

## Predicción de duración de la estadía de pacientes en UCIs con lógica difusa

Cismondi F.<sup>1,2,3</sup>, Romero G.<sup>4</sup>, Fialho A.<sup>1,2,3</sup>, Vieira S.<sup>2</sup>, Sousa J.<sup>2</sup>, Reti S.<sup>3</sup> Finkelstein S.<sup>1</sup>

<sup>1</sup>*Engineering Systems Division, Massachusetts Institute of Technology, Cambridge, MA, USA;* <sup>2</sup>*Technical University of Lisbon, Instituto Superior Técnico, Department of Mechanical Engineering, CIS/IDMEC – LAETA, Lisbon, Portuga;* <sup>3</sup>*Division of Clinical Informatics, Department of Medicine, Beth Israel Deaconess Medical Centre, Harvard Medical School, Boston, MA, USA;* <sup>4</sup>*Fundación Escuela de Medicina Nuclear, Mendoza, Argentina*

### Resumen

*La planificación y administración de camas disponibles en la unidad de cuidados intensivos (UCI) es de gran relevancia en la mayoría de las instituciones de salud. En la actualidad, no existen modelos de decisión asistida que permitan predecir la duración de la admisión de un paciente a la UCI. En el presente trabajo, presentamos un modelo de predicción de la duración de la estadía en UCIs, usando una base de datos adquirida en el Hospital Beth Israel Deaconess Medical Center de la ciudad de Boston, EEUU. El modelo utiliza como variables de entrada las señales adquiridas por los monitores ligados al paciente durante las primeras 24 horas de admisión, así como también datos demográficos y sobre transfusiones, infusiones intravenosas y colecciones de orina realizadas en el mismo periodo. Haciendo uso de lógica difusa, la duración de la estadía en horas es transformada a dos posibles categorías: media y larga. Los resultados muestran una muy buena capacidad por parte de los modelos para predecir la duración de la estadía de cada paciente en la UCI; la sensibilidad y especificidad del modelo fueron 0.87 y 0.73, respectivamente, mientras que AUC fue de 0.77. Se precisará, en el futuro, de otras bases de datos con la misma granularidad de información para validar los resultados aquí presentados.*

### Palabras Clave

*lógica difusa; cuidados intensivos; modelos predictivos; decisión asistida, administración basada en datos.*

### 1 Introducción

Existe una creciente presión para administrar los recursos y el cuidado médico en las unidades de cuidados intensivos (UCIs) de una manera mas adecuada, tal que permita reducir costos y maximizar la utilización de las mismas [1,2]. En muchos casos, esto ha forzado a dar el alta a pacientes que, luego de pocas horas, son readmitidos, con el consi-

guiente estrés y complicaciones [3,4]. Por ejemplo, un estudio mostro que un retraso de mas de 6 horas en el traslado de pacientes a la unidad de cuidados intensivos incrementó la duración total de la estadía en el hospital, los costos asociados y las tasas de mortalidad dentro de la UCI y dentro del hospital. En tal escenario, el intensivista se encuentra ante la disyuntiva de trasladar a cuidados no intensivos a todo paciente que haya sido estabilizado en la UCI, de tal manera de hacer lugar a pacientes con estados mas complicados [5,6].

El objetivo principal de este trabajo es predecir la duración de la estadía de pacientes en la UCI, usando como elementos predictivos únicamente mediciones mínimamente invasivas que den información sobre la evolución y estado general del paciente. En el presente trabajo, la duración de la estadía es dividida en dos categorías que representan la manera en la que expertos intensivistas se refieren lingüísticamente a las mismas: media y larga duración.

En este trabajo, una herramienta de inteligencia artificial conocida como lógica difusa, combinada con selección progresiva de variables, es usada para modelar la duración de la estadía en la UCI. Cada una de las categorías de duración es representada en el modelo como una función de pertenencia difusa que representa cada concepto con la dispersión real con la cual es considerado en la práctica.

El modelo es creado a partir de datos recogidos en varias UCIs del Hospital Beth Israel Deaconess Medical Center, localizado en Boston, EEUU, conformando una base de datos de-identificada llamada MIMIC II.

