

Predicción de Readmisiones, Mortalidad, e Infecciones en la UCI usando Técnicas de Aprendizaje de Máquinas*

Natalia Serna** Álvaro J. Riascos*** Marcela Granados**** Fernando Rosso*****
Ramiro Guerrero*****

Resumen

La atención de los pacientes en la Unidad de Cuidados Intensivos (UCI) es costosa para los hospitales y demandante para los médicos. La detección temprana de los factores de riesgo asociados a las readmisiones, mortalidad, e infecciones en UCI, puede incrementar la calidad de la atención y reducir los costos en el largo plazo. En este artículo se usan técnicas de aprendizaje de máquinas para predecir estos tres resultados. Los datos provienen de la UCI de uno de los hospitales de alta complejidad en Colombia. En lo que respecta a este artículo, es la primera vez que el aprendizaje de máquinas se usa en el campo de la salud en este país. Los resultados muestran que las patologías de la aorta, cáncer, enfermedades neurológicas, y enfermedades respiratorias así como procedimientos invasivos como la diálisis, traqueostomías y broncoscopias, se correlacionan positivamente con la probabilidad de ser readmitido, de morir, y de adquirir una infección de catéter en la UCI. El área bajo la curva ROC para la primera variable de resultado oscila entre 71 y 74 %, para la segunda variable entre 76 y 81 %. y para la tercera entre 88 y 92 %. Se estima un modelo que compite con el APACHE II y logra igualar su poder predictivo usando menos información del paciente.

Palabras clave: *Unidad de Cuidados Intensivos, aprendizaje de máquinas, readmisiones, mortalidad, infecciones de catéter*

*Agradecimientos: este estudio no habría sido posible sin la ayuda de Robinson Gutierrez, Eliana Manzi, and Andrés Castro (Fundación Valle del Lili), involucrados en adquirir los datos. Todas las opiniones y posible errores u omisiones son responsabilidad de los autores y no comprometen ninguna de las instituciones a las que están afiliados.

**Quantil. e-mail: natalia.serna@quantil.com.co

***Quantil - Universidad de los Andes, Cali. e-mail: alvaro.riascos@quantil.com.co

****Fundación Valle del Lili, e-mail: mgranados@fcvl.org

*****Fundación Valle del Lili, e-mail: frosso@fcvl.org

*****PROESA - Universidad Icesi, e-mail: rguerrero@proesa.org.co

Índice

1. Introducción	3
2. Estadísticas descriptivas y preprocesamiento de datos	5
3. Técnicas de aprendizaje de máquinas y selección de variables	16
3.1. Modelo Logit	17
3.2. Random forests	18
3.3. Redes neuronales artificiales	19
3.4. Boosting de árboles	20
3.5. Comparación de los modelos de clasificación	21
4. Resultados	22
4.1. Readmisiones	22
4.2. Mortalidad	26
4.3. Infecciones de catéter	33
5. Comparación con la literatura relacionada	35
6. Conclusiones e investigaciones futuras	37

1. Introducción

Los servicios que se proveen dentro de la Unidad de Cuidados Intensivos están entre los más costosos para los hospitales. La detección temprana de los factores de riesgo asociados a las readmisiones, mortalidad, e infecciones en UCI, puede incrementar la calidad de la atención y reducir los costos en el largo plazo. De un lado, dadas de alta tempranas pueden estar asociadas a un mayor riesgo de readmisión lo que su vez representa menor calidad en la atención. Pero estancias prolongadas también pueden incrementar el riesgo de adquirir infecciones intra hospitalarias lo que va en detrimento de la salud de los pacientes. De otro lado, la mortalidad en UCI es uno de los estándares de medición de calidad de los hospitales. El presente estudio tiene dos objetivos: el primero es encontrar los factores de riesgo que correlacionan significativamente con el evento de ser readmitido, morir, y adquirir una infección de catéter dentro de la UCI, el segundo es predecir la probabilidad de cada variable de resultado usando técnicas de aprendizaje de máquinas que sirvan como insumos para la administración en salud dentro de la UCI.

Muy pocos estudios en el ámbito de la salud usan técnicas de aprendizaje de máquinas para realizar ejercicios predictivos. Si bien la predicción precisa de los resultados de los pacientes es fundamental para guiar esfuerzos y recursos de la salud, y el aprendizaje de máquinas ha demostrado tener más poder predictivo que los modelos estadísticos usuales aplicados en salud, el aprendizaje de máquinas aún se encuentra rezagado de este campo. Contados estudios han avanzado en este tipo de modelos. Por ejemplo, Sujin et al. (2011) usan redes neuronales (ANN), máquinas de soporte vectorial (SVM), y árboles de decisión para predecir la mortalidad en UCI; Ramon et al. (2007) estudian la evolución de los pacientes en UCI a través de variables de resultado como la sobrevivencia, las inflamaciones, y la disfunción renal usando árboles de decisión, redes bayesianas, y redes bayesianas ingenuas; Fiahlo et al. (2012) usan reglas de asociación para predecir las readmisiones a UCI entre 24 y 72 horas después de ser dado de alta; y Buchner et al. (2015) usan árboles de regresión para predecir el gasto en salud. El presente estudio difiere de los mencionados por varias razones: primero, el interés no es solamente hacer predicciones precisas de las variables de resultado sino también encontrar correlaciones que sean relevantes e interpretables desde el punto de vista médico; segundo, se usan técnicas de combinación de modelos como el bagging y el boosting que buscan mejorar el poder predictivo a través de la reducción de la varianza; tercero, se compara el modelo logit usual a las técnicas de aprendizaje de máquinas para determinar cuánto poder predictivo se gana únicamente a través del modelamiento matemático; y cuarto, se cuenta con una base de datos

única de pacientes admitidos a la UCI de un hospital de alta complejidad¹ en Colombia, pero no se tiene información de variables de laboratorio ni características fisiológicas de los pacientes, por lo tanto las técnicas de selección de variables y el modelamiento en aprendizaje de máquinas serán cruciales para alcanzar un poder predictivo alto.

Se estudian tres variables de resultado:

1. Readmisiones a UCI estratificadas como:

- *Readmisiones tempranas*, aquellas que ocurren dentro de las primeras 72 horas después de ser dado de alta.
- *Readmisiones medianas*, aquellas que ocurren entre 3 y 28 días después de ser dado de alta.
- *Readmisiones tardías*, aquellas que ocurren después de los 28 días de ser dado de alta.

2. Mortalidad en UCI con dos ejercicios:

- Usando variables que se conocen únicamente al momento de admisión, lo que hace los modelos comparables con el APACHE II.
- Usando variables que se conocen al momento de admisión y durante la estancia del paciente, lo que hace de los modelos indicadores de calidad del hospital.

3. Infecciones de catéter en UCI

El ejercicio predictivo de la primera variable de resultado es un ejercicio multinomial mientras que el resto es binomial. En la literatura se han encontrado diversos factores de riesgo que son transversales a estas variables de resultados. Estos incluyen, las comorbilidades y diagnósticos (Badawi and Breslow (2012), Kramer and Higgins (2012), Jo et al. (2015)); complicaciones como falla pulmonar, sepsis, sangrados, infecciones nosocomiales, y extubaciones accidentales (Kogan et al. (2003), Litmathe et al. (2009), Benetis et al. (2013)); procedimientos como ventilación invasiva y no invasiva y sedación; variables demográficas como el sexo y la edad (Campbell et al. (2008), Badawi and Breslow (2012), Bayati et al. (2014), Brown and Ratcliffe (2012), Sujin et al. (2011), Ramon et al. (2007)); variables de laboratorio como conteo de glóbulos rojos, conteo de glóbulos blancos,

¹Los hospitales de alta complejidad en Colombia son aquellos que cumplen como mínimo los siguientes requisitos de acuerdo con el Ministerio de Salud y Protección Social (Decreto 1760 de 1990, art. 9.): (i) alta frecuencia de las patologías, (ii) amplia base poblacional en las áreas donde tienen cobertura, (iii) proveen atención en las áreas donde únicamente hay presencia de un hospital de baja complejidad, (iv) cuentan con tecnología de alta calidad, (v) personal especializado y sub especializado encargado de proveer la atención a los pacientes.

conteo de plaquetas, creatinina, etc. (Fiahlo et al. (2012), Badawi and Breslow (2012), Sujin et al. (2011)); y algunas variables fisiológicas como la tasa respiratoria, el ritmo cardíaco, el peso y la talla (Ramon et al. (2007)).

El resto de este artículo está organizado de la siguiente forma: la segunda sección muestra algunas estadísticas descriptivas de cada variable de resultado y el preprocesamiento de datos. La tercera sección presenta las técnicas de aprendizaje de máquinas y las describe brevemente. La cuarta sección muestra los resultados y explica cómo se eligen los parámetros óptimos de ciertos modelos. La quinta sección presenta una comparación con la literatura relacionada. Y la sexta sección presenta las conclusiones, limitaciones e ideas para futuras investigaciones.

2. Estadísticas descriptivas y preprocesamiento de datos

Para estudiar readmisiones, mortalidad e infecciones en la UCI se cuenta como una base de datos única de los pacientes admitidos a la UCI de adultos de un hospital de alta complejidad en Colombia. En total hay 53,841 ingresos a la unidad desde 1998 hasta 2015. Se tienen variables medidas al momento de admisión como: fecha de admisión, edad, sexo, aseguradora, municipio de residencia, diagnóstico de ingreso, origen del paciente, causa de admisión, y APACHE II. Variables medidas durante la estancia del paciente como los días de estancia, días catéter, días de sonda vesical, procedimientos realizados, complicaciones padecidas, monitorías realizadas, número de catéteres Swan Ganz, horas de ventilación invasiva y no invasiva, e indicadores de plaquetas por encima de 150,000, transfusiones de glóbulos rojos, y transfusiones de otros componentes sanguíneos. Finalmente se tienen variables medidas al momento de ser dado de alta como el diagnóstico de salida. Los diagnósticos de entrada y salida no están codificados siguiendo alguna clasificación internacional como los CIE 10 sino que representan diagnósticos sindromáticos cuyas categorías fueron creadas por los médicos del hospital para las necesidades específicas de información de la UCI.

Siguiendo la literatura relacionada, se crean otras variables como: flujo de pacientes al día como proxy de la ocupación de la UCI; número de diagnósticos, procedimientos y monitorías recibidas por el paciente; día de la semana en el que el paciente ingresa y sale de la unidad; mes de ingreso y de egreso; indicadores de datos atípicos en días de estancia, días catéter, días de sonda vesical, y horas de ventilación invasiva y no invasiva, definiendo los datos atípicos como aquellos pacientes cuya medida de la variable se encuentra por encima del percentil 95 de la distribución de dicha variable; y un indicador de admisiones pasadas a la unidad.

Para el ejercicio de predicción de readmisiones, la variable dependiente se crea como se describe a continuación: primero, se ubica la primera entrada de cada paciente, luego se mira 3 y 28 días hacia adelante para determinar si hay una readmisión temprana, mediana o tardía cualquiera sea el caso, y se marca esta primera entrada de acuerdo a lo observado. Después se ubica la segunda entrada del paciente y se mira 3 y 28 días hacia adelante si existe otra entrada o no. El proceso continúa hasta ubicarse la última entrada del paciente para la cual no existirá información de entradas futuras. Por definición, un paciente que muere en la UCI no tendrá riesgo de readmisión, por lo tanto se eliminan todas las observaciones cuya condición de egreso registrada sea la muerte. Para estimar la probabilidad de readmisión a UCI es posible usar toda la información que se conoce del paciente al momento de ser dado de alta. Esto incluye los diagnósticos de egreso, procedimiento, complicaciones, monitorías, días de estancias, días catéter, etc.

Para el ejercicio de predecir mortalidad, la variable dependiente toma el valor de 1 si la condición de egreso es la muerte y 0 en caso contrario. Dado que la variable dependiente se mide al momento de egreso, no es posible usar predictores que se encuentren medidos en ese mismo momento. Entonces, para el score de mortalidad que es comparable con el APACHE II solamente se puede usar información que se recoge del paciente al momento de admisión, pero para el score de mortalidad que sirve como indicador de calidad del hospital es posible usar, adicionalmente, las variables que miden durante la estancia del paciente. Además, para el primer ejercicio, se excluyen los pacientes que provienen de otras UCIs porque el APACHE II está diseñado para medir el riesgo de muerte en la primera admisión a una UCI.

