


## ARTÍCULO DE REVISIÓN

# Modelos de predicción en trasplantes: Estado del arte y aplicaciones

## Predictive models in transplants: State of the art and applications

Santiago Cabas, MD<sup>1</sup> , Andrea García-López, MD, MSc<sup>1</sup> ,  
Andrea Gómez-Montero, MD, MSc<sup>1</sup> , Luis Alejandro Anichiarico-Castillo, MD<sup>2</sup> ,  
Juan Andrés Sarmiento-Gallego, MD<sup>2</sup> , Fernando Girón-Luque, MD, MHPE<sup>1,3</sup> 

1 Departamento de Investigación, Colombiana de Trasplantes, Bogotá, D.C., Colombia

2 Facultad de Medicina, Universidad de los Andes, Bogotá, D.C., Colombia

3 Departamento de Cirugía en Trasplantes, Colombiana de Trasplantes, Bogotá, D.C., Colombia

### Resumen

**Introducción.** Los modelos de predicción son utilizados en la cirugía de trasplantes para personalizar tratamientos y anticipar resultados, como supervivencia del injerto y mortalidad. El objetivo de este artículo fue revisar las herramientas empleadas en trasplantes de órganos sólidos para la identificación de factores de riesgo y la optimización de tratamientos.

**Métodos.** Se realizó una revisión de la literatura sobre herramientas de predicción en trasplantes de órganos sólidos. Adicionalmente, se presentó un ejemplo práctico de regresión logística aplicada a trasplantes hepáticos, mostrando el desarrollo, evaluación y validación de modelos predictivos en contextos clínicos reales.

**Resultados.** Comparadas con las técnicas tradicionales, las técnicas de *machine learning* permiten procesar grandes volúmenes de datos complejos. Así incrementan la precisión en la identificación de factores de riesgo y el desempeño de los modelos predictivos. El ejemplo práctico usó una regresión logística para la predicción de resultados en trasplantes hepáticos. Se identificaron desafíos como la necesidad de validación externa para verificar la aplicabilidad en diversas poblaciones y la adaptación a las prácticas clínicas en constante cambio.

**Conclusiones.** La integración de los modelos predictivos con la inteligencia artificial y una validación rigurosa son elementos clave para su implementación en la medicina personalizada, lo que puede influir en la supervivencia y la calidad de vida de los pacientes trasplantados. Además, se considera importante abordar las implicaciones éticas en la asignación de órganos que puedan surgir a partir de la creación de nuevos modelos.

**Palabras clave:** trasplante de órganos; factores de riesgo; medición de riesgo; predicción; inteligencia artificial; aprendizaje automático.

---

Fecha de recibido: 20/11/2024 - Fecha de aceptación: 29/01/2025 - Publicación en línea: 25/03/2025

Correspondencia: Andrea García-López, Av. Carrera 30 # 47A - 47, Colombiana de Trasplantes, Bogotá, D.C., Colombia.

Teléfono: +57 3005024618. Dirección electrónica: [aegarcia@colombianadetrasplantes.com](mailto:aegarcia@colombianadetrasplantes.com)

Citar como: Cabas S, García-López A, Gómez-Montero A, Anichiarico-Castillo LA, Sarmiento-Gallego JA, Girón-Luque F. Modelos de predicción en trasplantes: Estado del arte y aplicaciones. Rev Colomb Cir. 2025;40:(en prensa).

<https://doi.org/10.30944/20117582.2813>

Este es un artículo de acceso abierto bajo una Licencia Creative Commons - BY-NC-ND <https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>

## Abstract

**Introduction.** Prediction models are used in transplant surgery to personalize treatments and anticipate outcomes, such as graft survival and mortality. The aim of this article was to review the tools used in solid organ transplants for the identification of risk factors and the optimization of treatments.

**Methods.** A literature review on prediction tools in solid organ transplants was conducted. Additionally, a practical example of logistic regression applied to liver transplants was presented, showing the development, evaluation and validation of predictive models in real clinical contexts.

**Results.** Compared to traditional techniques, machine learning techniques can process large volumes of complex data. This increases the accuracy of identifying risk factors and the performance of predictive models. The practical example used logistic regression to predict outcomes in liver transplants. Challenges were identified such as the need for external validation to verify applicability in diverse populations and adaptation to constantly changing clinical practices.

**Conclusions.** The integration of predictive models with artificial intelligence and rigorous validation are key elements for their implementation in personalized medicine, which can influence the survival and quality of life of transplant patients. In addition, it is considered important to address the ethical implications in organ allocation that may arise from the creation of new models.

**Keywords:** organ transplantation; risk factors; risk assessment; prediction; artificial intelligence; machine learning.

## Introducción

Los modelos clínicos de predicción han transformado la medicina ofreciendo herramientas capaces de estimar con precisión el desarrollo de eventos futuros en los pacientes, lo cual resulta especialmente valioso en el ámbito de los trasplantes<sup>1</sup>. Para comprender mejor su uso, es esencial diferenciar entre modelos explicativos, que se centran en analizar las relaciones causales entre variables, y modelos predictivos, cuyo objetivo principal es anticipar con exactitud los resultados futuros<sup>2</sup>. Esta capacidad no solo optimiza la toma de decisiones, sino que también permite personalizar los tratamientos, mejorando de manera significativa la calidad de la atención médica<sup>1</sup>.

A lo largo del tiempo, los modelos de predicción han sido cruciales en trasplantes, como el renal y hepático, ayudando a anticipar complicaciones y mejorar la supervivencia del injerto<sup>3</sup>. Sin embargo, su implementación clínica es compleja por la variabilidad en la calidad de los órganos y las características de los receptores, lo que ha llevado a crear modelos más específicos. Un ejemplo temprano es el modelo de Hennige M, et

al.<sup>4</sup>, desarrollado en 1986 para predecir el éxito del trasplante renal, y refinado en 1995 por van Houwelingen HC & Thorogood J, garantizando su relevancia clínica a lo largo del tiempo<sup>3</sup>.

