

# Ajuste de Riesgo, Hospitalizaciones Innecearias y Aprendizaje de Máquinas

Álvaro J. Riascos Villegas <sup>1</sup>  
Natalia Serna <sup>2</sup>    Mauricio Romero <sup>3</sup>

<sup>1</sup>Universidad de los Andes and Quantil

<sup>2</sup>University of Wisconsin


<sup>3</sup>University of California, San Diego

# Contents

- 1 Sector Salud y Aprendizaje de Máquinas
- 2 Dos Aplicaciones: Hospitalizaciones y Ajuste de Riesgo
- 3 Hospitalizaciones Innecearias
  - Literatura Relacionada
  - Datos
  - Modelo de Apredizaje de Máquinas
  - Modelo Teoría de la Decisión
  - Resultados: Ahorro potencial
- 4 Ajuste de Riesgo
  - Problemas
  - Propuestas
  - Resultados

# Motivación

Machine learning has broad potential across industries and use cases



SOURCE: McKinsey Global Institute analysis

## Introducción: Hospitalizaciones Innecesarias

- Hospitalizaciones evitables son una fuente de incrementos en el gasto en salud.
- En Estados Unidos se estima en más USD 30 billones el costo de las hospitalizaciones innecesarias (Health Heritage Prize).
- Para darse una idea, Health Heritage Foundation ofreció 3 millones de dólares en premios al mejor modelo predictivo de hospitalizaciones.

## Introducción: Hospitalizaciones Innecesarias

- Hospitalizaciones evitables son una fuente de incrementos en el gasto en salud.
- En Estados Unidos se estima en más USD 30 billones el costo de las hospitalizaciones innecesarias (Health Heritage Prize).
- Para darse una idea, Health Heritage Foundation ofreció 3 millones de dólares en premios al mejor modelo predictivo de hospitalizaciones.

## Introducción: Hospitalizaciones Innecesarias

- Hospitalizaciones evitables son una fuente de incrementos en el gasto en salud.
- En Estados Unidos se estima en más USD 30 billones el costo de las hospitalizaciones innecesarias (Health Heritage Prize).
- Para darse una idea, Health Heritage Foundation ofreció 3 millones de dólares en premios al mejor modelo predictivo de hospitalizaciones.

# Introducción: Ajuste de Riesgo

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Usando un modelo de regresión lineal, el gobierno distribuye más de COP 24 billones de pesos entre las EPSs.
- Esto se hace usando como principal insumo la base de suficiencia que registra todas las atenciones, servicios, hospitalizaciones, etc. de 20 millones de Colombiano en el POS (tiene más de 450 millones de registros).

# Introducción: Ajuste de Riesgo

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Usando un modelo de regresión lineal, el gobierno distribuye más de COP 24 billones de pesos entre las EPSs.
- Esto se hace usando como principal insumo la base de suficiencia que registra todas las atenciones, servicios, hospitalizaciones, etc. de 20 millones de Colombiano en el POS (tiene más de 450 millones de registros).



# Introducción: Ajuste de Riesgo

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Usando un modelo de regresión lineal, el gobierno distribuye más de COP 24 billones de pesos entre las EPSs.
- Esto se hace usando como principal insumo la base de suficiencia que registra todas las atenciones, servicios, hospitalizaciones, etc. de 20 millones de Colombiano en el POS (tiene más de 450 millones de registros).

# Introducción: Ajuste de Riesgo

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Usando un modelo de regresión lineal, el gobierno distribuye más de COP 24 billones de pesos entre las EPSs.
- Esto se hace usando como principal insumo la base de suficiencia que registra todas las atenciones, servicios, hospitalizaciones, etc. de 20 millones de Colombiano en el POS (tiene más de 450 millones de registros).

## Introducción

- Usamos un panel de la base de datos de suficiencia del Ministerio de Salud y Protección Social entre 2009 - 2011.
- Contribuimos a la literatura con dos ideas complementarias:
  - 1 Construímos un algoritmo de aprendizaje de máquinas que predice relativamente bien los días de estancia con un año de anticipación.
  - 2 Introducimos un modelo de decisión que permite evaluar la costo efectividad de los programas de prevención de individuos con alto riesgo de hospitalización.