En el caso de predicción de infecciones de catéter, la variable dependiente toma el valor de 1 si el paciente presenta alguna de las siguientes complicaciones: sepsis por catéter, bacteremia por catéter, o infección del sitio de inserción. La probabilidad de adquirir una infección de catéter está concebida como un score que se puede actualizar durante la estancia del paciente pero que no tiene utilidad una vez el paciente es dado de alta. En ese sentido, no es posible usar variables que se midan al momento de egreso pero sí aquellas que se midan al momento de admisión y durante la estancia.

En esta sección se presentan algunas estadísticas descriptivas para cada variable de resultado. La tabla (1) muestra las estadísticas descriptivas por tipo de readmisión y para la categoría base (los pacientes que no son readmitidos). No existen diferencias significativas entre los pacientes readmitidos dentro de las primeras 72 horas y aquellos que no son readmitidos. Sin embargo, existen diferencias marcadas en relación a los pacientes readmitidos después del tercer día de ser dados

de alta. Pacientes con readmisiones medianas son 4 años mayores que los no readmitidos y tienen valores más altos del APACHE II. Pacientes con readmisiones tempranas tienen significativamente menos horas de ventilación invasiva, días de sonda vesical, y cantidad de monitorías comparado con los pacientes que no son readmitidos. No se encuentran diferencias en el número de diagnósticos recibidos por pacientes con readmisiones tempranas y los no readmitidos. Pero aquellos con readmisiones tardías tienen significativamente más diagnósticos y más horas de ventilación invasiva relativo a la categoría base. La evidencia también muestra que hay una proporción más alta de pacientes readmitidos (bajo cualquier definición) que provienen de otras UCIs, mientras que los pacientes con un único ingreso por lo general no son admitidos de otra unidad sino que provienen directamente de sus casas.

Cuadro 1: Estadísticas descriptivas por tipo de readmisión

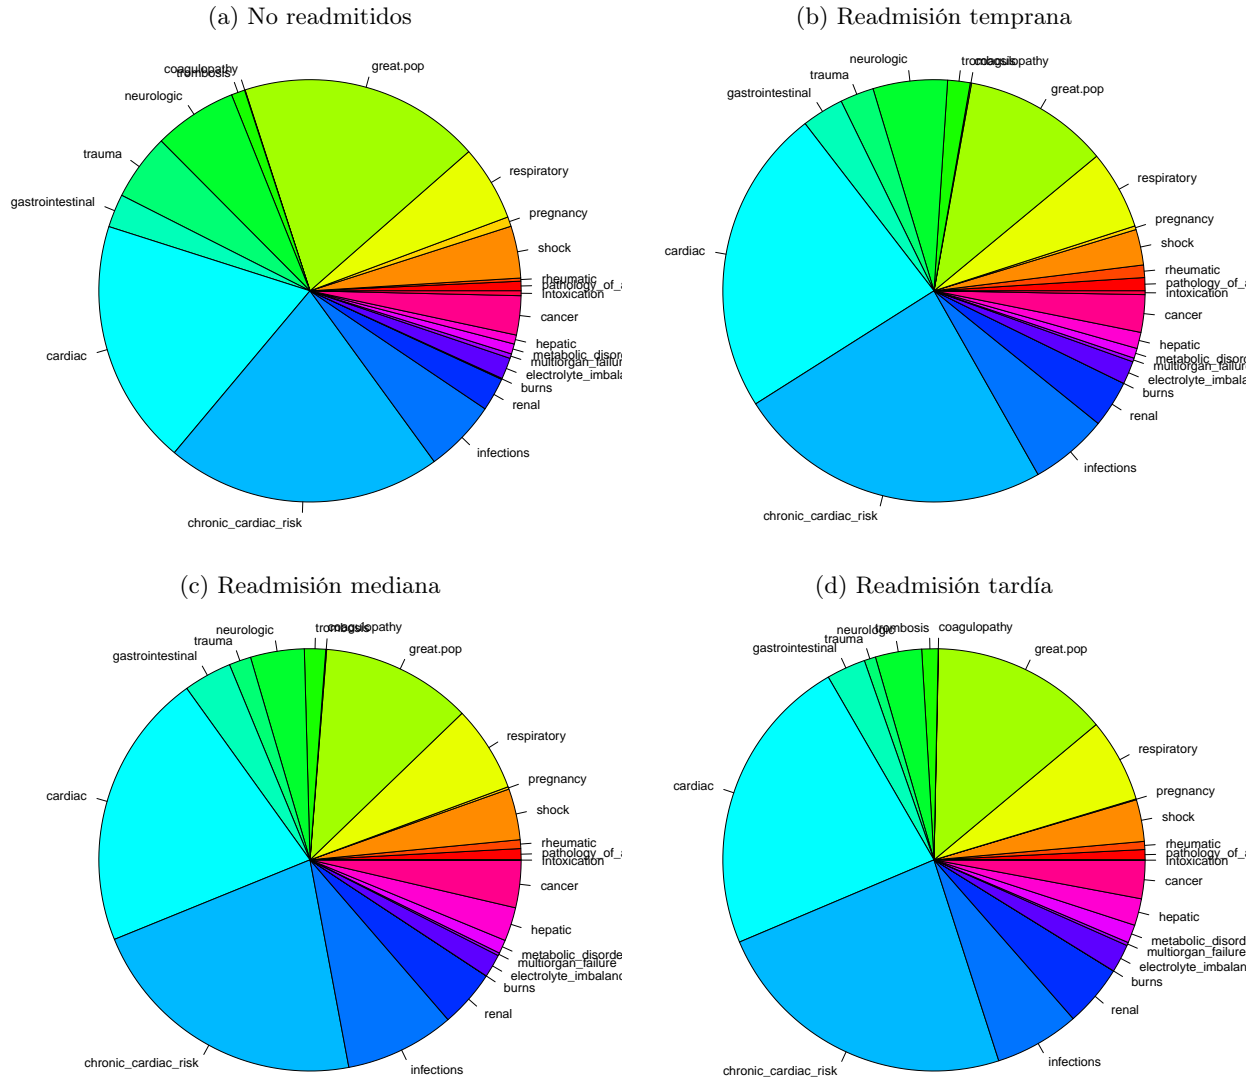
	No readmitidos		Temprana		Mediana		Tardía	
	Media	SD	Media	SD	Media	SD	Media	SD
Demográficas								
Hombre	0.56	0.5	0.54	0.5	0.55	0.5	0.55	0.5
Edad	55.88	35.22	59.36*	18.75	60.18	27.33	59.57	23.95
Médicas/Hospital.								
Apache	12.60	5.70	12.07*	5.37	13.32*	5.55	12.65	5.33
Días de estancia	4.07	27.2	2.12*	2.27	4.42	4.56	4.16	5.92
Días catéter	1.59	3.64	0.53*	1.7	1.7	3.55	1.64	4.56
Días de sonda vesical	2.31	4.79	0.8*	2.03	2.23	3.89	2.14*	5.01
# de catéteres centrales	0.4	1.22	0.19*	0.45	0.4	1.24	0.36*	0.77
# de Swan Ganz	0.08	0.46	0.02*	0.14	0.08	0.34	0.08	0.38
# de líneas arteriales	0.5	0.66	0.33*	0.47	0.5	0.58	0.43*	0.59
Horas de ventilación invasiva	28.99	96.98	6.74*	37.37	24.81*	68.78	29.44	118.56
Horas de ventilación no invasiva	0.01	0.47	0	0.17	0.02	1.55	0.01	0.24
Glóbulos rojos	0.03	0.17	0.02	0.15	0.03	0.17	0.03	0.16
Otros sanguíneos	0.02	0.14	0.02	0.13	0.02	0.13	0.02	0.13
Plaquetas > 150000	0.02	0.15	0.02	0.13	0.02	0.15	0.02	0.14
Admisión pasada	0	0	0.37*	0.48	0.41*	0.49	0.46*	0.5
# de diagnósticos	1.8	0.83	1.84	0.86	1.9*	0.83	1.93*	0.87
# de procedimientos	0.14	0.48	0.03*	0.18	0.13	0.45	0.14	0.49
# de complicaciones	0.08	0.38	0.03*	0.2	0.08	0.34	0.09	0.4
# de monitorías	0.49	1.06	0.27*	0.76	0.38*	0.95	0.37*	0.97
Causa ingreso cardiología	0.27	0.44	0.33*	0.47	0.31*	0.46	0.34*	0.47
Causa ingreso médico	0.37	0.48	0.45*	0.5	0.46*	0.5	0.43*	0.5
Causa ingreso quirúrgico	0.36	0.48	0.22*	0.41	0.23*	0.42	0.23*	0.42
Lugar hospitali. 2do piso	0.95	0.21	0.94*	0.25	0.96	0.2	0.94*	0.23
Lugar hospitali. UCI médica	0.05	0.21	0.06*	0.24	0.04	0.19	0.06*	0.23
Procedencia casa	0	0.01	0	0	0	0	0	0
Procedencia cateterismo	0.02	0.15	0.01	0.11	0.02*	0.13	0.02	0.15
Procedencia cirugía	0.26	0.44	0.16*	0.36	0.16*	0.36	0.18*	0.38
Procedencia consulta	0	0.01	0	0	0	0.01	0	0.02
Procedencia otra UCI	0.03	0.16	0.07*	0.26	0.08*	0.27	0.06*	0.24
Procedencia piso	0.05	0.21	0.06	0.24	0.09*	0.28	0.07*	0.26
Procedencia UCI intermedia	0	0.03	0.01*	0.09	0.01*	0.09	0	0.07
Procedencia urgencias	0.63	0.48	0.66	0.47	0.62	0.48	0.64	0.48
N	24767		1253		5998		8678	

Nota: se reportan la media y desviación estándar de cada variable condicional al tipo de readmisión.

(*) Indica que la diferencia en medias o proporciones entre el tipo de readmisión y la categoría base es significativa al 99%. Cálculos de los autores.


La figura (1) muestra la distribución de diagnósticos de egreso entre los diferentes tipos de readmisión. Los pacientes que no son readmitidos tienen en mayor proporción diagnósticos de post-operatorio de cirugías, mientras que entre los pacientes readmitidos (bajo cualquier definición) las enfermedades cardíacas y renales son más recurrentes.

Figura 1: Distribución de diagnósticos de egreso por tipo de readmisión




Cuando se comparan los tipos de procedimientos que reciben los pacientes readmitidos y aquellos que ingresan una única vez, se encuentran diferencias importantes. La figura (2) muestra una proporción significativamente más alta de pacientes readmitidos de forma temprana que reciben procedimientos relacionados al tratamiento de arritmias cardíacas y asociados a diálisis comparado con los no readmitidos. Sin embargo, los procedimientos asociados a arritmias son menos comunes entre los pacientes readmitidos de forma mediana y tardía. Los procedimientos invasivos respiratorios también son más prevalentes entre pacientes que ingresan una única vez que entre pacientes que reingresan de forma temprana.

Figura 2: Distribución de procedimientos entre tipos de readmisión



La figura (3) muestra la distribución de complicaciones por tipo de readmisión. Vale la pena resaltar cuatro hechos de esta figura: el primero es que las complicaciones asociadas a infección (infecciones urinarias y de catéter) son más prevalentes entre pacientes readmitidos de forma temprana que entre los no readmitidos; el segundo es que las complicaciones asociadas a catéter como la colonización de punta de catéter, neumotórax por catéter, y hemotórax por catéter, son también más prevalentes entre los pacientes readmitidos de formas temprana y tardía que aquellos de la categoría base; el tercero es que la inmovilización es más recurrente en pacientes readmitidos de forma mediana que en los no readmitidos; y el cuarto es que los pacientes con un único ingreso presentan más complicaciones asociadas a intubaciones que los pacientes readmitidos en general.