El objetivo de este artículo fue revisar las aplicaciones que existen, las oportunidades y los desafíos actuales de los modelos de predicción en trasplantes, buscando mejorar la precisión en la toma de decisiones y personalizando los tratamientos. Se presenta un ejemplo práctico en trasplante hepático y se dan recomendaciones para implementarlo efectivamente en la práctica clínica.

## Aplicaciones de los modelos de predicción en trasplantes

Los modelos de predicción son herramientas esenciales en el trasplante de órganos, no solo para la selección de donantes y receptores, sino también para abordar desafíos clínicos más complejos. Estos modelos son cruciales para evaluar complicaciones postrasplantes, estimar la supervivencia, mejorar la calidad de vida de los pacientes y predecir otros desenlaces clínicos relevantes<sup>4-9</sup>.

En el trasplante renal, uno de los modelos más destacados es el KDRI (*Kidney Donor Risk Index*), desarrollado por el Registro Americano de Trasplantes. Este índice evalúa el riesgo relativo de pérdida del injerto basándose en factores del donante como la edad, el peso y los antecedentes personales. El KDRI se utiliza para calcular el KDPI (*Kidney Donor Profile Index*), evaluando la calidad del riñón donado y la sobrevida del injerto<sup>5-7</sup>. Otros modelos más recientes, como los KIDMO (*Clinical Kidney Prediction Models*), han demostrado su eficacia al predecir desenlaces específicos en trasplante renal, incluyendo no solo la supervivencia del injerto, sino también indicadores alternativos de la progresión de la enfermedad renal postrasplante, convirtiéndose en herramientas clave para el manejo integral de estos pacientes<sup>8</sup>.

En trasplante hepático, el puntaje SOFT (*Survival Outcomes Following Liver Transplantation*) es un modelo paradigmático diseñado para predecir supervivencia a tres meses postrasplante. Este modelo considera variables del donante, receptor y del procedimiento de trasplante, permitiendo priorizar objetivamente la lista de espera<sup>9</sup>. Más recientemente, en 2023, se desarrolló el modelo SALT-M (*Sundaram ACLF-LT-Mortality*), que predice mortalidad a un año en pacientes con insuficiencia hepática aguda sobre crónica (ACLF, *Acute-on-Chronic Liver Failure*). Este modelo, que incluye variables como la edad, índice de masa corporal y presencia de falla respiratoria, presenta un rendimiento sólido, tanto en fase de desarrollo como en validación externa, convirtiéndose en una herramienta crucial para guiar la decisión de trasplantar<sup>10</sup>.

También existen modelos de predicción en trasplantes cardíacos, pulmonares y otras áreas de la investigación clínica, lo que resalta su papel en la medicina contemporánea<sup>11,12</sup>. Se espera que estos modelos continúen mejorando, optimizando así los resultados para los pacientes<sup>13</sup>.

## Tipos de modelos de predicción en trasplantes

Los modelos de predicción se dividen en modelos diagnósticos y modelos pronósticos. Los modelos diagnósticos estiman la probabilidad de que un

paciente tenga una enfermedad o condición en el presente, mientras que los modelos pronósticos predicen la probabilidad de que ocurra un desenlace clínico en el futuro, como complicaciones postoperatorias o mortalidad<sup>14,15</sup>. Ambos modelos son fundamentales en trasplantes, al anticipar riesgos y direccionar el tratamiento personalizado.

Las herramientas estadísticas han mejorado significativamente la precisión de estos modelos. Esto ha permitido optimizar la selección de donantes y receptores, el manejo postoperatorio y la planificación del tratamiento, logrando mejores desenlaces<sup>16</sup>. En este contexto, los modelos tradicionales como la regresión logística (RL), que predice desenlaces binarios como pérdida del injerto o mortalidad postrasplante, y el análisis de supervivencia han sido esenciales para la toma de decisiones en trasplantes<sup>16</sup>. Un ejemplo es el estudio realizado en Colombia por Torres-Gutiérrez M, et al.<sup>17</sup>, en el que se analizó la no adherencia al tratamiento como un factor de riesgo independiente para pérdida del injerto y mortalidad en receptores de riñón.

Recientemente, ha aumentado el interés por los modelos basados en aprendizaje automático (ML, *machine learning*), una rama de la inteligencia artificial (IA) que permite manejar grandes volúmenes de datos y detectar relaciones complejas que los modelos tradicionales no pueden identificar<sup>18,19</sup>. La revisión sistemática de Senanayake S, et al.<sup>20</sup>, que incluyó 18 estudios en trasplante renal mostró que los modelos ML superaron a los convencionales en términos de precisión, especialmente al considerar variables pre y postrasplante. En otro estudio, Badrouchi S, et al.<sup>21</sup>, demostraron que los modelos basados en ML, como bosques aleatorios y árboles de decisión, alcanzaron un área bajo la curva (AUC-ROC, *Area under the Receiver Operating Characteristic curve*) de 0,897, superando significativamente a los modelos tradicionales.

En trasplante hepático, los modelos ML también han mostrado un rendimiento superior en predicción de la mortalidad y complicaciones postrasplante. La revisión de 23 modelos de predicción, realizada por Chongo G & Soldera J<sup>22</sup>, reveló que la mayoría de los modelos ML supera-

ron a los tradicionales, utilizando variables tanto del donante como del receptor. Además, Gulla A, et al.<sup>23</sup>, encontraron que los modelos ML, que suelen emplear más de 50 variables, superaron en rendimiento a los modelos tradicionales como el CPT (*Child-Pugh-Turcotte*), MELD (*Model for End-stage Liver Disease*) y SOFT, alcanzando una AUC-ROC de hasta 0,94. Un ejemplo adicional de la superioridad de los modelos ML es el estudio del Hospital Universitario Nacional de Seúl, en 2018, que utilizó un modelo de aumento de gradientes (GBM, *Gradient Boosting Machine*) para predecir la lesión renal aguda en pacientes con trasplante hepático, mostrando un rendimiento superior al de la RL en múltiples contextos clínicos<sup>24</sup>.