## Introducción

- Usamos un panel de la base de datos de suficiencia del Ministerio de Salud y Protección Social entre 2009 - 2011.
- Contribuimos a la literatura con dos ideas complementarias:
  - 1 Construimos un algoritmo de aprendizaje de máquinas que predice relativamente bien los días de estancia con un año de anticipación.
  - 2 Introducimos un modelo de decisión que permite evaluar la costo efectividad de los programas de prevención de individuos con alto riesgo de hospitalización.

## Introducción

- Usamos un panel de la base de datos de suficiencia del Ministerio de Salud y Protección Social entre 2009 - 2011.
- Contribuimos a la literatura con dos ideas complementarias:
  - 1 Construimos un algoritmo de aprendizaje de máquinas que predice relativamente bien los días de estadia con un año de anticipación.
  - 2 Introducimos un modelo de decisión que permite evaluar la costo efectividad de los programas de prevención de individuos con alto riesgo de hospitalización.

## Introducción

- Usamos un panel de la base de datos de suficiencia del Ministerio de Salud y Protección Social entre 2009 - 2011.
- Contribuimos a la literatura con dos ideas complementarias:
  - 1 Construimos un algoritmo de aprendizaje de máquinas que predice relativamente bien los días de estancia con un año de anticipación.
  - 2 Introducimos un modelo de decisión que permite evaluar la costo efectividad de los programas de prevención de individuos con alto riesgo de hospitalización.

## Literatura Relacionada

- 1 Chang et. al 2016. Prediction of Length of Stay of First-Ever Ischemic Stroke.
- 2 Ali, et.al. Predicting Hospital Length of Stay PHLOS: A Multi-Tiered Data Mining Approach.
- 3 Chertow. 2005. Acute Kidney Injury, Mortality, Length of Stay, and Costos in Hospitalized Patients.
- 4 Clague, et.al 2002. Predictors of outcome following hip fracture. Admission time predicts length of stay and in-hospital mortality.
- 5 Rezaei, et.al 2013. Use of Data Mining Techniques to Determine and Predict Length of Stay of Cardiac Patients.
- 6 **Bayati, et.al 2014. Data-Driven decisions for reducing readmissions for heart failure: general methodology and case study.**

# Datos

- Tenemos un panel de 5.7 million afiliados al regimen contributivo entre 2009 y 2011.
- Tenemos edad, sexo, localización, IPS, EPS, diagnóstico (codificación internacional ICD10) días de estancia, costo del servicio, ingreso base de cotización, etc.
- Usamos una muestra aleatoria de un millón de individuos para entrenamiento y un millón para prueba.



# Datos

- Tenemos un panel de 5.7 million afiliados al regimen contributivo entre 2009 y 2011.
- Tenemos edad, sexo, localización, IPS, EPS, diagnóstico (codificación internacional ICD10) días de estancia, costo del servicio, ingreso base de cotización, etc.
- Usamos una muestra aleatoria de un millón de individuos para entrenamiento y un millón para prueba.

# Datos

- Tenemos un panel de 5.7 million afiliados al regimen contributivo entre 2009 y 2011.
- Tenemos edad, sexo, localización, IPS, EPS, diagnóstico (codificación internacional ICD10) días de estacia, costo del servicio, ingreso base de cotización, etc.
- Usamos una muestra aleatoria de un millón de individuos para entrenamiento y un millón para prueba.

- Construimos varias características con datos entre  $t - 2$  to  $t - 1$ :

Annual LOS, average LOS, maximum LOS, second maximum LOS, indicator of annual LOS greater than 30 days, standard deviation of LOS, average cost, standard deviation of cost, average income of enrollees in each insurer, standard deviation of income in each insurer, indicators of the 10 costlier diagnoses in the sample, number of hemograms, pressure tests, CTs, creatinine tests, thyroid tests, ER services, ambulatory services, hospital services, domiciliary services, drug claims, and the number of different long-term diseases affecting each patient. We also create the number of claims per month and per day of week, indicators of long-term diseases, and interactions between indicators of hospital services, ER services, domiciliary services and ambulatory services.