Este trabajo presenta la siguiente estructura: la sección 2 presenta la estructura de la base de datos utilizada, así como también los métodos aplicados para crear el modelo de predicción. La sección 3 presenta los resultados obtenidos con dicho modelo y discute posibles interpretaciones de los mismos. La sección 4 presenta las conclusiones obtenidas.

## **2 Trabajos relacionados**

Estudios previos han identificado varios factores de riesgo útiles para predecir la criticidad y extensión de la estadía en la UCI, incluyendo APACHE II [7], SAPS I y II, tiempo de intubación, cantidad de medicaciones, necesidad de soporte a órganos vitales [8], admisión durante la noche [9], y procedencia del paciente respecto al tipo de cuidado que estaba recibiendo previo a su internación [10]. Los modelos predictivos

basados en estos factores de riesgo tienen una habilidad moderada para discriminar la duración de la estadía en la UCI. Luego de una búsqueda intensiva en la literatura disponible, los autores del presente trabajo se inclinan a decir que no existen modelos predictivos basados en información fisiológica de la evolución del paciente. De esta manera, un intensivista cuenta hoy en día solo con la capacidad de la inspección clínica como herramienta predictiva, la cual difícilmente integra la multidimensionalidad del problema.

### **3 Métodos**

#### **3.1 Base de datos MIMIC II**

En este trabajo fue utilizada una base de datos recogida en diversas UCIs del Hospital Beth Israel Deaconess Medical Center en Boston, EEUU, llamada MIMIC II. Esta base de datos fue construida como parte de un proyecto BRP (por sus siglas en inglés, de Bioengineering Research Partnership) del Instituto Nacional de Imágenes Biomédicas y Bioingeniería, EEUU, titulado “Integración de Datos, Modelos y Razonamiento en Cuidados Intensivos” (RO1- EB001659). MIMIC II ha sido creada en 2001, y desde entonces recoge datos muestreados en alta frecuencia de los monitores de señales vitales, datos clínicos de la inspección física del paciente, datos de test laboratoriales, notas de médicos y enfermeras, reportes de imágenes, medicaciones y transfusiones/infusiones realizadas a los pacientes, así como también información demográfica. Todos los datos están apropiadamente de-identificados [11]. En la base de datos MIMIC II existen actualmente datos de 40426 pacientes, de los cuales 32332 son adultos (mayores de 18 años). De esta población de pacientes adultos, 38% estuvieron alojados en la UCI médica, 26% en la quirúrgica, 20% en la de recuperación post cirugía y 15% en la de cuidados críticos [11].

El cohorte de pacientes seleccionados para este trabajo fue obtenido a través de los siguientes criterios de inclusión:

- El paciente estuvo alojado en la UCI por al menos 24 horas;
- El paciente es mayor de 18 al momento de admisión;
- El paciente tiene datos recogidos para cada una de las variables consideradas como predictores en el modelo propuesto.

Las variables consideradas como entradas para el modelo predictivo pueden apreciarse en la Tabla I. La principal consigna para su elección fue que su medición sea obtenida a través de un método mínimamente invasivo. Se identificaron 6 grupos generales para las mismas: señales vitales, datos referentes a la admisión y demografía de los pacientes, transfusiones/infusiones y colecciones de orina acumuladas durante las primeras 24 horas de admisión.

Las señales vitales fueron reducidas valores representativos de las primeras 24 horas de estadía en la UCI. De esta forma, la media, la mediana, la desviación estándar, el máximo y el mínimo valor de dicho periodo fueron extraídos para cada una de ellas.

### 3.2 Modelos de Lógica Difusa

Los modelos de lógica difusa permiten la aproximación de sistemas no lineales, sobre los cuales se tiene poca o ninguna información disponible para modelarlos [12]; en general presentan un muy buen desempeño lidiando con valores imprecisos y definiciones lingüísticas. Estos modelos, aplicados a situaciones de clasificación en problemas médicos, han mostrado buenas performances, mejores incluso que otras reconocidas herramientas no lineales de modelación [13,14]. Los modelos de lógica difusa son especialmente atractivos debido a que proveen un resultado transparente, diferente de las cajas negras que conforman las redes neurales; también la interpretación lingüística en forma de reglas y lógica conectiva que ofrecen es una ventaja en aplicaciones clínicas, en las cuales muchas definiciones no son exactas, sino que los umbrales entre una y otra categoría pueden ser, justamente, difusos.