Estos desarrollos sugieren que, aunque los modelos tradicionales como la RL siguen siendo útiles, los modelos basados en ML están demostrando una mayor capacidad para manejar la complejidad y el volumen de datos en el contexto de los trasplantes, abriendo nuevas oportunidades para mejorar los resultados clínicos y personalizar la atención médica<sup>13</sup>.

## Mejores prácticas en el desarrollo y validación de modelos de predicción

### *Definición de objetivos y selección de predictores*

El desarrollo y la validación de los modelos de predicción en trasplantes requieren un enfoque riguroso que asegure la precisión, utilidad clínica y reproducibilidad de los modelos. Para esto, se deben garantizar mejores prácticas, las cuales se han publicado recientemente<sup>25</sup>.

Inicialmente, se debe definir el objetivo del modelo y seleccionar los predictores de manera informada. Esta selección debe basarse en un conocimiento previo sólido y relevancia clínica de los predictores, evitando la dependencia exclusiva de la significancia estadística, que puede llevar a sobreajustes y a expectativas poco realistas sobre el rendimiento del modelo<sup>26</sup>. Además, se debe evitar la dicotomización temprana de predictores continuos, ya que esta práctica reduce la información disponible y puede afectar negativamente la capacidad predictiva del modelo<sup>25,26</sup>.

### *Codificación y especificación del modelo*

Es crucial utilizar predictores continuos en su forma original y preespecificar la estructura del modelo basándose en conocimientos externos. Esta aproximación mejora la estabilidad del modelo y contribuye a un rendimiento más consistente<sup>26</sup>. Es fundamental evitar el sobreajuste, especialmente en conjuntos de datos pequeños, asegurando un modelo generalizable y aplicable en diferentes contextos clínicos<sup>25</sup>.

### *Validación del modelo*

La validación del modelo es un paso crítico para su desarrollo. La validación interna, utilizando técnicas como el *bootstrap* o la validación cruzada, evalúa la estabilidad del modelo dentro del conjunto de datos original. La validación externa garantiza que el modelo sea aplicable en poblaciones distintas a la de desarrollo<sup>15,27</sup>. Para asegurar un rendimiento confiable, los modelos deben validarse en múltiples cohortes grandes antes de su implementación clínica<sup>26</sup>.

### *Evaluación del rendimiento del modelo*

La evaluación del rendimiento del modelo debe incluir calibración, que mide la concordancia entre los riesgos predichos y observados, y discriminación, que evalúa la capacidad del modelo para diferenciar entre pacientes que experimentarán el evento de interés y aquellos que no lo harán<sup>25</sup>. Utilizar múltiples medidas de precisión, como la AUC-ROC, la especificidad y la sensibilidad, permite analizar el rendimiento del modelo<sup>28</sup>.

### *Implementación clínica de los modelos de predicción*

La implementación de los modelos de predicción en la práctica clínica debe realizarse de manera transparente y reproducible. El uso de un marco estandarizado, como el propuesto por Reys JM, et al.<sup>29</sup>, facilita la replicación de estudios y la validación externa de los modelos, para adoptarlos en la práctica clínica. Sin embargo, antes de implementarlos, es esencial validar los modelos prospectivamente en cohortes externas, asegurando que su rendimiento no se sobreestime.

Además, la integración del modelo en herramientas clínicas, como aplicaciones móviles o calculadoras web, puede mejorar su accesibilidad y eficacia en la práctica diaria<sup>30</sup>.

### **Seguridad y mitigación de sesgos en modelos basados en inteligencia artificial**

Es imprescindible cumplir con las normativas de privacidad y protección de datos, al tiempo que se identifican y mitigan posibles sesgos algorítmicos que podrían afectar la equidad y la efectividad del modelo<sup>31</sup>.

### **Transparencia en el reporte de los modelos**

Finalmente, la transparencia en el reporte de los modelos es fundamental. Se deben seguir las directrices de la declaración TRIPOD (*Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis*), y asegurar que se informe de manera completa y detallada sobre el proceso de desarrollo y validación del modelo, lo cual es crucial para la reproducibilidad y la confiabilidad de los resultados<sup>27</sup>.

### **Ejemplo práctico: Regresión logística para predicción en trasplantes hepáticos**

En este ejemplo práctico, se ilustra el desarrollo y validación de un modelo de predicción para identificar la probabilidad de que un paciente muera antes de recibir un trasplante. El análisis se llevó a cabo utilizando RStudio con R versión 4.3.3 (Team RC. R: A language and environment for statistical computing [Internet]. Vienna, Austria: R Foundation for statistical computing; 2024. <https://www.R-project.org/>).

Los datos utilizados provienen de un conjunto de datos público sobre listas de espera para trasplantes de hígado, disponible en Kaggle® (Ashfaq JMA. Liver transplant waiting list. Kaggle; 2020. Disponible en: <https://www.kaggle.com/datasets/ukveteran/liver-transplant-waiting-list>).

### **Ejecutar el análisis directamente en R**

Para ejecutar el análisis completo, basta con copiar y pegar el siguiente *script* en RStudio:

```
if (!requireNamespace("downloader",
  quietly = TRUE))
  install.packages("downloader")
if (!requireNamespace("rmarkdown",
  quietly = TRUE))
  install.packages("rmarkdown")
library(downloader)
library(rmarkdown)
markdown_url <-
  paste0("https://raw.githubusercontent.com/",
    "ColTrasplantes/Prediccion/main/",
    "modelo_prediccion.Rmd")
markdown_dest <- tempfile(fileext = ".Rmd")
download.file(markdown_url,
  destfile = markdown_dest)
html_output <- tempfile(fileext = ".html")
rmarkdown::render(markdown_dest,
  output_format = "html_document",
  output_file = html_output)
Sys.sleep(2)
browseURL(html_output)
```

Este *script* descarga automáticamente la base de datos desde GitHub y ejecuta el análisis mostrándolo en un archivo R Markdown. La salida en HTML se muestra directamente. De igual modo, en los documentos suplementarios (ver anexo 1) se encuentra un archivo formato PDF que muestra la salida del código ejecutado en R, incluyendo las líneas de código, el análisis de los resultados y su interpretación.

