with Applications*, 138:112788, 2019.

- [25] C. Xiao, T. Ma, A. B. Dieng, D. M. Blei, y F. Wang. Readmission prediction via deep contextual embedding of clinical concepts. *PLOS ONE*, 13(4):1–15, 04 2018.
- [26] B. Zheng, J. Zhang, S. W. Yoon, S. S. Lam, M. Khasawneh, y S. Poranki. Predictive modeling of hospital readmissions using metaheuristics and data mining. *Expert Systems with Applications*, 42(20):7110 – 7120, 2015.