**Tabla 1.** Lista de variables seleccionadas de la base de datos MIMIC II.

Grupo	VARIABLES	Unidades
Señales vitales	Frecuencia Cardíaca	[latidos/minuto]
	Presión Arterial	[mmHg]
	Frecuencia Respiratoria	[respiraciones/minuto]
	Temperatura	grados Fahrenheit
	Saturación de O <sub>2</sub>	[%]
Datos de admisión y demográficos	Estadía en el hospital previo a su admisión en la UCI	[días]
	Día de la semana en que fue admitido	[día de la semana]
	Hora del día en que fue admitido	[hora del día]
	Peso	[kg]

	Edad	[años]
Transfusiones	Glóbulos rojos	[ml] acumulados en 24 horas
	Plaquetas	[ml] acumulados en 24 horas
	Plasma congelado	[ml] acumulados en 24 horas
	Infusiones intravenosas	[ml] acumulados en 24 horas
Colecciones de orina	Colección y mediciones de orina realizadas durante las primeras 24 horas de admisión.	[ml] acumulados en 24 horas

Un clasificador basado en lógica difusa consiste de una base de reglas, de la forma “Si..., entonces...”, junto con un mecanismo de inferencia difusa, que son capaces, en última instancia, de clasificar cada vector de datos en un set de datos como perteneciente a una de múltiples posibles clases definidas para un problema específico [12].

En general, se aceptan tres métodos reconocidos para diseñar un modelo de lógica difusa [13]: el método de regresión, el método discriminante y el método de máxima compatibilidad. En este trabajo, el método discriminante fue utilizado, basado en una función de discriminación  $d_i^c$ , la cual es asociada a cada una de las diferentes clases  $c$ ,  $c = 1, \dots, C$ . Las funciones de discriminación pueden ser implementadas por un modelo de inferencia difusa [17]. En este trabajo, sistemas de inferencia difusa del tipo Takagi-Sugeno (TS) [15] fueron usados, los cuales consisten de reglas describiendo relaciones entre las entradas y la salida del modelo. Cuando se utiliza un sistema de inferencia TS, cada función discriminante puede ser descripta como:

$$\text{Si } x_{i1} \text{ es } A_{i1}^c \text{ y } \dots \text{ y } x_{iM} \text{ es } A_{iM}^c \text{ entonces } d_i^c = f_i^c, i = 1, 2, \dots, K \quad (1)$$

donde  $f_i^c$  es el consecuente de la función para la regla  $R_i^c$ . En estas reglas, el índice  $c$  está asociado con la clase de salida  $c$ . La salida de cada función de discriminación  $d_i^c$  puede ser interpretada como un score (o cantidad de evidencia) de que el vector de entrada  $x$  debe ser clasificado en la clase  $c$ . La función de discriminación con el valor más elevado es la que define a que clase pertenece el vector  $x$ . Para una descripción más detallada del método utilizado en este trabajo, se refiere al lector a las referencias [15-17].

### 3.3 Selección de variables

El objetivo del proceso de selección de variables es identificar cuales de las entradas disponibles están relacionadas, incluso de manera compleja, con la clasificación de la salida y, al mismo tiempo, descartar aquellas sin ningún valor predictivo.

De esta manera, la selección de variables es realizada como primer paso para reducir la complejidad computacional del modelo, para reducir el número de variables con alta correlación cruzada [18], y para expandir las propiedades de generalización del modelo [19]. Desde un punto de vista clínico, este proceso podría descubrir nuevo conocimiento respecto de variables con valor predictivo para clasificar un problema médico.

Debido a que la clasificación propuesta en este trabajo consiste en asignar a un dado vector de valores, correspondientes a las variables seleccionadas, una de dos posibles clases (media o larga duración), el área bajo la curva ROC puede ser utilizada para evaluar la performance del modelo de clasificación [21]. Esta curva no es más que una función en la cual se relacionan la tasa de verdaderos positivos y negativos para cada clase. El área bajo la curva roca (AUC, por sus siglas en inglés) corresponde a la integral de cada una de esas dos tasas, de la siguiente forma:

$$AUC = 1 - \int_0^1 FP(FN) \delta FN \quad (2)$$

donde  $FP$  y  $FN$  representan, respectivamente, la tasa de falsos positivos y falsos negativos. Las tasas de verdaderos positivos y verdaderos negativos, también conocidas como sensibilidad y especificidad, corresponden en este escenario particular a pacientes correctamente clasificados en una clase dada, o correctamente excluidos de una clase dada, respectivamente.