### **Paso 1: Definición del problema y exploración de datos**

Definir un objetivo claro y específico es fundamental para guiar el proceso de modelado y garantizar que el modelo final sea clínicamente relevante<sup>15,25</sup>. En este caso es predecir si un paciente morirá antes de recibir un trasplante.

Para ello, se procede a cargar los datos en el entorno de trabajo en RStudio y se inspeccionan mediante funciones como `summary()` y `str()`, observando el resumen estadístico y la estructura de las variables. Esta inspección es crucial para identificar valores faltantes, tipos de datos (numéricos o categóricos) y detectar posibles anomalías, permitiendo una planificación adecuada para el modelado posterior<sup>15</sup>.

```
url <- paste0("https://raw.githubusercontent.com/ColTrasplantes/Prediccion/",
"main/transplant.csv")
transplant <- read.csv(url)
summary(transplant)
str(transplant)
```

### Paso 2: Codificación de los predictores

En este paso, las variables categóricas se convierten en factores utilizando funciones como `as.factor()` para que puedan ser procesadas adecuadamente por el modelo. Además, se recodifica la variable de resultado para que sea binaria: 1 si el paciente murió antes del trasplante, y 0 si fue trasplantado o censurado. La correcta codificación es esencial para que el modelo de regresión logística pueda interpretar y procesar adecuadamente los datos categóricos y el resultado binario<sup>15,25</sup>.

```
transplant$sex <- as.factor(transplant$sex)
transplant$abo <- as.factor(transplant$abo)
transplant$event <- as.factor(transplant$event)
transplant$event_binary <- ifelse(transplant$event == "death", 1, 0)
```

### Paso 3: Especificación del modelo

Para predecir la probabilidad de muerte antes del trasplante, se desarrolla un modelo de regresión logística utilizando la función `glm()` en R. En la

especificación del modelo, se seleccionan como variables predictoras relevantes la edad, el sexo, el tipo de sangre (ABO) y el tiempo en la lista de espera. En este caso particular, se decidió no incluir el año de ingreso en la lista de espera, ya que su impacto está adecuadamente representado a través del tiempo de espera, que es la variable de mayor interés en este contexto.

```
modelo_logistico <- glm(event_binary ~ age +
sex + abo + futime,
data = transplant,
family = binomial)
```

### Paso 4: Estimación del modelo

Los coeficientes del modelo se estiman mediante el método de máxima verosimilitud, utilizando la función `summary()` sobre el modelo ajustado. El resumen del modelo ofrece información crucial sobre los coeficientes, lo que permite interpretar la influencia de cada predictor sobre la probabilidad de muerte antes del trasplante. Los coeficientes positivos sugieren un aumento en la probabilidad de muerte, mientras que los valores p se utilizan para determinar la significancia estadística de los predictores<sup>15</sup>. La tabla 1 muestra los resultados del modelo de regresión logística que explica el riesgo de muerte en este modelo que incluyó 790 observaciones después de excluir datos faltantes. `summary(modelo_logistico)`

**Tabla 1.** Resultados del modelo de regresión logística para el desenlace muerte.

Variable	Estimación ( $\beta$ )	Error Estándar	Valor Z	Valor p	Significancia
Intercepto	-3,728	0,755	-4,941	<0,001	p < 0,001
Edad	0,019	0,013	1,459	0,145	-
Sexo (masculino)	0,433	0,268	1,613	0,107	-
Grupo ABO AB	0,117	0,644	0,181	0,856	-
Grupo ABO B	0,485	0,407	1,193	0,233	-
Grupo ABO O	0,511	0,299	1,708	0,088	p < 0,1
Tiempo de seguimiento	-0,001	0,001	-1,748	0,08	p < 0,1

Fórmula del modelo: Muerte ~ Edad + Sexo + Grupo ABO + Tiempo de seguimiento

Fuente: elaborada por los autores.

### Paso 5: Evaluación del rendimiento del modelo

El rendimiento del modelo se evalúa utilizando la AUC-ROC, para medir la discriminación, y el test de Hosmer-Lemeshow para la calibración. Estos cálculos se realizan en R utilizando los paquetes pROC y ResourceSelection, respectivamente. Una AUC-ROC cercana a 1 indica excelente discriminación, mientras que un valor de p alto en el test de Hosmer-Lemeshow indica buena calibración, lo que significa que las predicciones del modelo están alineadas con las observaciones reales<sup>15,25</sup>.

```
transplant <- na.omit(transplant) # Se eliminan
valores faltantes para evitar errores en las
predicciones
predicciones <- predict(modelo_logistico, type
= "response")
library(pROC)
roc_curve <- roc(transplant$event_binary, pre-
dicciones)
auc_valor <- auc(roc_curve)
auc_valor
hoslem_test <- hoslem.test(transplant$event_
```

```
binary, fitted(modelo_logistico))
hoslem_test
```