- Construimos varias características con datos entre  $t - 2$  to  $t - 1$ :

Annual LOS, average LOS, maximum LOS, second maximum LOS, indicator of annual LOS greater than 30 days, standard deviation of LOS, average cost, standard deviation of cost, average income of enrollees in each insurer, standard deviation of income in each insurer, indicators of the 10 costlier diagnoses in the sample, number of hemograms, pressure tests, CTs, creatinine tests, thyroid tests, ER services, ambulatory services, hospital services, domiciliary services, drug claims, and the number of different long-term diseases affecting each patient. We also create the number of claims per month and per day of week, indicators of long-term diseases, and interactions between indicators of hospital services, ER services, domiciliary services and ambulatory services.

# The Machine Learning Task

- Tarea: Predecir los días de hospitalización en  $t$  usando la información de  $t - 1$  y  $t - 2$ . La variable dependiente es  $\ln(LOS + 1)$  en  $t$ .
- El problema es idéntico al puesto en el premio de Health Heritage Foundation.
- Como medida de rendimiento se utilizó (RMSE). El ganador del concurso obtuvo un RMSE de 0,4438 que es 2,5 veces el promedio de  $\ln(LOS + 1)$  del tercer año.

# The Machine Learning Task

- Tarea: Predecir los días de hospitalización en  $t$  usando la información de  $t - 1$  y  $t - 2$ . La variable dependiente es  $\ln(LOS + 1)$  en  $t$ .
- El problema es idéntico al puesto en el premio de Health Heritage Foundation.
- Como medida de rendimiento se utilizó (RMSE). El ganador del concurso obtuvo un RMSE de 0,4438 que es 2,5 veces el promedio de  $\ln(LOS + 1)$  del tercer año.

# The Machine Learning Task

- Tarea: Predecir los días de hospitalización en  $t$  usando la información de  $t - 1$  y  $t - 2$ . La variable dependiente es  $\ln(LOS + 1)$  en  $t$ .
- El problema es idéntico al puesto en el premio de Health Heritage Foundation.
- Como medida de rendimiento se utilizó (RMSE). El ganador del concurso obtuvo un RMSE de 0,4438 que es 2,5 veces el promedio de  $\ln(LOS + 1)$  del tercer año.

# Resultados

## Cuadro: Out-of-sample model fit

Model	MAE	RMSE	R-squared
OLS	0.4546	0.7502	0.1731
ANN	0.5032	0.7824	0.1006
RF	0.2634	0.5623	0.5354
BT	0.2721	0.5720	0.5192
ENS	0.2523	0.5609	0.5179

- El RMSE del ensemble lineal es 75 % el promedio de  $\ln(LOS + 1)$ , mientras que el ganador del premio Health Heritage es 249 %



# Resultados

Cuadro: Out-of-sample model fit

Model	MAE	RMSE	R-squared
OLS	0.4546	0.7502	0.1731
ANN	0.5032	0.7824	0.1006
RF	0.2634	0.5623	0.5354
BT	0.2721	0.5720	0.5192
ENS	0.2523	0.5609	0.5179

- El RMSE del ensemble lineal es 75 % el promedio de  $\ln(LOS + 1)$ , mientras que el ganador del premio Health Heritage es 249 %




Figura: Variation in the RMSE by percentiles of the LOS distribution

# Problema Clasificación




Figura: Prediction accuracy

# Resultados: Importancia relativa




Figura: Risk factors in the random forest model

## Modelo Teoría de la Decisión

- Siguiendo a Bayati, et.al 2014 el costo esperado de hospitalizar al individuo  $i$  es el producto entre la probabilidad de ser hospitalizado y el costo de ser hospitalizado del grupo de riesgo al que pertenece:

$$C_0(\hat{p}_i) = \hat{p}_i c_g \quad (1)$$

- Si un asegurador implementa un plan de prevención la probabilidad de ser hospitalizado disminuye de acuerdo a la eficacia del programa  $\alpha$ , pero también tiene unos costos fijos  $f$ . Si el individuo es intervenido los costos esperados son:

$$C_1(\hat{p}_i) = (1 - \alpha)\hat{p}_i c_g + f \quad (2)$$

## Modelo Teoría de la Decisión

- Siguiendo a Bayati, et.al 2014 el costo esperado de hospitalizar al individuo  $i$  es el producto entre la probabilidad de ser hospitalizado y el costo de ser hospitalizado del grupo de riesgo al que pertenece:

$$C_0(\hat{p}_i) = \hat{p}_i c_g \quad (1)$$

- Si un asegurador implementa un plan de prevención la probabilidad de ser hospitalizado disminuye de acuerdo a la eficacia del programa  $\alpha$ , pero también tiene unos costos fijos  $f$ . Si el individuo es intervenido los costos esperados son:

$$C_1(\hat{p}_i) = (1 - \alpha)\hat{p}_i c_g + f \quad (2)$$


- Luego, un individuo debe ser intervenido si:

$$\pi(\hat{p}_i|\alpha, f) = C_0(\hat{p}_i) - C_1(\hat{p}_i) \geq 0 \quad (3)$$

- Comparamos los costos esperados de utilizar el modelo de predicción con base la rela de decisión anterior contra dos escenarios (dados  $\alpha$  and  $f$ ):
  - 1 Política de no intervenir.
  - 2 Mejor intervención uniforme.



# Ahorro potencial contra no intervención



# Ahorro potencial contra intervención uniforme




Figura: Cost savings over best uniform policy

# Introducción

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Dos sistemas: Contributivo y Subsidiado. Aquí nos concentramos únicamente en el régimen contributivo.
- Por razones de equidad se estableció un sistema de subsidios cruzados donde las contribuciones dependen del nivel de ingresos del afiliado.
- El FOSYGA recauda y Ministerio redistribuye.

## Introducción

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Dos sistemas: Contributivo y Subsidiado. Aquí nos concentramos únicamente en el régimen contributivo.
- Por razones de equidad se estableció un sistema de subsidios cruzados donde las contribuciones dependen del nivel de ingresos del afiliado.
- El FOSYGA recauda y Ministerio redistribuye.

## Introducción

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Dos sistemas: Contributivo y Subsidiado. Aquí nos concentramos únicamente en el régimen contributivo.
- Por razones de equidad se estableció un sistema de subsidios cruzados donde las contribuciones dependen del nivel de ingresos del afiliado.
- El FOSYGA recauda y Ministerio redistribuye.

## Introducción

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Dos sistemas: Contributivo y Subsidiado. Aquí nos concentramos únicamente en el régimen contributivo.
- Por razones de equidad se estableció un sistema de subsidios cruzados donde las contribuciones dependen del nivel de ingresos del afiliado.
- El FOSYGA recauda y Ministerio redistribuye.

## Introducción

- La ley 100 de 1993 transformó el sistema colombiano de salud en un mercado de aseguramiento competitivo.
- Elementos fundamentales en la organización del mercado: POS, IPS, EPS, UPC.
- Dos sistemas: Contributivo y Subsidiado. Aquí nos concentramos únicamente en el régimen contributivo.
- Por razones de equidad se estableció un sistema de subsidios cruzados donde las contribuciones dependen del nivel de ingresos del afiliado.
- El FOSYGA recauda y Ministerio redistribuye.

# Eficiencia

- Contención del gasto.
- Solución:
  - 1 Pagar con anterioridad a la prestación de los servicios (pago ex-ante).
  - 2 UPC debe reflejar el gasto esperado de salud de los afiliados.



# Eficiencia

- Contención del gasto.
- Solución:
  - 1 Pagar con anterioridad a la prestación de los servicios (pago ex-ante).
  - 2 UPC debe reflejar el gasto esperado de salud de los afiliados.

# Eficiencia

- Contención del gasto.
- Solución:
  - 1 Pagar con anterioridad a la prestación de los servicios (pago ex-ante).
  - 2 UPC debe reflejar el gasto esperado de salud de los afiliados.

# Eficiencia

- Contención del gasto.
- Solución:
  - 1 Pagar con anterioridad a la prestación de los servicios (pago ex-ante).
  - 2 UPC debe reflejar el gasto esperado de salud de los afiliados.

- Descreme del mercado mediante estrategias sutiles: calidad del servicio, largas colas, tiempos prolongados para obtener citas, etc.
- Solución:
  - 1 Ajuste de riesgo ex ante a la UPC.
  - 2 El auste de riesgo debe compensar por riesgos predecibles y socialmente aceptables.
  - 3 Mejor uso de la información.

- Descreme del mercado mediante estrategias sutiles: calidad del servicio, largas colas, tiempos prolongados para obtener citas, etc.
- Solución:
  - 1 Ajuste de riesgo ex ante a la UPC.
  - 2 El auste de riesgo debe compensar por riesgos predecibles y socialmente aceptables.
  - 3 Mejor uso de la información.