### 3.4 Selección progresiva de variables

Una descripción detallada del método de selección progresiva puede encontrarse en [20]. Brevemente, un modelo es construido para cada una de las variables disponibles; aquella variable que arroje el mejor resultado de AUC es seleccionada. A continuación, cada una de las variables remanentes es combinada con la ya seleccionada, y un nuevo

modelo es construido y testado para evaluar su performance. Este proceso se repite hasta que la adición de una nueva variable no genera un incremento estadísticamente significativo de la performance del modelo, en términos de su AUC. Al final, el conjunto de variables que permite el mejor resultado combinatorio es obtenido [22].

#### 4 Resultados y discusión

Durante un período de 10 años, 32.332 pacientes adultos fueron identificados en MIMIC II. Si bien hay actualmente muchas versiones disponibles, en este trabajo se utilizó la versión 2.6 disponible en el sitio web de Physionet (<http://www.physionet.org/>). La Tabla 2 muestra las características del cohorte de acuerdo a los dos tipos de duración de estadía en la UCI definidos en este trabajo.

**Tabla 2.** Características de cada grupo de pacientes de acuerdo a las clases definidas para cada duración de la estadía en la UCI.

Variables	Duración de estadía en la UCI											
	Todos los pacientes (n=32332)				Media (n=23348)				Larga (n=7984)			
	Media	Varianza	Max	Min	Media	Varianza	Max	Min	Media	Varianza	Max	Min
Frecuencia Cardíaca (latidos/min)	82.4	15.4	190	45	<b>81.8</b>	16.6	176	58	<b>83.5</b>	14.2	190	45
Presión Arterial (mmHg)	133.3	19.9	210	0	132.1	19.6	190	10	134.9	20.12	210	0
Frecuencia Respiratoria (respiraciones/min)	23.3	8.08	48	0	<b>18.4</b>	9.02	39	0	<b>28.7</b>	6.09	48	0
Temperatura (Fahrenheit)	98.4	3.02	104.1	90	98.3	2.8	103.2	92.3	98.5	3.4	104.1	90
Saturación de O <sub>2</sub> (%)	96.4	2.03	100	40	96.3	2.02	100	75	96.5	2.04	100	40
Estadía en hospital previo admisión en UCI (días)	1.7	3.05	67	0	<b>0.9</b>	1.98	67	0	<b>2.8</b>	4.67	44	0
Día admitido en UCI (1: Domingo – 7: Sábado)	4.31	2.15	7	1	4.28	2.29	7	1	4.44	1.98	7	1
Hora del día en que fue admitido en la UCI	11.30	6.02	23	0	11.45	6.43	23	0	11.22	5.89	23	0
Peso (kg)	79.3	10.6	168	38	76.9	12.7	162	42	82.4	9.8	168	38
Edad (años)	66.4	20.3	102	18	63.8	19.7	96	18	68.9	21.2	102	45
Transfusiones de Glóbulos rojos (ml/24h)	109.3	230.1	3000	0	<b>64.2</b>	207.1	1800	0	<b>153.2</b>	251.8	3000	0
Transfusiones de Plaquetas (ml/24h)	22.8	50.2	1200	0	<b>14.1</b>	39.3	900	0	<b>35.9</b>	100.2	1200	0
Transfusiones de Plasma congelado (ml/24h)	4.6	40.8	1400	0	<b>3.9</b>	32.8	1400	0	<b>7.7</b>	64.6	1400	0
Infusiones intravenosas (ml/24h)	506.7	237.8	4500	0	<b>466.5</b>	180.4	4200	0	<b>614.9</b>	330.6	4500	0
Colecciones de orina (ml/24h)	650.3	193.2	2300	0	650.1	180.5	2250	20	651.0	200.7	2300	0