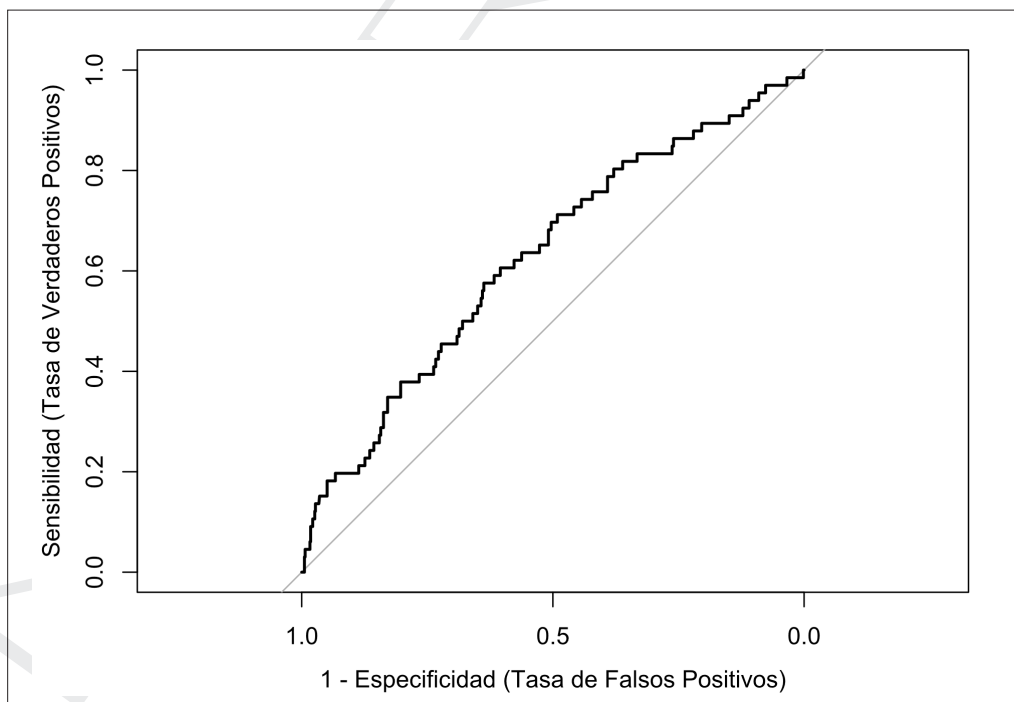
### Paso 6: Validación interna

La validación cruzada mide la estabilidad y la capacidad de generalización del modelo. Esto se realiza utilizando el paquete boot en R mediante re-muestreo. Un bajo error de validación cruzada sugiere que el modelo es robusto y tiene buen rendimiento en nuevos datos, esencial para confirmar la utilidad clínica del modelo antes de su implementación<sup>15,25</sup>.

```
library(boot)
set.seed(123)
cv_error <- cv.glm(transplant, modelo_logis-
tico, K=10)$delta(1)
cv_error
```

### Paso 7: Presentación del modelo

Para facilitar la interpretación clínica, se presenta el modelo de manera visual, incluyendo la curva ROC y una curva de calibración. La Figura 1 muestra la curva ROC con la relación entre la tasa de



**Figura 1.** Curva ROC del modelo.

Fuente: elaborada por los autores.

verdaderos positivos y la tasa de falsos positivos y permite evaluar la capacidad discriminativa del modelo. Una curva ROC que se aproxima al vértice superior izquierdo indica una excelente capacidad discriminativa del modelo. Por otro lado, la Figura 2 muestra la curva de calibración, que compara las predicciones del modelo con las observaciones reales; cuando los puntos están cerca de la línea diagonal, indica que el modelo está bien calibrado, es decir, que las predicciones están alineadas con los resultados observados<sup>15,25</sup>.

```
plot(roc_curve, main=sprintf("Curva ROC del
Modelo (AUC = %.2f)", auc_valor))
transplant$deciles <- cut(predicciones, breaks
= quantile(predicciones, probs = seq(0, 1,
0.1)), include.lowest = TRUE)
observed <- tapply(transplant$event_binary,
transplant$deciles, mean)
predicted <- tapply(predicciones, transplant$-
deciles, mean)
plot(predicted, observed,
xlab = "Riesgo Predicho",
ylab = "Proporción Observada",
```

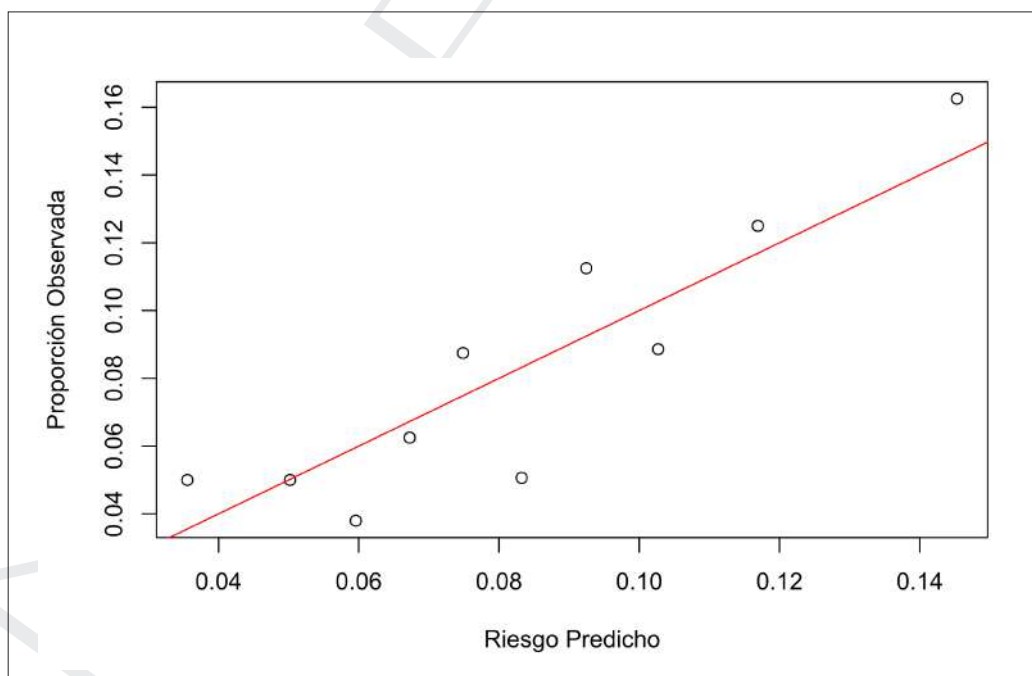
```
main = "Curva de Calibración")
abline(0, 1, col = "red")
```

### **Paso 8: Validación externa**

Aunque en este ejemplo no se realizó una validación externa debido a la falta de bases de datos comparables, es importante mencionar que este paso es fundamental para evaluar la aplicabilidad del modelo en diferentes poblaciones o contextos clínicos. La validación externa permite confirmar que el modelo es generalizable y útil en otros escenarios, lo cual es crucial para su implementación efectiva en la práctica clínica<sup>15,25</sup>.