Figura 3: Distribución de complicaciones entre tipos de readmisión



La tabla (2) muestra la media y desviación estándar de algunas variables entre los pacientes que mueren en UCI y los que no. En general, los pacientes que mueren en la unidad presentan peores condiciones de salud que quienes sobreviven. Por ejemplo, los primeros tienen estancias más largas, más horas de ventilación invasiva, más días catéter y de sonda vesical, y un número mayor de lineal arteriales comparado con los que sobreviven. También presentan significativamente más complicaciones en UCI y reciben más procedimientos.

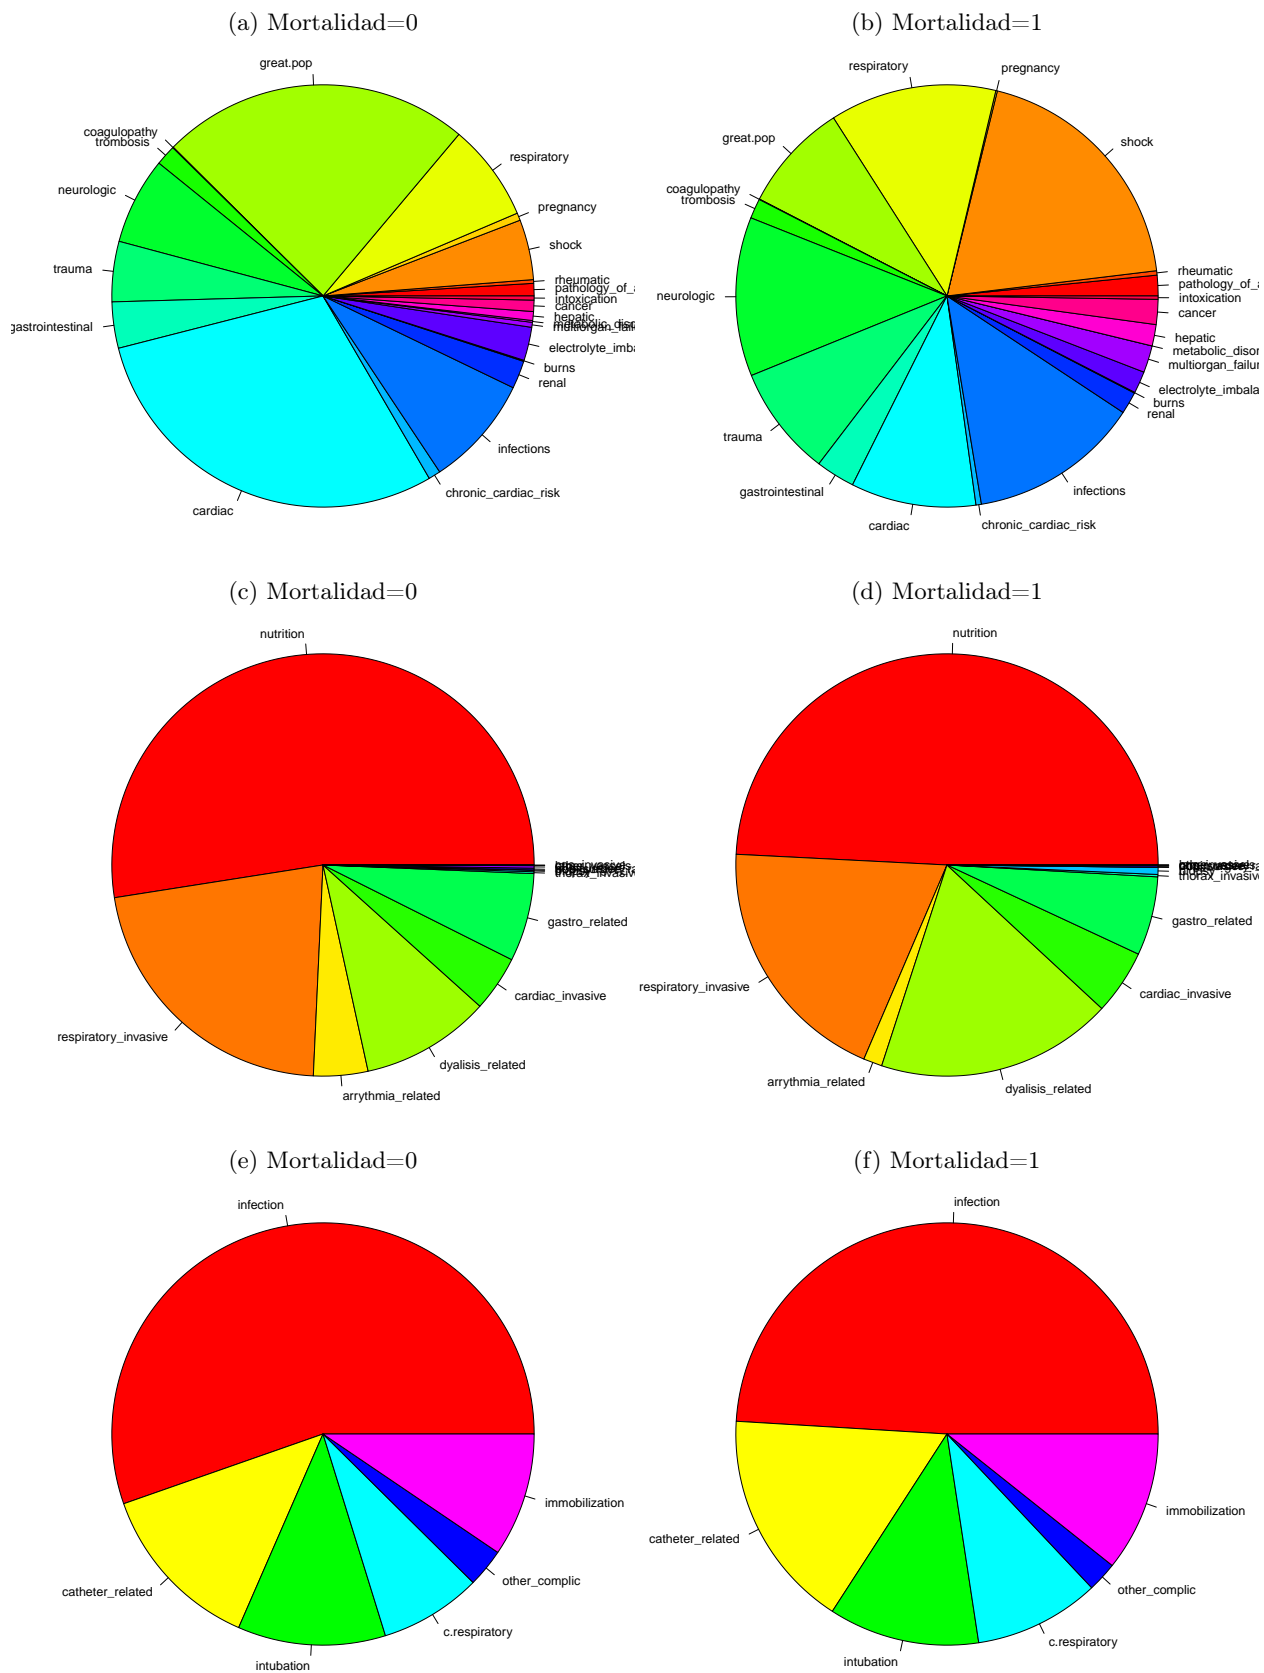
Cuadro 2: Estadísticas descriptivas para mortalidad

	Mortalidad=0		Mortalidad=1	
	Media	SD	Media	SD
Demográficas				
Hombre	0.56	0.5	0.56	0.5
Edad	57.97	30.88	58.99	31.74
Médicas/Hospital.				
Días de estancia*	4.11	23.78	5.39	7.08
Días catéter*	1.57	3.75	3.44	5.76
Días de sonda vesical*	2.19	4.57	4.25	6.71
# catéteres centrales*	0.38	1.09	0.84	2.04
# de Swan Ganz*	0.08	0.45	0.26	0.59
# de líneas arteriales*	0.48	0.62	0.84	0.55
Horas de ventilación invasiva*	26.92	94.54	81	162.2
Horas de ventilación no invasiva	0.01	0.86	0.1	3.61
Glóbulos rojos*	0.03	0.17	0.07	0.26
Otros sanguíneos*	0.02	0.14	0.05	0.23
Plaquetas>150000*	0.02	0.15	0.06	0.24
# de procedimientos*	0.13	0.47	0.37	0.81
# de complicaciones*	0.08	0.37	0.18	0.58
# de monitorías*	0.43	1	1.08	1.49
Causa ingreso cardiología*	0.29	0.45	0.13	0.33
Causa ingreso médico*	0.41	0.49	0.66	0.47
Causa ingreso quirúrgico*	0.3	0.46	0.21	0.41
Lugar hospitali. 2do piso*	0.95	0.21	0.99	0.07
Lugar hospitali. UCI médica*	0.05	0.21	0	0.07
Procedencia casa	0	0.01	0	0
Catheterization origin*	0.02	0.15	0.01	0.08
Procedencia cirugía*	0.22	0.41	0.09	0.29
Procedencia consulta	0	0.01	0	0
Procedencia otra UCI*	0.06	0.23	0.1	0.3
Procedencia piso*	0.07	0.25	0.11	0.31
Procedencia UCI intermedia*	0	0.06	0.01	0.09
Procedencia urgencias*	0.61	0.49	0.66	0.47
N	48525		4867	

Nota: se reporta la media y desviación estandar de cada variable condicional a la condición de egreso muerte. (*) Indica que la diferencia en medias o proporciones entre quienes mueren y quienes sobreviven es significativa al 99%. Cálculos de los autores.

Las figuras (4a) y (4b) ilustran la distribución de diagnósticos de ingreso entre los pacientes que mueren en UCI y los que sobreviven. Una proporción más alta de los pacientes que mueren ingresan a la unidad con diagnósticos de shock, infecciones, enfermedades pulmonares, y enfermedades neurológicas comparado con los que sobreviven. En este último grupo de pacientes, por el contrario, son más comunes al ingreso los diagnósticos cardíacos y los post-operatorios de cirugías. También hay diferencias significativas en la proporción de pacientes que mueren en la unidad y que son admitidos con diagnósticos de cáncer, disfunción multiorgánica, patologías de la aorta, y desequilibrio hidroelectrolítico contrario a los que sobreviven.

Figura 4: Distribución de diagnósticos de ingresos, procedimientos y complicaciones entre pacientes que sobreviven y mueren durante la estancia en la UCI



Las figuras (4c) y (4d) presentan la distribución de procedimientos para el grupo de pacientes que sobreviven y mueren dentro de la unidad, respectivamente. En este caso, vale la pena notar una cosa: los procedimientos asociados a diálisis y arritmias cardíacas son más prevalentes entre el grupo de pacientes que mueren dentro de la UCI que entre quienes sobreviven. Finalmente, no hay diferencias significativas en la proporción de pacientes por tipo de complicación entre ambos grupos como lo muestran las figuras (4e) y (4f).

Cuadro 3: Estadísticas descriptivas para infecciones de catéter


	Sin infección de catéter		Con infección de catéter	
	Media	sd	Media	sd
Demográficas				
Hombre	0.56	0.5	0.56	0.5
Edad*	58.48	18.39	55.51	17.43
Médicas/Hospital.				
Apache*	13.36	6.38	17.84	6.57
Días de estancia*	4.12	22.36	20.85	55.03
Días catéter*	1.67	3.85	11.36	10.68
Días de sonda vesical*	2.3	4.65	14.02	12.49
# catéteres centrales*	0.42	1.21	1.51	1.34
# de Swan Ganz*	0.09	0.38	0.73	3.41
# de líneas arteriales*	0.51	0.62	1.18	0.96
Horas de ventilación invasiva*	30	97.8	303.73	336.41
Horas de ventilación no invasiva	0.02	1.37	0.02	0.32
Glóbulos rojos*	0.03	0.18	0.14	0.34
Otros sanguíneos*	0.02	0.15	0.11	0.31
Plaquetas>150000*	0.03	0.16	0.12	0.32
# de procedimientos*	0.14	0.49	1.34	1.31
# de complicaciones	0.08	0.36	0.93	1.05
# de monitorías*	0.48	1.07	1.25	1.5
Causa ingreso cardiología*	0.27	0.45	0.15	0.35
Causa ingreso médico*	0.43	0.5	0.55	0.5
Causa ingreso quirúrgico	0.29	0.46	0.3	0.46
Lugar hospitali. 2do piso*	0.96	0.2	1	0.05
Lugar hospitali. UCI médica*	0.04	0.2	0	0.05
Procedencia casa	0	0.01	0	0
Procedencia cateterismo	0.02	0.14	0	0.05
Procedencia cirugía	0.21	0.4	0.16	0.37
Procedencia consulta	0	0.01	0	0
Procedencia otra UCI*	0.06	0.24	0.14	0.34
Procedencia piso	0.07	0.25	0.1	0.3
Procedencia UCI intermedia	0	0.07	0.01	0.12
Procedencia urgencias*	0.62	0.49	0.54	0.5
N	53032		360	

Nota: se reporta la media y desviación estándar de cada variable condicional en estar infectado o no. (*) Indica que la diferencia en medias o proporciones entre pacientes con infecciones de catéter y sin infecciones es significativa al 99%. Cálculos de los autores.