Como puede verse en la Tabla 2, hay diferencias significativas entre los valores poblacionales de media, varianza, máximo y mínimo para algunas de las variables, tales como frecuencia cardíaca y respiratoria, y

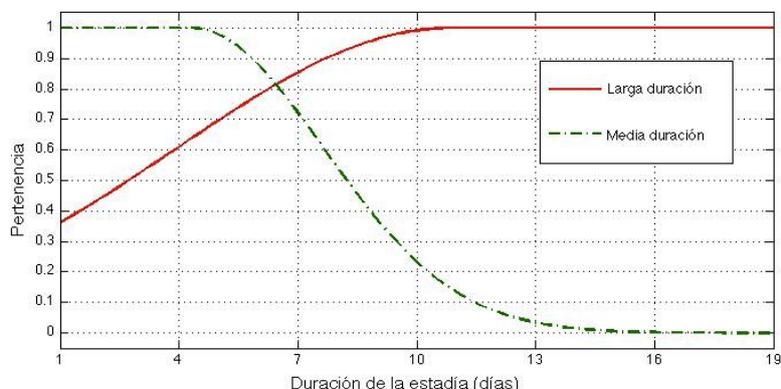
todas las variables representativas de transfusiones e infusiones. La evidencia de los datos fue corroborada por expertos intensivistas, que consideraron reales y relevantes las diferencias encontradas.

Para cada paciente, se calculó la media, varianza, máximo y mínimo de las cinco variables adquiridas por monitores de señales vitales, durante las primeras 24 horas de admisión. Además, se adicionaron los valores acumulados de transfusiones, infusiones y colecciones de orina en el mismo periodo, así como también los valores demográficos al momento de admisión. Todas estas variables fueron usadas como entradas para los modelos de lógica difusa.

El conjunto de pacientes original fue dividido aleatoriamente en dos subconjuntos de igual tamaño, uno para luego ser utilizado durante la selección de variables (SV), y el otro para la selección del mejor modelo (SM). El objetivo de esta división fue realizar dichas selecciones en grupos de datos diferentes, principalmente para escoger el mejor modelo basándose en su performance con datos no utilizados previamente para su creación [22].

Para el proceso de clasificación, las estadías de duración larga fueron considerada como casos positivos, mientras que aquellas de duración media fueron consideradas como casos negativos.

De esta manera, una variable de distribución continua, como es la estadía de un paciente en la UCI, fue transformada en una variable binaria. Las funciones de pertenencia para cada uno de los estados de la nueva variable binaria de salida, definidas de acuerdo a parámetros validados por expertos intensivistas, pueden verse en la Figura 1. En la misma, se aprecia el solapamiento entre las funciones de una y otra duración, lo que favorece la correcta representación de la incertidumbre lingüística con la cual se definen las estadías en la práctica cotidiana.



**Fig. 1.** Funciones de pertenencia difusa representando estadías medias y largas.

El proceso de selección progresiva de variables fue realizado dividiendo el subconjunto SV en un 60% para entrenamiento, un 30% para test y un 10% para validación de las variables. El conjunto de variables seleccionados fue el que arrojó los mejores resultados de AUC durante el proceso de validación.

La Tabla 3 resume los resultados obtenidos durante el proceso de selección progresiva de variables utilizado en este trabajo. Las variables con mayor valor predictivo (aquellas que arrojaron el valor más alto de AUC) fueron: la media de la frecuencia cardíaca, la varianza de la frecuencia respiratoria y el valor acumulado de transfusiones de glóbulos rojos, plaquetas y plasma congelado.

Una vez seleccionadas las variables con valor predictivo, solo los datos correspondientes a las mismas fueron extraídos del subconjunto de datos SM, para así hallar el mejor modelo.

**Tabla 3.** Variables con mayor poder predictivo seleccionadas por los modelos de lógica difusa. AUC – Área bajo la curva ROC.

	AUC	Variables con mayor poder predictivo
Selección Progresiva de variables	0.82	Media de la frecuencia cardíaca Varianza de la frecuencia respiratoria Acumulado de transfusiones de glóbulos rojos Acumulado de transfusiones plaquetas Acumulado de transfusiones plasma congelado

Un proceso de validación cruzada tipo “leave-one-out” (LOOCV, por sus siglas en inglés) fue usado para seleccionar el mejor modelo, usan-

do el 90% de SM para entrenarlo y el 10% restante para validarlo, utilizando un 10% diferente cada vez, de tal manera que el proceso sea repetido 10 veces con datos diferentes. Los resultados mostrados en la Tabla 4 fueron obtenidos luego de promediar las 10 iteraciones realizadas para los modelos obtenidos.