### **Paso 9: Uso del modelo de predicción**

Finalmente, se ilustra cómo utilizar el modelo para predecir la probabilidad de muerte antes del trasplante en un nuevo paciente. Si la probabilidad predicha es alta (> 50 %), se sugiere priorizar al paciente debido a su alto riesgo de muerte antes del trasplante. Por el contrario, una probabilidad baja indicaría una mayor probabilidad de que el paciente reciba el trasplante a



**Figura 2.** Curva de calibración del modelo.

Fuente: elaborada por los autores.



tiempo. Este enfoque permite a los clínicos tomar decisiones más informadas sobre la priorización de pacientes en la lista de espera, asegurando que aquellos con mayor riesgo sean tratados con mayor urgencia<sup>15,25</sup>.

Este tipo de visualización es crucial para que los clínicos puedan evaluar la precisión y la confiabilidad del modelo en la práctica clínica, permitiendo una toma de decisiones más informada y basada en evidencia.

```
nuevo_paciente <- data.frame(age = 50,
sex = factor("m", levels = levels(transplant$sex)),
abo = factor("O", levels = levels(transplant$abo)),
futime = 365)
str(nuevo_paciente)
prediccion_nuevo <- predict(modelo_logistico,
newdata = nuevo_paciente, type = "response")
prediccion_nuevo
probabilidad_muerte <- round(prediccion_nuevo * 100, 2)
cat("La probabilidad predicha de que el paciente muera antes del trasplante es:", probabilidad_muerte, "%.\n")
```

### Oportunidades, desafíos y limitaciones de los modelos de predicción

La aplicación de IA en calculadoras para predecir desenlaces perioperatorios ha demostrado su capacidad para identificar riesgos de forma temprana y precisa, gracias a modelos de ML con alta sensibilidad. Esta tecnología podría aplicarse en el área de trasplantes para facilitar la detección oportuna de pacientes de alto riesgo, mejorar la toma de decisiones clínicas y optimizar la recolección de datos, contribuyendo así a la validación continua de los modelos y su adaptación a diferentes poblaciones<sup>32</sup>.

Sin embargo, la investigación en predicción enfrenta desafíos importantes que limitan su aplicabilidad y generalización. Uno de los principales desafíos es la dependencia de datos retrospectivos, que a menudo son incompletos o inconsistentes, lo que puede afectar la precisión de los modelos.

Como lo mencionaron Hallaji E, et al.<sup>33</sup>, la exclusión de pacientes con información incompleta para estudios resulta en pérdida de la eficiencia en el desarrollo de publicaciones, por lo cual muchas veces se estima sobre los datos faltantes.

Además, los cambios en las prácticas clínicas a lo largo del tiempo pueden hacer que los datos históricos no sean representativos de las condiciones actuales, comprometiendo la validez de los modelos y llevando a resultados dudosos en la práctica clínica. Un ejemplo claro de esta limitación se observa en el estudio de van Houwelingen HC, et al.<sup>3</sup>, donde los datos recopilados entre 1984 y 1987 tuvieron que ser recalibrados debido a los cambios en el manejo de los pacientes en años posteriores.

Otro reto es la falta de validación externa en la mayoría de los modelos desarrollados<sup>33</sup>. Investigaciones previas revelaron que pocos estudios incluyen validación externa, limitando su generalización y utilidad en la práctica clínica diaria<sup>34</sup>. Sin esta validación, es difícil asegurar que un modelo mantendrá su rendimiento cuando se aplique en una población distinta, lo que podría llevar a errores en la toma de decisiones clínicas<sup>34,35</sup>.

Además de los desafíos metodológicos, existen también consideraciones éticas en el uso de los modelos de predicción en trasplantes. Los enfoques utilizados para la asignación de órganos, como el enfoque utilitario, que prioriza a los pacientes con mejor pronóstico postrasplante, o el enfoque basado en la urgencia, que favorece a los pacientes con mayor riesgo de mortalidad pretrasplante, plantean dilemas éticos significativos. Estos enfoques pueden resultar en la exclusión de pacientes que, aunque gravemente enfermos, podrían beneficiarse de un trasplante, cuestionando la equidad y la justicia en la distribución de unos recursos médicos limitados<sup>36,37</sup>. Además, la subjetividad en la evaluación de ciertas variables y la posibilidad de manipulación de los resultados por parte de los clínicos son preocupaciones adicionales que deben abordarse para garantizar la integridad y la transparencia en la toma de decisiones<sup>36</sup>.

## Conclusión

Los modelos de predicción son fundamentales en la donación y trasplantes, al personalizar tratamientos y anticipar resultados, como la supervivencia del injerto y la mortalidad, mejorando así la calidad de vida de los pacientes. Herramientas como el KDRI y el SOFT han demostrado su eficacia en trasplantes renales y hepáticos, mientras que las técnicas de ML han incrementado la precisión y capacidad de manejo de datos complejos. No obstante, persisten desafíos importantes, como la necesidad de una validación externa rigurosa y la actualización a las prácticas clínicas cambiantes. Se requieren mejores alternativas en el desarrollo de estos modelos, asegurando una selección adecuada de predictores y una evaluación exhaustiva de su desempeño. La integración de IA y una validación robusta permitirán optimizar aún más los resultados en trasplantes, consolidando estos modelos como herramientas clave en la medicina personalizada.