La tabla (3) muestra las estadísticas descriptivas para el grupo de pacientes que presentan una infección de catéter en la UCI y el grupo que no las presenta. Se reportan diferencias significativas en la edad, APACHE II, días de estancia, días catéter, días de sonda vesical, horas de ventilación

invasiva, entre otras, entre ambos grupos de pacientes. Específicamente, los pacientes infectados tienen una estancia en UCI que es 16 días más larga que quienes no presentan infecciones de catéter, también tienen catéteres por más de 10 días y sondas vesicales por más de 14 días. En promedio, los pacientes con infecciones de catéter tienen plaquetas sobre 150,000, 14% de ellos reciben transfusiones de glóbulos rojos y 14% de ellos provienen de otras UCIs, mientras que solo el 6% de pacientes no infectados provienen de otras unidades.

Figura 5: Distribución de diagnósticos de ingreso y procedimiento entre pacientes infectado y no infectados



Los paneles (a) y (b) de la figura (5) ilustran la distribución de diagnósticos de ingreso entre el grupo de pacientes infectados y los no infectados. Shock, infecciones, y enfermedades respiratorias al

ingreso son más prevalentes entre los pacientes que presentan infecciones de catéter comparado con los pacientes que no se infectan. Los paneles (c) y (d) también indican que una mayor proporción de pacientes infectados reciben procedimiento invasivos respiratorios y diálisis.

Las estadísticas descriptivas presentadas en esta sección resaltan varios hecho estilizados de la muestra de pacientes. Primero, los diagnósticos de ingreso de shock, infecciones, enfermedades respiratorias, cáncer, y patologías de aorta, están positivamente correlacionados con peores condiciones de salud tras la estancia en UCI. Los pacientes que reciben esos diagnósticos al ingreso son más probables que sean readmitidos, que mueran, o que presenten infecciones de catéter dentro de la UCI. Segundo, peores resultados son más probables entre pacientes que reciben diálisis y procedimientos invasivos como las traqueostomías y las broncoscopias. Finalmente, pacientes que ingresan a la UCI por un post-operatorio de cirugía mayor son menos propensos a ser readmitidos o a morir en la UCI.

Antes de estimar los modelos de aprendizaje de máquinas, se realiza otro preprocesamiento a los datos. Todas las variables continuas se estandarizan (media cero y varianza unitaria) y todas las variables categóricas se dicotomizan. Con el propósito de evitar predicciones sobre ajustadas fuera de muestra, la base de datos se divide en dos conjuntos mutuamente excluyentes cuyas observaciones son elegidas aleatoriamente del pool de 53,841 ingresos a la ICU. La base de entrenamiento comprende el 70 % de la base de datos total, y la muestra de prueba el 30 % restante.

3. Técnicas de aprendizaje de máquinas y selección de variables

Se toma de la literatura de aprendizaje de máquinas, los modelos y técnicas de estimación para predecir las variables de resultado de este estudio. Para cada una se estiman cuatro modelos:

- Logit
- Random Forests (RF)
- Redes neuronales artificiales (ANN)
- Boosting de árboles Trees (GBM)

El modelo logit se incluye dentro del menú de modelos porque es estándar en medicina y porque facilita la interpretación de los efectos marginales de los predictores en la probabilidad de ser

readmitido, de morir, y de presentar una infección de catéter dentro de la UCI. En el caso de readmisiones, la variable dependiente es categórica y toma cuatro posibles valores: (0) sin readmisión, (1) readmisiones tempranas, (2) readmisiones medianas, y (3) readmisiones tardías. Entonces, el problema de predecir el tipo de readmisión es multinomial. Para las otras variables de resultado, mortalidad e infecciones, la variable dependiente es binomial. En la siguiente subsección se describe brevemente cada modelo.

3.1. Modelo Logit

Sea y_i , por ejemplo, el evento de morir dentro de la UCI. Esta toma el valor de 1 si el paciente i muere y 0 en caso contrario. Sea \mathbf{x}'_i el vector de características del pacientes. La ecuación (1) muestra la relación entre y_i y \mathbf{x}'_i .

$$y_i = \mathbf{x}'_i \beta + \varepsilon_i \quad (1)$$

donde ε_i es un choque específico al pacientes. Suponiendo que ε_i sigue una distribución valor extremo tipo I, la probabilidad de que $y_i = 1$ condicional en \mathbf{x}'_i tendrá la forma logística usual mostrada en la ecuación (2).

$$\hat{\pi}_i = Pr[y_i = 1 | \mathbf{x}_i] = \frac{e^{\mathbf{x}'_i \hat{\beta}}}{1 + e^{\mathbf{x}'_i \hat{\beta}}} \quad (2)$$

El vector de parámetros β se estima por el método de máxima verosimilitud que consiste en maximizar la función de log verosimilitud (o minimizar el negativo de la función):

$$L(y) = \sum_{i=1}^n y_i \log(\hat{\pi}_i) + (1 - y_i) \log(1 - \hat{\pi}_i) \quad (3)$$

Con $\hat{\beta}$ es posible computar los efectos marginales de cada predictor en la probabilidad de morir en la UCI. Tomando la derivada de $\hat{\pi}_i$ respecto a x_i se tiene que:

$$\frac{\partial \hat{\pi}_i}{\partial x_i} = \hat{\beta} \hat{\pi}_i (1 - \hat{\pi}_i) \quad (4)$$

Por lo tanto, variaciones en x_i , cambian la probabilidad del evento en $\hat{\beta} \hat{\pi}_i (1 - \hat{\pi}_i)$ puntos porcentuales. También se puede computar el riesgo relativo como muestra la ecuación (5).

$$Odds_i = \frac{\hat{\pi}_i}{1 - \hat{\pi}_i} = \frac{e^{\mathbf{x}'_i \hat{\beta}}}{1 + e^{\mathbf{x}'_i \hat{\beta}}} = e^{\mathbf{x}'_i \hat{\beta}} \quad (5)$$

En este caso, variaciones en x_i deben ser interpretadas en términos del porcentaje de aumento o disminución en el riesgo relativo de morir. Nótese que si el intervalo de confianza del riesgo relativo contiene el 1, este no es significativo.

Para respuestas multinomiales, si k es el número de categorías de la variable dependientes, el modelo logit requiere estimar $k - 1$ regresiones logísticas, una para cada categoría relativo a la categoría base, de la forma $\log(\pi_k/\pi_0) = \mathbf{x}'_i \hat{\beta}$. La estimación se hace por medio de máxima verosimilitud y los efectos marginales y los riesgos relativos se calculan de forma separada para cada categoría. No se ampliará sobre los supuestos implícitos en la estimación de un logit multinomial, pero el lector puede remitirse al capítulo 18 de Greene (2012).

3.2. Random forests

Suponer una distribución particular para la probabilidad de observar un evento no necesariamente mejora el poder predictivo. De hecho, distribuciones paramétricas por lo general no se ajustan bien a los datos. Muchas de las técnicas de aprendizaje de máquinas se ocupan de realizar predicciones acertadas en un escenario no paramétrico. Este es el caso de los árboles de decisión.

Suponga que y_i es una función de \mathbf{x}'_i . Dada una variable k y una realización de esta variable, s , la región de características X se divide en dos: $R_1(k, s) = \{X|X_k \leq s\}$ y $R_2(k, s) = \{X|X_k > s\}$. k y s se eligen de forma recursiva a través de la minimización de una función de pérdida, que en el caso de un problema de clasificación usualmente es el índice Gini. Sea c_j la proporción de observaciones en la región j marcadas como 1, la función de pérdida que se quiere minimizar con cada k y s es:

$$I(R) = \min_{k,s} [c_1(1 - c_1) + c_2(1 - c_2)] \quad (6)$$

Cada una de las regiones resultantes, se divide nuevamente en dos subregiones eligiendo k y s de todo el conjunto de variables explicativas, buscando minimizar la impureza del Gini. El particionamiento recursivo continúa hasta que el algoritmo converge a algún criterio fijado por el investigador, que puede ser por ejemplo hasta que el Gini alcanza cierto umbral o hasta que la cantidad de observaciones en un nodo no terminal alcanza un mínimo.

Dado que los árboles de decisión son sensibles a los criterios de convergencia fijados por el investigador, sus predicciones también son volátiles. Una varianza alta es problemática para realizar predicciones fuera de muestra. Con el propósito de reducir la varianza, diversos métodos se han introducido en el campo del aprendizaje de máquinas. Uno de ellos es el bagging que consiste en

crear muestras de bootstrap en las que se entrena un árbol de decisión. Las predicciones fuera de muestra son promediadas entre los diferentes árboles para obtener un único predictor. Este es el random forest, un bagging de árboles de decisión donde las variables elegidas para dividir el espacio de características en cada nodo no terminal se eligen de forma aleatoria del conjunto de predictores disponibles. En esta aplicación se entrenan 500 árboles en los random forests.

3.3. Redes neuronales artificiales

Las redes neuronales artificiales (ANN), aunque paramétricas, son modelos no lineales usados en aprendizaje de máquinas para problemas de clasificación y regresión. Similar a la forma como funciona el cerebro humano, las ANNs reciben diferentes insumos o predictores, cuya información es procesada en unas neuronas internas. Luego, dependiendo de si la información provista por cada predictor es relevante o no para predecir el resultado, la neurona pasa las predicciones a una capa externa. Una ANN con una capa interna de neuronas puede escribirse como:

$$f_k(X) = \sigma_k \left(\sum_{l=1}^L w_{2lk} \sigma \left(\sum_{j=1}^J w_{1jk} x_j + \theta_j \right) + \theta_l \right) \quad (7)$$

donde L es la cantidad de predictores creados a partir de conjunto inicial de variables J , σ_k y σ son funciones de activación, θ_l y θ_j son indicadores de sesgo en cada nodo, y x_j es el predictor j . En el problema de clasificación, las funciones de activación se definen como:

$$\sigma_k(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

Los parámetros de la ANN, $\beta = [w_{1jk}, w_{2lk}]$, usualmente conocidos como ponderadores, se estiman usando el algoritmo de propagación hacia atrás. La función de pérdida que se quiere minimizar es la entropía cruzada de la ecuación (9):

$$R(\beta) = - \sum_{i=1}^n \sum_{k=1}^K y_{ik} \log f_k(x_i) \quad (9)$$

En el caso de múltiples clasificadores, las funciones de activación se definen como:

$$\sigma_k(x) = \frac{e^{X_k}}{\sum_{l=1}^K e^{X_l}} \quad (10)$$

que es la misma transformación que en el logit multinomial. En este estudio se amplía la estima-

ción de las redes usando bagging. Se estiman 30 ANNs en muestras aleatorias de 70 % de la base de entrenamiento y luego se promedian sus predicciones. Todas las ANNs se estiman con los mismos parámetros. En la sección de resultados se discute cómo se fijan estos parámetros.