- Descreme del mercado mediante estrategias sutiles: calidad del servicio, largas colas, tiempos prolongados para obtener citas, etc.
- Solución:
  - 1 Ajuste de riesgo ex ante a la UPC.
  - 2 El auste de riesgo debe compensar por riesgos predecibles y socialmente aceptables.
  - 3 Mejor uso de la información.

- Descreme del mercado mediante estrategias sutiles: calidad del servicio, largas colas, tiempos prolongados para obtener citas, etc.
- Solución:
  - 1 Ajuste de riesgo ex ante a la UPC.
  - 2 El auste de riesgo debe compensar por riesgos predecibles y socialmente aceptables.
  - 3 Mejor uso de la información.

- Descrime del mercado mediante estrategias sutiles: calidad del servicio, largas colas, tiempos prolongados para obtener citas, etc.
- Solución:
  - 1 Ajuste de riesgo ex ante a la UPC.
  - 2 El auste de riesgo debe compensar por riesgos predecibles y socialmente aceptables.
  - 3 Mejor uso de la información.



# Capacidad predictiva del gasto

- El modelo de ajuste de riesgo del Ministerio tiene un poder predictivo estándar (de acuerdo a los estándares internacionales).
- Predice el 33 % del gasto del quintil de mayor gasto de salud.
- La capacidad de predecir el gasto de ciertos **riesgos predecibles** es baja: Quedan muchos incentivos a la selección de riesgos.
- Por esta razón se hace un ajuste ex-post.

# Capacidad predictiva del gasto

- El modelo de ajuste de riesgo del Ministerio tiene un poder predictivo estándar (de acuerdo a los estándares internacionales).
- Predice el 33% del gasto del quintil de mayor gasto de salud.
- La capacidad de predecir el gasto de ciertos **riesgos predecibles** es baja: Quedan muchos incentivos a la selección de riesgos.
- Por esta razón se hace un ajuste ex-post.

# Capacidad predictiva del gasto

- El modelo de ajuste de riesgo del Ministerio tiene un poder predictivo estándar (de acuerdo a los estándares internacionales).
- Predice el 33% del gasto del quintil de mayor gasto de salud.
- La capacidad de predecir el gasto de ciertos **riesgos predecibles** es baja: Quedan muchos incentivos a la selección de riesgos.
- Por esta razón se hace un ajuste ex-post.

# Capacidad predictiva del gasto

- El modelo de ajuste de riesgo del Ministerio tiene un poder predictivo estándar (de acuerdo a los estándares internacionales).
- Predice el 33 % del gasto del quintil de mayor gasto de salud.
- La capacidad de predecir el gasto de ciertos **riesgos predecibles** es baja: Quedan muchos incentivos a la selección de riesgos.
- Por esta razón se hace un ajuste ex-post.

## Ajuste ex-ante

- 1 Usar más la información disponible del Ministerio para hacer un mejor ajuste de riesgo ex-ante.
- 2 Introducir nuevas técnicas para predecir el gasto de la población.

## Ajuste ex-ante

- 1 Usar más la información disponible del Ministerio para hacer un mejor ajuste de riesgo ex-ante.
- 2 Introducir nuevas técnicas para predecir el gasto de la población.

## Ajuste ex-ante

Cuadro: Ajuste fuera de muestra distribución completa

Modelo		RMSE	MAE	PR anual	PR - no anual	$R^2$
1.	WLS UPC	3,506,658	720,587	0.896	0.999	1.57
2.	WLS UPC + Dx	3,440,928	694,404	0.892	0.999	5.23
3.	ANN FS	3,455,366	774,190	1.064	1.179	
4.	RF FS	3,465,301	712,820	0.975	1.087	
5.	GBM FS	3,431,044	721,168	1.002	1.115	

## Ajuste ex-ante

Cuadro: Ajuste fuera de muestra en el quintil superior

Modelo		RMSE	MAE	PR anual	PR no anual
1.	WLS UPC	7,749,235	1,920,486	0.291	0.335
2.	WLS UPC + Dx	7,580,659	1,983,269	0.367	0.426
3.	ANN FS	7,582,293	1,962,318	0.412	0.474
4.	RF FS	7,580,672	1,988,824	0.424	0.490
5.	GBM FS	7,517,520	1,961,026	0.430	0.500



# Gracias

alvaro.riascos@quantil.com.co