## Cumplimiento de normas éticas

**Consentimiento informado:** Este estudio cumple con los principios éticos establecidos en la Resolución 8430 de 1993 del Ministerio de Salud de Colombia, que regula las normas científicas, técnicas y administrativas para la investigación en salud. Dado que este artículo es una revisión de la literatura con un ejemplo práctico de análisis de datos y no incluye datos identificables de pacientes ni casos clínicos específicos, no fue necesario obtener consentimiento informado adicional.

**Conflictos de interés:** Los autores declararon que no existen conflictos de interés que pudieran haber influido en la realización del estudio ni en la interpretación de sus resultados.

**Uso de Inteligencia Artificial:** Durante el desarrollo del estudio, se utilizaron modelos de lenguaje (LLM) para la corrección del código empleado en el ejemplo práctico de regresión logística. Estas herramientas fueron utilizadas únicamente para mejorar la calidad técnica del análisis y no influyeron en los resultados obtenidos ni en su interpretación.

**Fuentes de financiación:** El estudio fue financiado exclusivamente con recursos internos de Colombiana de Trasplantes.

## Contribución de los autores

- Diseño y concepción del estudio: Santiago Cabas, Andrea García-Lopez, Fernando Girón-Luque.
- Adquisición de datos: Santiago Cabas, Andrea Gómez-Montero.
- Análisis e interpretación de datos: Santiago Cabas, Andrea García-Lopez, Andrea Gómez-Montero.
- Redacción del manuscrito: Santiago Cabas, Luis Alejandro Anichiarico-Castillo, Juan Andrés Sarmiento-Gallego.
- Revisión crítica del manuscrito: Andrea García-Lopez, Andrea Gómez-Montero, Fernando Girón-Luque.

## Referencias

1. Isaza-Jaramillo S, Jaimes-Barragán F. Ronda clínica y epidemiológica: aproximación a los modelos de predicción clínica. *Iatreia*. 2017;30:92-9. <https://doi.org/10.17533/udea.iatreia.v30n1a10>
2. Shmueli G. To explain or to predict? *Statist Sci*. 2010;25:289-310. <https://doi.org/10.1214/10-STS330>
3. van Houwelingen HC, Thorogood J. Construction, validation and updating of a prognostic model for kidney graft survival. *Stat Med*. 1999;14:1999-2008.
4. Hennige M, Köhler CO, Opelz C. Multivariate prediction model of kidney transplant success rates. *Transplantation*. 1986;42:491-3.
5. Rao PS, Schaubel DE, Guidinger MK, Andreoni KA, Wolfe RA, Merion RM, et al. A comprehensive risk quantification score for deceased donor kidneys: The kidney donor risk index. *Transplantation*. 2009;88:231-6. <https://doi.org/10.1097/TP.0b013e3181ac620b>
6. García del Moral-Martín RM, Retamero-Díaz JA, Cava-Molina M, Cobacho-Tornel BM, Bravo-Soto J, Osuna-Ortega A, et al. Validación del KDRI/KPDI para la selección de donantes renales con criterios expandidos. *Nefrología*. 2018;38:297-303. <https://doi.org/10.1016/j.nefro.2017.08.006>
7. Health Resources and Services Administration, U.S. Department of Health & Human Services. Organ Procurement and Transplantation Network. A guide to calculating and interpreting the Kidney Donor Profile Index (KDPI). Organ Procurement and Transplantation Network (OPTN); 2024. Fecha de consulta: 16 de septiembre de 2024. Disponible en: [https://optn.transplant.hrsa.gov/media/j34dm4mv/kdipi\\_guide.pdf](https://optn.transplant.hrsa.gov/media/j34dm4mv/kdipi_guide.pdf)
8. Schwab S, Sidler D, Haidar F, Kuhn C, Schaub S, Koller M, et al. Clinical prediction model for prognosis in kidney transplant recipients (KIDMO): Study protocol. *Diagn Progn Res*. 2023;7:6. <https://doi.org/10.1186/s41512-022-00139-5>