3.4. Boosting de árboles

El boosting de árboles (GBM) es un caso especial de árboles de decisión, en el que los árboles crecen secuencialmente en muestras ponderadas. Este difiere de los random forests en el sentido de que los árboles en los random forests crecen de forma simultánea y no secuencial, y en el sentido de que las observaciones mal clasificadas en la muestra de entrenamiento reciben mayor peso en iteraciones subsiguientes. El algoritmo de boosting realiza los siguientes pasos:

1. Fije $f_0(x) = 0$

2. De $m=1$ hasta M :

a) Compute $(\beta_m, \gamma_m) = \arg \min_{\beta, \gamma} \sum_{i=1}^N L(y_i, f_{m-1}(x_i) + \beta T(x_i, \gamma))$

b) Fije $f_m(x) = f_{m-1}(x) + \beta_m T(x, \gamma_m)$

donde γ representa todos los parámetros del árbol T (las variables y puntos de partición en los nodos no terminales, y las predicciones en los nodos terminales), L es cualquier función de pérdida, y β es un parámetro de expansión. Este último se estima por medio de validación cruzada en una grilla de β 's.

Si la función de pérdida es una función exponencial $L(y, f(x)) = e^{-yf(x)}$ entonces la etapa 2(a) del algoritmo puede reescribirse como:

$$\begin{aligned}
 (\beta_m, \gamma_m) &= \arg \min_{\beta, \gamma} \sum_{i=1}^N e^{-y_i(f_{m-1}(x_i) + \beta T(x_i, \gamma))} \\
 &= \arg \min_{\beta, \gamma} \sum_{i=1}^N e^{-y_i f_{m-1}(x_i)} e^{-y_i \beta T(x_i, \gamma)} \\
 &= \arg \min_{\beta, \gamma} \sum_{i=1}^N w_i^m e^{-y_i \beta T(x_i, \gamma)}
 \end{aligned} \tag{11}$$

La última línea de la ecuación (11) se obtiene porque $e^{-y_i f_{m-1}(x_i)}$ no depende de los parámetros sobre los cuales se realiza la minimización, lo cual es equivalente a encontrar pesos w_i^m por cada observación i en la iteración m . Más aún, para las observaciones mal clasificadas para las cuales

$-y_i f_{m-1}(x_i)$ es menor que 1, el peso será mayor en iteraciones subsiguientes que para las observaciones clasificadas correctamente. El predictor final o boosting de árboles es básicamente un promedio ponderado de árboles de decisión.

3.5. Comparación de los modelos de clasificación

El poder predictivo de los modelos presentados en la subsección anterior se compara usando el área bajo la curva ROC (AUC). Cuanto más cercana a 1 mejor es el modelo. Para que la comparación sea justa, también se necesita que el conjunto de variables sobre las que se entrenan los modelos sea el mismo. Para elegir las variables se realizan dos técnicas de selección: árboles de decisión y boosting de árboles. Para la primera, se estiman 20 árboles en la base de entrenamiento fijando el parámetro de complejidad en 0.001 y permitiendo un mínimo de 50 observaciones en los nodos no terminales. Dado que los parámetros se fijan en niveles relativamente bajos, lo más probable es que los árboles resulten sobreajustados por lo cual se podan al final. Luego de podarlos, se registran las variables que finalmente se usaron para partir el espacio de características y se eligen aquellas que se usaron en más de 4 árboles.

Para la segunda técnica, se estima un boosting de 500 árboles y se computa la importancia relativa de cada variable. La importancia relativa mide la influencia de la variable x_j en la variación de $g(x)$ sobre la distribución conjunta de los predictores, en otras palabras, mide cuánto cae la función de pérdida al usar x_j como variable de partición. Breiman et al. (1983) propone la siguiente aproximación al cálculo de la importancia relativa:

$$\hat{I}_j(T) = \sum_{t=1}^{J-1} \hat{l}(y, f(x)) \mathbf{1}(x_t = j) \quad (12)$$

donde $J-1$ son los nodos no terminales del árbol T , x_j es la variable de partición usada en el nodo no terminal t y $\hat{l}(y, f(x))$ es la función de pérdida.² Entonces, la importancia relativa de la variable x_j es la suma de las mejoras en la función de pérdida sobre todos los nodos no terminales donde x_j se usa como variable de partición.³ Generalizando a M árboles en el boosting, la importancia relativa de x_j es:

$$\hat{I}_j = \frac{1}{M} \sum_{m=1}^M \hat{I}_j(T_m) \quad (13)$$

²La función de pérdida puede ser la exponencial $e^{-yf(x)}$ o la desviación binomial $\log(1 + e^{-2yf(x)})$ para problemas multinomiales o binomiales.

³Para más detalles sobre la importancia relativa el lector puede remitirse al capítulo 10 sección 13 de Hastie et al. (2012)

En este caso, se eligen aquellas variables para las que la importancia relativa es mayor o igual a 0.1. El conjunto final de predictores sobre los que se entrenan los modelos será la unión de aquellos elegidos bajo las dos metodologías.

Para el ejercicio de predicción de readmisiones a ICU, 90 de las 167 variables fueron elegidas para la estimación, 55 de 104 para el caso de mortalidad en UCI comparable con el APACHE II, 60 de 145 para mortalidad en UCI como indicador de calidad hospitalaria, y 38 de 145 en el caso de infecciones de catéter en la UCI.

4. Resultados

En esta sección se presentan los resultados de la estimación. En el caso de la ANN y el GBM, diferentes parámetros deben ser fijados exógenamente. En la ANN estos son el número de neuronas en la capa interna y el decaimiento de los pesos cuando las predicciones pasan de una capa a otra. En el boosting, estos son el número de árboles, el factor de expansión, el número de observaciones en los nodos no terminales, y el número de interacciones entre las variables. Todos los parámetros se escogen de una grilla de valores por medio de validación cruzada en 10 iteraciones en la muestra de entrenamiento. Las medidas resultantes son aquellas que maximizan el AUC dentro de muestra y se reportan en la tabla (4).

Cuadro 4: Parámetros óptimos para la ANN y el GBM

	ANN			GBM		
	Tamaño	Decaimiento	# de árboles	Obs en nodo	Expansión	Interacciones
Readmisiones	NA	0	500	120	0.05	3
Mortalidad (Apache)	5	1	1000	30	0.05	2
Mortalidad (Calidad)	5	1	1000	30	0.05	2
Infecciones catéter	3	1	500	120	0.05	3

4.1. Readmisiones

Cuadro 5: Riesgo relativo del modelo logit para readmisiones

	Early			Median			Late		
	OR	2.5 %	97.5 %	OR	2.5 %	97.5 %	OR	2.5 %	97.5 %
Demográficas									
Hombre	1.060	0.917	1.224	1.106	1.024	1.195	1.070	0.997	1.148
Edad 45-49	1.272	0.921	1.755	1.229	1.033	1.463	1.286	1.101	1.503
Edad 50-54	1.329	0.989	1.785	1.062	0.898	1.256	1.272	1.100	1.470
Edad 55-59	1.260	0.952	1.667	1.348	1.160	1.566	1.279	1.115	1.466
Edad 60-64	1.025	0.763	1.377	1.534	1.330	1.770	1.311	1.147	1.498
Edad 65-69	1.821	1.414	2.345	1.635	1.421	1.882	1.360	1.192	1.551
Edad 70-74	1.148	0.864	1.525	1.473	1.275	1.703	1.359	1.190	1.553


Edad mayor a 75	1.261	1.003	1.586	1.209	1.066	1.371	1.123	0.999	1.261
Médicas/Hospital.									
Apache	1.026	0.930	1.132	1.067	1.022	1.114	1.000	0.957	1.046
Días de estancia	0.007	0.003	0.019	1.002	0.976	1.028	0.953	0.809	1.122
Días catéter	1.128	0.831	1.529	1.115	1.044	1.190	1.151	1.086	1.220
Días de sonda vesical	0.941	0.678	1.307	0.986	0.917	1.060	0.948	0.885	1.017
# catéteres centrales	0.806	0.647	1.005	0.983	0.929	1.040	0.991	0.939	1.047
# líneas arteriales	0.896	0.798	1.007	1.049	1.007	1.092	0.904	0.862	0.949
Horas de ventilación invasiva	0.951	0.667	1.354	0.866	0.806	0.930	1.072	1.022	1.124
Glóbulos rojos	1.767	1.100	2.839	1.093	0.869	1.375	1.088	0.870	1.360
Pacientes al día	1.100	1.026	1.181	1.082	1.041	1.124	0.962	0.927	0.998
Admisión pasada	4.E+09	0.000	NA	5.E+09	0.000	NA	6.E+09	0.000	NA
# de diagnósticos	1.043	0.918	1.185	0.948	0.884	1.018	1.052	0.988	1.120
# de proceds.	1.082	0.877	1.336	1.001	0.924	1.083	1.036	0.964	1.112
# de monitorías	1.028	0.924	1.143	1.015	0.969	1.063	0.972	0.932	1.014
Causa ingreso quirúrgico	1.223	0.828	1.807	0.906	0.743	1.104	0.858	0.716	1.027
Causa ingreso médico	1.176	0.901	1.535	0.828	0.717	0.956	1.066	0.937	1.213
Procedencia piso	1.841	1.044	3.248	1.673	1.257	2.226	1.249	0.961	1.622
Procedencia cirugía	1.428	0.806	2.530	0.977	0.736	1.298	1.038	0.807	1.336
Procedencia urgencias	1.632	0.993	2.681	1.240	0.969	1.586	1.177	0.946	1.464
Procedencia otra UCI	3.301	1.878	5.800	1.897	1.401	2.569	1.260	0.950	1.671
Proced. respuesta rápida	2.208	1.119	4.358	1.492	1.030	2.162	1.240	0.871	1.765
Diagnósticos									
Reumatológicos	3.995	2.193	7.279	2.394	1.563	3.668	2.111	1.412	3.156
Neurológicos	1.217	0.915	1.619	1.001	0.850	1.180	0.844	0.723	0.984
Trauma	1.104	0.728	1.672	0.597	0.469	0.760	0.381	0.296	0.490
Hepáticos	1.777	1.070	2.951	3.245	2.550	4.129	2.641	2.091	3.335
Infecciones	0.927	0.691	1.244	1.274	1.099	1.478	0.953	0.827	1.098
Respiratorios	0.957	0.710	1.288	1.125	0.962	1.316	1.047	0.907	1.208
Desorden metabólico	0.750	0.403	1.398	1.150	0.849	1.556	1.376	1.056	1.794
Gastrointestinal	1.071	0.745	1.540	1.427	1.186	1.716	1.125	0.942	1.344
Renal	0.968	0.689	1.360	1.302	1.090	1.556	1.272	1.079	1.499
Cardíaco	1.102	0.830	1.462	1.164	1.002	1.352	1.203	1.051	1.376
Shock	1.061	0.742	1.517	1.074	0.899	1.284	0.857	0.721	1.018
Cáncer	1.134	0.799	1.610	1.365	1.143	1.630	1.062	0.895	1.260
Trombosis	1.152	0.704	1.883	1.461	1.123	1.900	1.053	0.814	1.361
Embarazo	0.361	0.122	1.070	0.323	0.162	0.644	0.128	0.054	0.300
Riesgo cardíaco crónico	1.023	0.792	1.321	1.142	0.994	1.313	1.039	0.916	1.179
POP Mayor	0.636	0.451	0.896	0.837	0.705	0.995	1.118	0.962	1.300
Procedimientos									
Díálisis y similares	1.399	0.588	3.330	1.672	1.163	2.404	1.478	1.058	2.065
Nutrición	0.374	0.150	0.931	1.200	0.907	1.588	0.872	0.671	1.133
Asociado a arritmias	0.773	0.219	2.727	0.411	0.189	0.897	0.922	0.564	1.506
Complicaciones									
Infecciones	1.390	0.737	2.620	0.911	0.728	1.141	1.186	0.970	1.450
Inmovilización	0.000	0.000	.	1.235	0.769	1.982	0.729	0.457	1.165
Intoxicación	1.129	0.426	2.989	0.173	0.050	0.596	0.204	0.079	0.531
Otras									
Día ingreso lunes	1.073	0.835	1.379	1.053	0.917	1.209	0.962	0.849	1.090
Día ingreso martes	1.101	0.866	1.400	0.997	0.870	1.141	0.939	0.832	1.060
Día ingreso jueves	0.718	0.550	0.938	1.082	0.946	1.236	0.843	0.746	0.953
Día ingreso viernes	0.935	0.722	1.210	1.084	0.945	1.243	0.863	0.762	0.978
Día ingreso sábado	0.935	0.715	1.222	1.036	0.899	1.194	0.915	0.804	1.042
Día ingreso domingo	0.972	0.743	1.273	0.891	0.766	1.036	0.878	0.767	1.006

Nota: Se excluye el día de egreso, mes de egreso, mes de ingreso y tipo de aseguradora por razones de convergencia. La categoría base del logit multinomial son los no readmitidos.