**Tabla 4.** Media y varianza de los resultados de clasificación obtenidos a través de un proceso LOOCV usando el subconjunto de datos SM. PCC: Porcentaje de clasificaciones correctas. AUC: Área bajo la curva ROC

AUC	Sensitividad	Especificidad	PCC (%)
0.77 ± 0.02	0.87 ± 0.05	0.73 ± 0.04	76 ± 3

Como puede apreciarse en los valores mostrados en la Tabla 4, la clase de larga duración, representada por los casos positivos y ponderada por la sensibilidad del modelo, fue mejor identificada que la clase de media duración, ponderada por la especificidad de los modelos. Si bien la situación óptima desde un punto de vista teórico requeriría valores elevados tanto de sensibilidad como de especificidad, en la práctica es importante tener una buena capacidad discriminatoria para aquellos pacientes que se espera tengan una estadía prolongada en la UCI

La baja especificidad del modelo de lógica difusa puede explicarse por la variabilidad clínica de los casos que se presentan en la unidad de cuidados intensivos, y que se resuelven en uno o dos días, incluso cuando las condiciones iniciales son tan o más complejas que para un paciente de estadía de larga duración. Los expertos intensivistas que evaluaron los resultados, hipotetizaron que sería posible obtener mejores resultados si se realizara una segmentación de pacientes de acuerdo a las condiciones medicas que derivaron en su internación, así también como enfermedades concomitantes, número y clase de medicaciones administradas.

## 5 Conclusión

La posibilidad de predecir la duración de la estadía de pacientes en la unidad de cuidados intensivos abre las puertas a un nuevo modo de

administrar la ocupación en dichos departamentos. La gran demanda de cuidados intensivos, sumada a la insuficiente oferta, son motivos necesarios para encontrar caminos alternativos al actual proceso decisorio.

En este trabajo, un método para predecir la duración de la estadía de pacientes en la UCI, basado en mediciones mínimamente invasivas, es presentado. El modelo predictivo está basado en lógica difusa, categorizando la duración de la estadía en dos criterios, media y larga duración, a través de funciones de pertenencia difusa. El modelo es aplicado a una base de datos real adquirida en el Hospital Beth Israel Deaconess Medical Center de Boston, EEUU, la cual consiste de 40426 pacientes admitidos a diferentes UCIs.

Usando el método propuesto, fue posible clasificar correctamente las duraciones de estadía en el 76% de los casos. Además, el proceso de selección progresiva de variables permitió encontrar las variables con mayor poder predictivo para el problema en cuestión. Las mismas fueron la media de la frecuencia cardíaca, la varianza de la frecuencia respiratoria y el valor acumulado de transfusiones de glóbulos rojos, plaquetas y plasma congelado. Estos resultados echan luz sobre una nueva alternativa para el manejo de pacientes en la UCI, así como también para la administración de recursos a nivel general en el ambiente hospitalario.

## **6 Trabajo a futuro**

En el futuro, nuevas bases de datos deberán ser utilizadas para validar el método propuesto en este trabajo, así como también otros métodos que puedan ajustarse a los requerimientos de la predicción de estadía.

Otras consideraciones, como separar grupos específicos de pacientes discriminados por enfermedades subyacentes, grupos sociales, plan médico de cobertura e historia clínica previa podrían incrementar significativamente el porcentaje de clasificaciones correctas.

Por último, la determinación de las funciones de pertenencia podría hacerse basado en la opinión de un número mayor de profesionales médicos, de tal manera que se represente más fielmente los conceptos lingüísticos usados.