9. Rana A, Hardy MA, Halazun KJ, Woodland DC, Ratner LE, Samstein B, et al. Survival Outcomes Following Liver Transplantation (SOFT) score: A novel method to predict patient survival following liver transplantation. *Am J Transplant.* 2008;8:2537-46. <https://doi.org/10.1111/j.1600-6143.2008.02400.x>
10. Hernaiz R, Karvellas CJ, Liu Y, Sacleux SC, Khemichian S, Stein LL, et al. The novel SALT-M score predicts 1-year post-transplant mortality in patients with severe acute-on-chronic liver failure. *J Hepatol.* 2023;79:717-27. <https://doi.org/10.1016/j.jhep.2023.05.028>
11. Perry WA, Chow JK, Nelson J, Kent DM, Snyderman DR. A clinical model to predict the occurrence of select high-risk infections in the first year following heart transplantation. *Transplant Direct.* 2023;9:e1542. <https://doi.org/10.1097/TXD.0000000000001542>
12. Diamond JM, Anderson MR, Cantu E, Clausen ES, Shashaty MGS, Kalman L, et al. Development and validation of primary graft dysfunction predictive algorithm for lung transplant candidates. *J Heart Lung Transplant.* 2024;43:633-41. <https://doi.org/10.1016/j.healun.2023.11.019>
13. Gotlieb N, Azhie A, Sharma D, Spann A, Suo NJ, Tran J, et al. The promise of machine learning applications in solid organ transplantation. *NPJ Digit Med.* 2022;5:89. <https://doi.org/10.1038/s41746-022-00637-2>
14. Hendriksen JMT, Geersing GJ, Moons KGM, de Groot JAH. Diagnostic and prognostic prediction models. *J Thromb Haemost.* 2013;11(Suppl 1):129-41. <https://doi.org/10.1111/jth.12262>
15. Moons KGM, Altman DG, Reitsma JB, Ioannidis JPA, Macaskill P, Steyerberg EW, et al. Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis (TRIPOD): Explanation and elaboration. *Ann Intern Med.* 2015;162:W1-73. <https://doi.org/10.7326/M14-0698>
16. Fiuza-Pérez MD, Rodríguez-Pérez JC. La regresión logística: Una herramienta versátil. *Nefrología.* 2000;20:495-500.
17. Torres-Gutiérrez M, Lozano-Suárez N, Burgos-Camacho VA, Caamaño-Jaraba J, Gómez-Montero JA, García-López A, et al. Is non-adherence associated with adverse outcomes in kidney transplant recipients? The role of non-adherence as a risk and predictor factor for graft loss and death. *Patient Prefer Adherence.* 2023;17:2915-25. <https://doi.org/10.2147/PPA.S436833>
18. Panch T, Szolovits P, Atun R. Artificial intelligence, machine learning and health systems. *J Glob Health.* 2018;8:020303. <https://doi.org/10.7189/jogh.08.020303>
19. Ravindhran B, Chandak P, Schafer N, Kundalia K, Hwang W, Antoniadis S, et al. Machine learning models in predicting graft survival in kidney transplantation: Meta-analysis. *BJS Open.* 2023;7:zrad011. <https://doi.org/10.1093/bjsopen/zrad011>
20. Senanayake S, White N, Graves N, Healy H, Baboolal K, Kularatna S. Machine learning in predicting graft failure following kidney transplantation: A systematic review of published predictive models. *Int J Med Inform.* 2019;130:103957. <https://doi.org/10.1016/j.ijmedinf.2019.103957>
21. Badrouchi S, Bacha MM, Ahmed A, Abdallah TB, Abderrahim E. Predicting long-term outcomes of kidney transplantation in the era of artificial intelligence. *Sci Rep.* 2023;13:21273. <https://doi.org/10.1038/s41598-023-48645-w>
22. Chongo G, Soldera J. Use of machine learning models for the prognostication of liver transplantation: A systematic review. *World J Transplant.* 2024;14:88891. <https://doi.org/10.5500/wjt.v14.i1.88891>
23. Gulla A, Jakiunaite I, Juchneviciute I, Dzemyda G. A narrative review: Predicting liver transplant graft survival using artificial intelligence modeling. *Front Transplant.* 2024;3:1378378. <https://doi.org/10.3389/frtra.2024.1378378>
24. Lee HC, Yoon HK, Nam K, Cho YJ, Kim TK, Kim WH, et al. Derivation and validation of machine learning approaches to predict acute kidney injury after cardiac surgery. *J Clin Med.* 2018;7:322. <https://doi.org/10.3390/jcm7100322>
25. Steyerberg EW, Vergouwe Y. Towards better clinical prediction models: Seven steps for development and an ABCD for validation. *Eur Heart J.* 2014;35:1925-31. <https://doi.org/10.1093/eurheartj/ehu207>
26. Steyerberg EW, Uno H, Ioannidis JPA, van Calster B, Ukaegbu C, Dhingra T, et al. Poor performance of clinical prediction models: The harm of commonly applied methods. *J Clin Epidemiol.* 2018;98:133-43. <https://doi.org/10.1016/j.jclinepi.2017.11.013>
27. Kappen TH, van Klei WA, van Wolfswinkel L, Kalkman CJ, Vergouwe Y, Moons KGM. Evaluating the impact of prediction models: Lessons learned, challenges, and recommendations. *Diagn Progn Res.* 2018;2:11. <https://doi.org/10.1186/s41512-018-0033-6>
28. Poldrack RA, Huckins G, Varoquaux G. Establishment of best practices for evidence for prediction: A review. *JAMA Psychiatry.* 2020;77:534-40. <https://doi.org/10.1001/jamapsychiatry.2019.3671>
29. Reps JM, Schuemie MJ, Suchard MA, Ryan PB, Rijnbeek PR. Design and implementation of a standardized framework to generate and evaluate patient-level prediction models using observational healthcare data. *J Am Med Inform Assoc.* 2018;25:969-75. <https://doi.org/10.1093/jamia/ocy032>
30. Lee YH, Bang H, Kim DJ. How to establish clinical prediction models. *Endocrinol Metab (Seoul).* 2016;31:38-44. <https://doi.org/10.3803/EnM.2016.31.1.38>
31. de Hond AAH, Leeuwenberg AM, Hooft L, Kant IMJ, Nijman SWJ, van Os HJA, et al. Guidelines and quality criteria for artificial intelligence-based prediction models in

- healthcare: A scoping review. NPJ Digit Med. 2022;5:2. <https://doi.org/10.1038/s41746-021-00549-7>
32. Lozano-Suárez N, Salamanca-Lozano JF, Cabrera-Rivera PA, Briceño-Ayala L, Pérez-Rivera CJ. Inteligencia artificial en cirugía: creación y validación de una calculadora colombiana de riesgo de mortalidad perioperatoria. Rev Colomb Cir. 2025;40:67-78. <https://doi.org/10.30944/20117582.2741>
  33. Hallaji E, Razavi-Far R, Palade V, Saif M. Adversarial learning on incomplete and imbalanced medical data for robust survival prediction of liver transplant patients. IEEE Access. 2021;9:73641-50. <https://doi.org/10.1109/ACCESS.2021.3081040>
  34. Ramspek CL, Jager KJ, Dekker FW, Zoccali C, van Diepen M. External validation of prognostic models: What, why, how, when and where? Clin Kidney J. 2021;14:49-58. <https://doi.org/10.1093/ckj/sfaa188>
  35. van Calster B, Steyerberg EW, Wynants L, van Smeden M. There is no such thing as a validated prediction model. BMC Med. 2023;21:70. <https://doi.org/10.1186/s12916-023-02779-w>
  36. Ahearn A. Ethical dilemmas in liver transplant organ allocation: Is it time for a new mathematical model? AMA J Ethics. 2016;18:126-32. <https://doi.org/10.1001/journalofethics.2017.18.2.nlit1-1602>
  37. Merion RM, Sharma P, Mathur AK, Schaubel DE. Evidence-based development of liver allocation: A review. Transpl Int. 2011;24:965-72. <https://doi.org/10.1111/j.1432-2277.2011.01274.x>