La tabla (5) presenta los riesgos relativos del logit multinomial para cada tipo de readmisión. Por razones de convergencia, se excluyen los indicadores de día de egreso, mes de ingreso, y tipo de aseguradora. En primer lugar, la literatura relacionada a las readmisiones a UCI no es concluyente respecto al efecto de la estancia. Algunos autores sostienen que una estancia prolongada puede estar asociada a un mejor cuidado, en cuyo caso el riesgo de readmisión puede ser menor; y otros sostienen que la estancia prolongada en realidad se asocia a peores condiciones de entrada, en cuyo caso el riesgo de readmisión no necesariamente es menor. Los resultados de este estudio confirman uno de estos efectos: la estancia prolongada está asociada a un menor riesgo de readmisiones tempranas, pero no es significativo para las readmisiones medianas y tardías. El efecto de otras variables refleja las expectativas desde un punto de vista médico. Más días catéter incrementan el riesgo de readmisión y el efecto es más fuerte para readmisiones medianas y tardías que para readmisiones tempranas. Las transfusiones de glóbulos rojos también son un factor de riesgo significativo así como el hecho de haber tenido admisiones pasadas. Para esta última variable no se reporta el límite superior del intervalo de confianza al 95 % debido a su alto error estándar. Los pacientes que provienen de otras UCIs tienen un riesgo más alto de ser readmitidos de forma temprana, mediana y tardía. Diagnósticos de egreso como enfermedades reumatológicas y trombosis también se asocian a un mayor riesgo de readmisión, mientras que los post-operatorios de cirugía mayor y el embarazo reducen el riesgo de readmisión.

La figura (6) ilustra las siete variables con mayor importancia relativa en el modelo de boosting de árboles. El indicador de admisiones pasadas tiene la mayor importancia, seguido de los días de estancia, diagnósticos de trauma y enfermedades hepáticas, tener entre 18 y 44 años, los días de sonda vesical, y el flujo diario de pacientes.

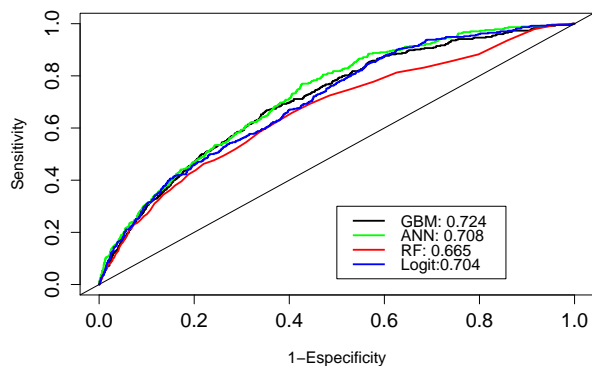
Figura 6: Importancia relativa en el modelo de boosting para readmisiones




La figura (7) muestra la curva ROC fuera de muestra del bagging de redes, el boosting de árboles, el random forest y el logit para cada tipo de readmisión. Para construir estas curvas, primero se obtiene la matriz de probabilidades de dimensión $N \times 4$ obtenidas de cada modelo (una columna por tipo de readmisión) y luego se comparan estas probabilidades al evento observado. La leyenda de cada figura muestra el área bajo la curva. En el caso de readmisiones tempranas, la diferencia en el poder predictivo entre modelos es mayor que para las readmisiones medianas y tardías. El boosting supera al bagging de redes por 3 puntos porcentuales y al RF por 6 puntos porcentuales. Más aún, el logit alcanza un AUC mayor que el RF, lo que sugiere que en el caso de readmisiones no hay ganancias significativas en poder predictivo cuando se usa una distribución no paramétrica para aproximar la distribución conjunta de las variables. Este resultado se mantiene para otros tipos de readmisión.

Figura 7: Curvas ROC de los modelos por tipo de readmisión


(a) Readmisión temprana



(b) Readmisión mediana



(c) Readmisión tardía



Las predicciones de readmisiones tardías son, en general, más precisas que las de readmisiones medianas (AUC de 75% para tardías contra 71% para medianas). Esto se debe a que se observan más readmisiones tardías que medianas en los datos, por lo tanto los modelos cuentan con más información en el grupo de tratamiento para encontrar patrones relevantes.

4.2. Mortalidad

Para el ejercicio de estimar un modelo que sea comparable con el APACHE II en términos de las variables que usa (solo aquellas que se miden al momento de admisión), la tabla (6) muestra el riesgo relativo en el modelo logit y el intervalo de confianza al 95%.

Cuadro 6: Riesgo relativo del modelo logit para mortalidad comparable con el APACHE II

	Odds ratio	2.50 %	97.50 %
<hr/> Demográficas <hr/>			
Hombre	1.030	0.951	1.115
Edad 18-44	0.855	0.752	0.973
Edad 50-54	0.994	0.833	1.182
Edad 55-59	1.116	0.950	1.310
Edad 65-69	1.101	0.944	1.282
Edad 70-74	1.084	0.927	1.267
Edad más de 75	1.273	1.121	1.446
<hr/> Médicas/Hospital. <hr/>			
Pacientes al día	0.892	0.847	0.939
Causa ingreso quirúrgico	0.788	0.132	15.347
Causa ingreso médico	0.961	0.161	18.679
Procedencia cirugía	0.594	0.465	0.762
Procedencia piso	1.343	1.080	1.678
Procedencia urgencias	1.045	0.867	1.269
Lugar hospitali. 2do piso	2.198	0.384	42.431
Lugar hospitali. UCI médica	0.319	0.051	6.375
<hr/> Diagnósticos <hr/>			
Shock	4.683	4.002	5.487
Cardíaco	0.518	0.421	0.637
Neurológicos	1.807	1.553	2.104
Trauma	2.305	1.907	2.784
Disfunción multiorgánica	5.006	3.542	7.014
POP Mayor	0.721	0.581	0.895
Infecciones	1.765	1.504	2.072
Respiratorios	1.713	1.451	2.022
Riesgo cardíaco crónico	0.571	0.313	0.959
Hepáticos	2.900	2.086	3.977
Patología de la aorta	2.136	1.541	2.912
Desequilibrio hidroelectrolítico	0.738	0.533	1.002
Cáncer	2.202	1.582	3.018
Embarazo	0.264	0.065	0.706
<hr/> Otras <hr/>			
Día ingreso lunes	0.987	0.857	1.138
Día ingreso martes	0.853	0.740	0.984
Día ingreso jueves	0.870	0.753	1.004
Día ingreso viernes	0.907	0.786	1.047
Día ingreso sábado	0.975	0.844	1.125
Día ingreso domingo	1.019	0.881	1.179
Mes ingreso enero	1.372	1.125	1.674
Mes ingreso febrero	1.476	1.216	1.790
Mes ingreso marzo	1.277	1.058	1.542
Mes ingreso abril	1.264	1.048	1.524
Mes ingreso mayo	0.962	0.797	1.160
Mes ingreso junio	0.691	0.559	0.850
Mes ingreso julio	0.695	0.567	0.851
Mes ingreso agosto	0.918	0.761	1.107
Mes ingreso octubre	1.018	0.850	1.218
Mes ingreso noviembre	1.228	1.031	1.463
Mes ingreso diciembre	1.664	1.349	2.050

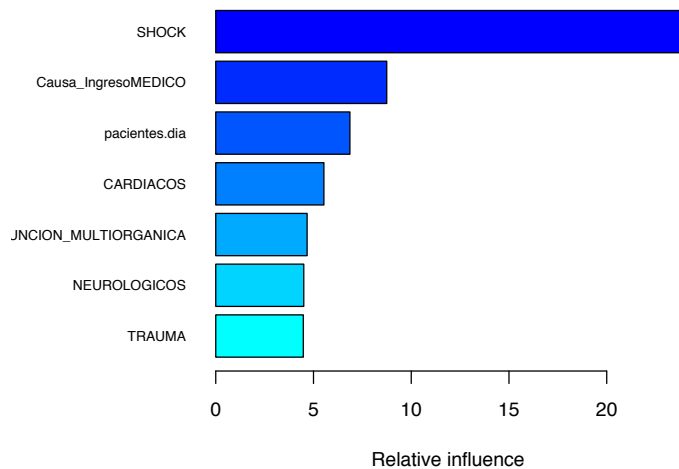
Nota: No se reporta el riesgo relativo del régimen contri-
butivo, ciudades capitales, y departamento de residencia Cauca

Un paciente que es admitido a la UCI con un diagnóstico de shock tiene un riesgo de morir que

es cuatro veces más grande que el riesgo de pacientes que se admiten con cualquier otro diagnóstico. Pacientes con cáncer, enfermedades neurológicas, patologías de aorta, infecciones, y enfermedades respiratorias al momento de ingreso también están en un riesgo más alto de morir en la UCI. Por otro lado, el embarazo, los post-operatorios de cirugías, y el riesgo cardíaco crónico en el momento de ingreso se asocian significativamente a un menor riesgo de muerte en UCI.


La figura (8) muestra las variables más relevantes para el boosting de árboles. Similar a lo encontrado en el modelo logit, los diagnósticos de ingreso de shock, enfermedades neurológicas, disfunción multiorgánica, enfermedades cardíacas, y trauma tienen una alta importancia relativa. El flujo diario de pacientes es la tercera variable más importante para el boosting.

Figura 8: Importancia relativa en el modelo de boosting de mortalidad comparable con el APACHE II




El AUC fuera de muestra de cada modelo con su correspondiente intervalo de confianza al 95 % se reportan en la figura (9). El RF es superado por el resto de modelos por cerca de 3 puntos porcentuales y no hay diferencias importantes entre el poder predictivo del logit, el bagging de redes y el boosting de árboles. El límite superior del intervalo de confianza del AUC para las redes es de 78%. Eligiendo este como el mejor predictor de mortalidad con variables medidas al ingreso del paciente, se compara con el APACHE II.

Figura 9: Curvas ROC de los modelos de mortalidad comparables con el APACHE II




Para recuperar la mortalidad predicha por el APACHE II de los datos seguimos la figura (3) del artículo seminal de Knaus et al. (1985). En esta figura los autores muestra una correlativa entre intervalos del APACHE II y la tasa de mortalidad en su muestra original de pacientes. No es posible usar la metodología que proponen los autores para el cálculo de la tasa de mortalidad individual (reportada en el apéndice del artículo de Knaus et al. (1985)) porque se carece de información precisa sobre el diagnóstico de ingreso de los pacientes. No obstante, evidencia de este hospital en particular sugiere que el cómputo de la mortalidad individual como se mencionó anteriormente es una buena base para medir la calidad de la atención en la UCI y sus cambios. La figura (10) muestra los resultados de la comparación entre la mortalidad predicha por el APACHE II y por el modelo de bagging de redes. Este último alcanza el mismo poder predictivo del APACHE II, pero usa mucha menos información del paciente para lograrlo. El bagging de redes se entrena con información del diagnóstico de ingreso, la fecha de ingreso, el municipio de residencia, la edad, el sexo, la causa de admisión y el origen del paciente; mientras que el APACHE II utiliza, además, indicadores de enfermedades crónicas o de larga duración, indicador de cirugías de emergencia, variables fisiológicas como la temperatura corporal, el ritmo cardíaco, la tasa respiratoria, y variables de laboratorio como los niveles de sodio, potasio, creatinina, conteo de glóbulos blancos, y presión arterial media.

Figura 10: Mejor modelo vs. APACHE II



La figura (11) muestra la mortalidad hospitalaria predicha por el modelo de redes, el APACHE II y mortalidad observada mes a mes desde 1998 hasta 2015. De acuerdo con la evidencia anecdótica provista por los doctores de la UCI, la tendencia de la mortalidad predicha por el APACHE II relativo a la observada es lo esperado. Las desviaciones de la mortalidad observada a la predicha por el APACHE II refleja un mejoramiento de la calidad de la atención en la unidad. Sin embargo, dichas desviaciones también sugieren que el APACHE II no es preciso para predecir la mortalidad hospitalaria, mientras que el modelo estimado en este artículo sí lo es.

Figura 11: Evolución de la mortalidad esperada y observada



Cuadro 7: Riesgo relativo del modelo logit para mortalidad como indicador de calidad

	Odds ratio	2.50 %	97.50 %
Diagnósticos			
Shock	4.007	3.444	4.667
POP Mayor	0.683	0.554	0.842
Cardíaco	0.609	0.502	0.739
Neurológicos	1.875	1.617	2.175
Disfunción multiorgánica	4.646	3.305	6.481
Trauma	2.244	1.861	2.703
Infecciones	1.742	1.497	2.028
Hepáticos	3.003	2.194	4.064
Respiratorios	1.756	1.501	2.055
Cáncer	2.537	1.867	3.407
Patología de la aorta	2.047	1.477	2.791
Embarazo	0.245	0.060	0.660
Desequilibrio hidroelectrolítico	0.748	0.543	1.009
Complicaciones			
Infecciones	0.909	0.765	1.076
Respiratorios	1.127	0.789	1.588
Relacionados a catéter	1.165	0.872	1.545
Inmovilización	1.566	1.143	2.121
Procedimientos			
Diálisis y similares	3.021	2.474	3.681
Nutrición	1.033	0.899	1.185
Invasivos respiratorios	0.826	0.679	1.000
Invasivos cardíacos	2.226	1.556	3.143
Monitorías			
Monitorías invasivas	2.848	2.577	3.148
Otras	1.913	1.332	2.716
Médicas/Hospital.			
Causa ingreso médico	0.742	0.128	14.205
Causa ingreso quirúrgico	0.535	0.092	10.258
Causa ingreso cardiología	0.503	0.086	9.658
Procedencia cirugía	0.480	0.397	0.580
Procedencia piso	1.061	0.907	1.241
Procedencia urgencias	0.837	0.748	0.937
Lugar hospitali. UCI médica	0.660	0.114	12.762
Lugar hospitali. 2do piso	3.068	0.587	57.480
Pacientes al día	0.873	0.830	0.918
Demográficas			
Hombre	1.027	0.951	1.110
Edad 19-44	0.802	0.717	0.896
Edad 50-54	0.964	0.823	1.126
Edad 60-64	0.958	0.831	1.101
Edad 70-74	1.025	0.891	1.177
Edad mayor a 75	1.248	1.120	1.390


Nota: No se reportan los riesgos relativos del día y mes de ingreso, régimen subsidiado, régimen contributivo, aseguradora empresa, ciudades capitales, y departamento de residencia Cauca.

Si se permiten que los modelos sean entrenados en un subconjunto de variables que conocen del paciente durante su estancia, se da paso al score de mortalidad que sirve como indicador de calidad del hospital, pero este ya deja de ser comparable con el APACHE II. La tabla (7) muestra el riesgo relativo en el modelo logit. Varios efectos permanecen significativos del ejercicio anterior. Por ejem-

plo, diagnósticos de ingreso de shock, disfunción multiorgánica, trauma, infecciones, enfermedades neurológicas, cáncer, enfermedades respiratorias, y patologías de la aorta incrementan el riesgo de muerte en UCI casi el doble. En particular, un paciente que ingresa a la UCI con shock es 4 veces más probable que muera en la unidad que un paciente que ingresa con cualquier otro diagnóstico diferente de los reportados en la tabla. Pacientes inmovilizados tienen un riesgo de muerte que es tres veces mayor que los pacientes que no reciben procedimientos. Los procedimientos invasivos cardíacos y las monitorías invasivas como la presión intraabdominal e intracraneal también incrementan el riesgo de muerte en UCI entre 120 y 180 %.

La figura (12) muestra los siete predictores más importantes del modelo de boosting de árboles. Diagnósticos de shock y monitorías invasivas son los dos predictores que reducen en mayor medida la función de pérdida, seguido de un indicador de causa de admisión médica, post-operatorio de cirugía, recibir procedimientos relacionados a diálisis, flujo diario de pacientes, y recibir nutrición enteral o parenteral.

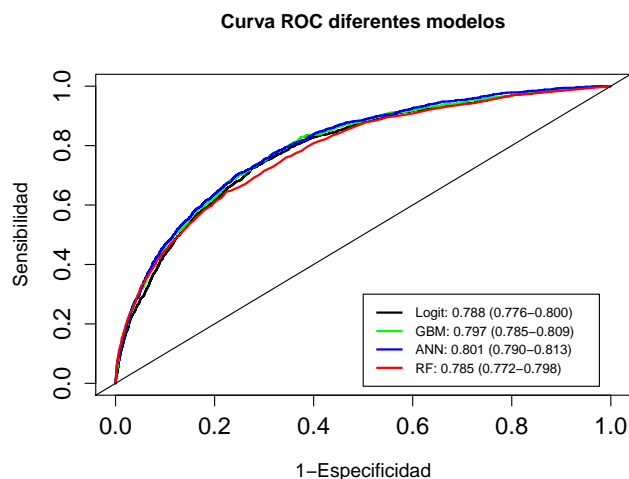
Figura 12: Importancia relativa en el modelo de boosting para mortalidad como indicador de calidad



El poder de clasificación fuera de muestra de cada modelo medido como el AUC y su respectivo intervalo de confianza al 95 % se ilustra en la figura (13). En general, no hay diferencias entre los modelos pues sus intervalos de confianza se solapan. Nótese sin embargo que el AUC en este ejercicio es mayor que el AUC del ejercicio anterior, lo que significa que la creación e inclusión de predictores medidos durante la estancia mejoran el poder predictivo. El mejor modelo para predecir mortalidad

en este caso es el bagging de redes, que alcanza un AUC de 80% con una desviación estandar de 1 punto porcentual.

Figura 13: Curvas ROC para cada modelo de mortalidad como indicador de calidad



4.3. Infecciones de catéter

En esta subsección se presentan los resultados de la predicción de infecciones de catéter en UCI. Este ejercicio puede ser considerado como uno de predicción de complicaciones o de desarrollo de estados peligrosos en la UCI. La tabla (8) muestra los riesgos relativos de las variables en el modelo logit. En este caso, entre las variables que incrementan significativamente el riesgo de adquirir una infección de catéter se incluyen: días catéter, número de catéteres Swan Ganz, APACHE II, número de complicaciones y procedimientos, y tener más de 60 años.

Otros factores de riesgo se obtienen de la importancia relativa del modelo de boosting (ver figura 14). Entre estos están: las horas de ventilación invasiva, días de estancia, días de sonda vesical, y flujo diario de pacientes.


Cuadro 8: Riesgo relativo en el modelo logit para infecciones de catéter

	Odds ratio	2.50 %	97.50 %
Diagnósticos			
Infecciones	1.421	0.971	2.043
Complicaciones			
Respiratorios	0.544	0.258	1.078
Inmovilización	0.828	0.473	1.418
Procedimientos			
Invasivo respiratorio	0.864	0.514	1.455
Intubation	0.428	0.224	0.775
Nutrición	1.184	0.667	2.095

Diálisis y similares Médicas/Hospital.	0.688	0.382	1.220
Días de estancia	1.029	0.981	1.054
Días catéter	1.180	1.063	1.309
Horas ventilación invasiva	1.000	0.927	1.071
Días de sonda vesical	0.918	0.814	1.031
# de Swan Ganz	1.049	1.007	1.112
Apache	1.208	1.079	1.315
# central catheter	1.007	0.910	1.052
# líneas arteriales	1.017	0.946	1.077
Días catéter > perc(95)	1.303	0.788	2.142
Días de estancia > perc(95)	7.049	4.516	10.950
Pacientes al día	0.919	0.770	1.091
# de complicaciones	1.201	1.117	1.291
# de procedimientos	1.283	1.090	1.503
# de monitorías	1.004	0.869	1.158
Causa ingreso quirúrgico	0.710	0.506	0.991
Causa ingreso cardiología	0.888	0.569	1.356
Procedencia otra UCI	1.450	0.936	2.186
Demográficas			
Edad 19-44	1.128	0.800	1.575
Edad 45-49	1.361	0.780	2.255
Edad 60-64	1.641	1.067	2.457

Nota: No se reportan los riesgos relativos del día y mes de ingreso, y departamento de residencia Caldas.


Figura 14: Importancia relativa en el modelo de boosting para infecciones de catéter



Finalmente, la figura (15) presenta la curva ROC fuera de muestra de todos los modelos. De nuevo, no existen diferencias importantes en el poder predictivo de los modelos, pero comparado

con los demás ejercicios en este artículo, en este caso se alcanza un AUC de 91 % con el boosting de árboles con una desviación estándar de 3 puntos porcentuales.

Figura 15: Curvas ROC de los modelos para infecciones de catéter



5. Comparación con la literatura relacionada

Los dos objetivos principales de este artículo son proveer herramientas para la administración en salud que puedan mejorar la calidad de la atención de la atención en la UCI y encontrar los factores de riesgo más importantes para cada variable de resultado que sean relevantes desde el punto de vista médico. Para comprobar que las técnicas de aprendizaje de máquinas usadas en este estudio son herramientas que se pueden implementar en el hospital, se comparan los resultados obtenidos con aquellos de artículos relacionados.

La tabla (9) muestra el AUC de algunos estudios que se ocupan de predecir ciertos tipos de readmisión. La mayoría de ellos usan el modelo logit con variables predefinidas, mientras que Goulart et al. (2015) añaden la técnica de selección hacia atrás (*stepwise backward selection*) para elegir los predictores que mejor se asocian a la probabilidad de ser readmitido. En el campo de aprendizaje de máquinas y minería de datos, Fiahlo et al. (2012) usan árboles de decisión para elegir las variables relevantes y luego reglas de asociación para predecir las readmisiones a UCI. El AUC más alto es reportado por Ferreira et al. (2014) y Jo et al. (2015), con un 76 % cada uno, seguido de Goulart et al. (2015) y Ouanes et al. (2012) con 74 % cada uno. Estos estudios usan información relacionada a variables de laboratorio como el conteo de glóbulos rojos y blancos, niveles de creatinina, etc. y variables fisiológicas como el peso, la talla, ritmo cardíaco, tasa respiratoria, y temperatura corporal,

de la que se carece en el presente estudio. Sin embargo, a diferencia de la literatura relacionada, en esta aplicación se cuenta con una muestra mucho más amplia de pacientes. Y a pesar de contar con menos información sobre al morbilidad del paciente, las técnicas de aprendizaje de máquinas de este estudio igualan el poder predictivo de muchos de los estudios similares. Incluso, comparado con aquellos que usan un conjunto similar de predictores (Campbell et al. (2008)) los resultados de este artículo son superiores.

Cuadro 9: Clasificación en la literatura de readmisiones

Autor	Resultado	AUC
Gajic et al. (2008)	Readmisión a los 7 días	0.70
Badawi and Breslow (2012)	Readmisión a las 48h	0.71
Ferreira et al. (2014)	Readmisión	0.76
Goulart et al. (2015)	Readmisión a las 48h	0.74
Ouanes et al. (2011)	Readmisión a los 7 días	0.74
Fiahlo et al. (2012)	Readmisión a las 72h	0.72
Bayati et al. (2014)	Readmisión a los 30 días	0.66
Campbell et al. (2008)	Readmisión a las 48h	0.67
Jo et al. (2015)	Readmisión	0.76

La tabla (10) muestra el AUC de diversos estudios relacionados a mortalidad en la UCI. Sujin et al. (2011) estiman árboles de decisión, ANNs, y máquinas de soporte vectorial, siendo el primero el mejor predictor. También en la línea de la minería de datos, Ramon et al. (2007) usa árboles de decisión, random forests, redes bayesianas ingenuas, entre otras, siendo esta última el mejor predictor. De otro lado, el resto de estudios reportados en la tabla usan el modelo logit con variables predefinidas para analizar el riesgo de muerte en UCI.

Comparado con la aplicación del score de mortalidad que sirve como indicador de calidad, el mejor modelo de este estudio (bagging de redes con una AUC de 80%) es superado por tres artículos (Badawi and Breslow (2012), Sujin et al. (2011), Ramon et al. (2007)). No obstante, como se mencionó anteriormente, estos autores tienen más información relacionada al estado de salud del paciente. Por nombrar algunas, Badawi and Breslow (2012) usa el índice de masa corporal, acidosis, alkalosis, niveles de creatinina, conteo de glóbulos blancos, niveles de glucosa sérica, presión arterial media, tasa respiratoria, ritmo cardíaco, etc.

Cuadro 10: Clasificación en la literatura de mortalidad

Autor	Resultado	AUC
Badawi and Breslow (2012)	Muerte tras egreso	0.92
Campbell et al. (2008)	Muerte tras egreso	0.74
Sujin et al. (2011)	Muerte tras egreso	0.89
Ramon et al. (2007)	Sobrevivencia tras egreso	0.88
Ouanes et al. (2011)	Muerte a los 7 días	0.74

Aunque existe muy poca literatura relacionada a la predicción de infecciones de catéter en la UCI, esta variable de resultado puede asociarse a los estudios de desarrollo de complicaciones o estados peligrosos en UCI. La tabla (11) presenta el AUC de varios artículos que predicen sepsis e inflamaciones. Todos ellos excepto por Ramon et al. (2007) usan el modelo logit para predecir dichos eventos. La mayoría de estudios encuentran que los niveles de procalcitonina y de la proteína C-reactiva (CRP) son altamente predictivos de la sepsis y las inflamaciones. Por ejemplo, Balcl et al. (2003) tiene un AUC de 97 % usando la procalcitonina y Miller et al. (1999) alcanza un AUC de 86 % usando el CRP como predictor del síndrome de respuesta inflamatoria. A pesar de no tener información de estas variables, el mejor modelo del presente artículo asociado a infecciones de catéter tiene un AUC de 91 % fuera de muestra.

Cuadro 11: Clasificación en la literatura de complicaciones

Autor	Resultado	AUC
Ramon et al. (2007)	Inflamación severa	0.84
Ramon et al. (2007)	Shock por inflamación	0.93
Moreno et al. (2008)	Muerte por sepsis	0.77
Balcl et al. (2003)	Sepsis (condicional en procalcitonina)	0.97
Ugarte et al. (1999)	Sepsis (condicional en CRP)	0.78
Miller et al. (1999)	Síndrome de respuesta inflamatoria	0.86

6. Conclusiones e investigaciones futuras

Este artículo usa las técnicas y métodos del aprendizaje de máquinas para predecir diferentes tipos de readmisión, mortalidad, e infecciones de catéter en la unidad de cuidados intensivos de adultos de un hospital de alta complejidad en Colombia. En lo que respecta a este estudio, es la primera vez que el aprendizaje de máquinas se usa en el campo de salud en este país. El artículo sirve a dos propósitos: uno es estimar modelos que puedan ayudar a los médicos en la UCI a asignar recursos y esfuerzos de manera óptima a los pacientes, y el otro es encontrar factores de riesgo para cada variable de resultado que sean relevantes desde el punto de vista médico. Para lograr esto

último se incluye el modelo logit dentro del menú de modelos de aprendizaje de máquinas para obtener riesgos relativos interpretables de cada predictor.

El bagging de redes neuronales y el boosting de árboles son los mejores modelos de cada ejercicio. En el caso de la predicción de readmisiones tempranas, medianas y tardías, se alcanza un AUC de 72, 71 y 75 %, respectivamente. En el caso de la predicción de mortalidad se desarrollan dos ejercicios: uno que pretende competir con el APACHE II y el otro pensado como un indicador de calidad del hospital. La diferencia entre ambos es el conjunto de variables sobre el que se puede entrenar los modelos. El primero se restringe a las variables que se miden al momento de admisión, mientras que el segundo permite usar información que se recoge del paciente durante su estancia. Usando mucha menos información sobre el paciente, se logra igualar el poder predictivo del APACHE II en la muestra de prueba (AUC de 76 %). Para el segundo ejercicio se alcanza un AUC de 80 %. Aunque esta medida es superada por varios artículos en la literatura relacionada, el conjunto de predictores con los que se cuenta en el presente estudio es mucho más limitado que el de dichos artículos en el sentido de que no se cuenta con información de variable fisiológicas ni de laboratorio. Finalmente, se estiman diversos modelos para predecir infecciones de catéter en la UCI. Este ejercicio puede relacionarse a la literatura de complicaciones en UCI. En este caso, el boosting de árboles alcanza un AUC de 92 % fuera de muestra.

En términos del segundo objetivo, se encuentran diferentes factores de riesgo que son transversales a las variables de resultado estudiadas. Diagnósticos de ingreso como shock, infecciones, patologías de la aorta, cáncer, enfermedades neurológicas, y enfermedades respiratorias incrementan el riesgo de readmisión, muerte e infecciones en la UCI. Procedimientos y monitorías invasivas como la diálisis, traqueostomías, y broncoscopias también están positivamente correlacionadas con la probabilidad de observar estos eventos. A diferencia de la mayoría de literatura, no se encontraron relaciones significativas entre el sexo y la edad con el riesgo de ser readmitido, de morir, o de adquirir una infección de catéter en el contexto particular de esta UCI. Los resultados también confirman uno de los hallazgos reportados en la literatura de cuidado crítico, este es el hecho de que el nivel de ocupación de la unidad va en detrimento de la calidad de la atención.

En el caso de las infecciones de catéter, los resultados pueden estar sesgados porque el desarrollo de este tipo de complicaciones puede depender de la atención que el paciente recibió antes del ingreso a UCI en vez de la atención recibida dentro de la unidad. Por ende, los factores de riesgo asociados a las infecciones de catéter podrían estar capturando la calidad de atenciones previas. Se puede ampliar la investigación de la predicción de complicaciones en UCI. Por ejemplo, la neumonía

nosocomial puede ser más apropiada para medir la calidad de la atención en la unidad en vez de las infecciones de catéter. También se puede ampliar la investigación sobre la forma de computar el AUC usando validación cruzada fuera de muestra o construyendo la base de prueba mediante la elección aleatoria de pacientes y no de registros como se hace en esta aplicación.

Referencias

- Badawi, O. and Breslow, M. (2012). Readmissions and Death after ICU Discharge: Development and Validation of Two Predictive Models. *PLOS ONE Open access*, 7(11):1–15.
- Balci, C., Sungurtekin, H., Gurses, E., Sungurtekin, U., and Kaptanoglu, B. (2003). Usefulness of procalcitonin for diagnosis of sepsis in the intensive care unit. *Critical Care*, 7(1):85–89.
- Bayati, M., Braverman, M., Gillam, M., Mack, K., Ruiz, G., Smith, M., and Horvits, E. (2014). Data-Driven Decisions for Reducing Readmissions for Heart Failure: General Methodology and Case Study. *PLOS ONE Open access*, 9(10):1–9.
- Benetis, R., Sirvinskas, E., Kumpaitiene, B., and Kinduris, S. (2013). A case-control study of readmission to the intensive care unit after cardiac surgery. *International medical journal of experimental and clinical research*, 19:148–152.
- Breiman, L., Friedman, J., Olshen, R., and Stone, C. (1983). *Classification and Regression Trees*. Wadsworth, Belmont, CA.
- Brown, S. and Ratcliffe, S. (2012). The Epidemiology of Intensive Care Unit Readmissions in the United States. *American Journal of Respiratory and Critical Care Medicine*, 185(9):955–964.
- Buchner, F., Wasem, J., and Schillo, S. (2015). Regression trees identify relevant interactions: can this improve the predictive performance of risk adjustment? *Health Economics*.
- Campbell, A., Cook, J., Adey, G., and Cuthbertson, B. (2008). Predicting death and readmission after intensive care discharge. *British Journal of Anaesthesia*, 100(5):656–662.
- Ferreira, D., Kras, I., Forgiarini, L., and Rieder, M. (2014). Assessment of ICU readmission risk with the Stability and Workload Index for Transfer Score. *Journal Brasileiro de Pneumologia*, 40(1):73–76.

- Fiahlo, A., Cismondi, F., Vieira, S., Reti, S., Sousa, J., and Finkelstein, S. (2012). Data Mining Using Clinical Physiology At Discharge To Predict ICU Readmission. *Expert Systems with Applications*, 39(18):13158–13165.
- Gajic, O., Malinchoc, M., Comfere, T., Harris, M., Achouiti, A., Yilmaz, M., Schultz, M., Hubmayr, R., Afessa, B., and Farmer, C. (2008). The Stability of Workload Index for Transfer Score predicts unplanned intensive care unit patient readmission: initial development and validation. *Critical Care Medicine*, 36(3):676–682.
- Goulart, R., Roehrig, C., Pinheiro, R., Gasparetto, J. Pecanha, A., de Souza, P., Dexheimer, F., Balzano, P., and Teixeira, C. (2015). Comparison of Unplanned Intensive Care Unit Readmission Scores: A Prospective Cohort Study. *PLOS ONE Open access*.
- Greene, W. (2012). *Econometric Analysis*, volume 1. Prentice Hall, 7 edition.
- Hastie, T., Tibshirani, R., and Friedman, J. (2012). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, 2 edition.
- Jo, Y., Lee, Y., Park, S., Yoon, H., Lee, J., Lee, C., and Cho, Y. (2015). Readmission to Medical Intensive Care Units: Risk Factors and Prediction. *Yonsei Medical Journal*, 56(2):543–549.
- Knaus, W., Draper, E., Wagner, D., and Zimmerman, J. (1985). APACHE II: A severity of disease classification. *Critical Care Medicine*, 13(10):818–829.
- Kogan, A., Cohen, J., Raanani, E., Sahar, G., Orlov, B., Singer, P., and Vidne, B. (2003). Readmission to the Intensive Care Unit After “Fast-Track” Cardiac Surgery: Risk Factor and Outcomes. *The Annals of Thoracic Surgery*, 76(2):503–307.
- Kramer, A. and Higgins, T. (2012). Intensive care unit readmission in US hospitals: Patient characteristics, risk factors, and outcomes. *Critical Care Medicine*, 40(1):3–10.
- Litmathe, J., Feindt, K., and Boeken, G. (2009). Predictors and Outcome of ICU Readmission after Cardiac Surgery. *The Thoracic and Cardiovascular Surgeon*, 57(7):391–394.
- Miller, P., Munn, D., Meredith, J., Wayne, M., and Chang, M. (1999). Systemic Inflammatory Response Syndrome in the Trauma Intensive Care Unit: Who is Infected? *Journal of Trauma-Injury Infection and Critical Care*, 47(6):1004.

- Moreno, R., Metnitz, B., Adler, L., Hoechtel, A., Bauer, P., and Metnitz, P. (2008). Sepsis mortality prediction based on predisposition, infection and response. *Intensive Care Medicine*, 34:496–504.
- Ouanes, I., Schwebel, C., Francais, A., Bruel, C., Philippart, F., Vesin, A., Soufir, L., Adrie, C., Garrouste-Orgeas, M., Timsit, J., and Misset, B. (2011). A model to predict short-term death or readmission after intensive care unit discharge. *Journal of Critical Care*, 27(4):422.E1–9.
- Ramon, J., Fierens, D., Guiza, F., Meyfroidt, G., Blockeel, H., Bruynooghe, M., and Van Den Bergh, G. (2007). Mining data from intensive care patients. *Advanced Engineering Informatics*, 21(3):243–256.
- Sujin, K., Woojae, K., and Rae, W. (2011). A comparison of Intensive Care Unit Mortality Prediction Models through the Use of Data Mining Techniques. *Healthcare Informatics Research*, 17(4):232–243.
- Ugarte, H., Silva, E., D., M., Mendoza, A., and Vincent, J. (1999). Procalcitonin used as a marker of infection in the intensive care unit. *Critical Care Medicine*, 27(2):498–453.