## Agradecimientos

Los autores quisieran agradecer la ayuda y espacio de trabajo provisto por la División de Informática Clínica del Hospital Beth Israel Deaconess Medical Center, por el Instituto Tecnológico de Massachusetts, y por la Fundación Escuela de Medicina Nuclear. Recursos técnicos y humanos fueron puestos a disposición, y fueron críticos para el desarrollo de este trabajo. Este trabajo fue financiado por el Gobierno Portugués, a través de los programas: proyecto PTDC/SEMENR/100063/2008, Fundação para a Ciência e Tecnologia (FCT), y por MIT-Portugal Program y las becas FCT SFRH / BPD / 65215 / 2009, SFRH / 43043 / 2008 y SFRH / 43081 / 2008, Ministério do Ensino Superior, da Ciência e da Tecnologia, Portugal.

## Referencias

1. Rubins, H.B., Moskowitz, M.A.: Discharge decision-making in a medical intensive care unit: Identifying patients at high risk of unexpected death or unit readmission. *Am. J. Med.* 84, 863-869 (1988)
2. Durbin, C.G. Jr, Kopel, R.F.: A case-control study of patients readmitted to the intensive care unit. *Crit. Care Med.* 21, 1547-1553 (1993)
3. Boudesteijn, E., Arbous, S., van den Berg, P.: Predictors of intensive care unit readmission within 48 hours after discharge. *Crit. Care* 1, 475 (2007)
4. Rosenberg, A.L., Watts, C.M.: Patients readmitted to intensive care units: A systematic review of risk factors and outcomes. *Chest* 118, 492-502 (2000)
5. Baigelman, W., Katz, R., Geary, G.: Patient readmission to critical care units during the same hospitalization at a community teaching hospital. *Intensive Care Med.* 9, 253-256 (1983)
6. Chalfin, D.B.: Impact of delayed transfer of critically ill patients from the emergency department to the intensive care unit. *Crit. Care Med.* 35,1477-1483 (2007)
7. Rosenberg, A.L., Hofer, T.P., Hayward, R.A.: Who bounces back? Physiologic and other predictors of intensive care unit readmission. *Crit. Care Med.* 29, 511-518 (2001)
8. Fieux, F., Jordan, B., Lang, T.: Critically ill patients readmitted to intensive care units: lessons to learn? *Intensive Care Med.* 29, 241-248 (2003)
9. Goldfrad, C., Rowan, K.: Consequences of discharges from intensive care at night. *Lancet* 355,1138-1142 (2000)
10. Campbell, A.J., Cook, J.A., Adey, G.: Predicting death and readmission after intensive care discharge. *Br. J. Anaesth.* 100, 656-662 (2008)
11. Clifford, G.D., Scott, D.J., Villarroel, M.: User guide and documentation for the MIMIC II database version 2.1, <http://mimic.physionet.org/UserGuide/UserGuide.pdf>
12. Sousa, J.M.C., Kaymak, U.: Fuzzy decision making in modeling and control. River Edge, New Jersey: World Scientific Publishing Co. Pte.Ltd., 335 (2002)
13. Fialho, A.S., Cismondi, F., Vieira, S.M., Sousa, J.M.C., Reti, S.R., Howell, M.D., Finkelstein, S.N.: Predicting outcomes of septic shock patients using feature selection based on soft computing techniques. Applications 13th International Con-

- ference, IPMU 2010, Dortmund, Germany, Proceedings, Part II, vol. 81 of Communications in Computer and Information Science (CCIS), pp. 65–74. Springer-Verlag Berlin, Heidelberg (2010)
14. Horn, A.L., Cismondi, F., Fialho, A.S., Vieira, S.M., Sousa, J.M.C., Reti, S.R., Howell, M.D., Finkelstein, S.N.: Multi-objective performance evaluation using fuzzy criteria: Increasing sensitivity prediction for outcome of septic shock patients. 18th World Congress of the International Federation of Automatic Control (IFAC). Italy, (2011)
  15. Kuncheva, L.I.: Fuzzy Classifier Design. Springer-Verlag, Heidelberg (2000)
  16. van den Berg, J., Kaymak, U., van den Bergh, W.: Fuzzy classification using probability based rule weighting. Proceedings of the IEEE International Conference on Fuzzy Systems, FUZZ-IEEE02, vol. 2, pp. 991–996 (2002)
  17. Takagi, T., Sugeno, M.: Fuzzy identification of systems and its applications to modelling and control. IEEE Transactions on Systems, Man and Cybernetics 15, 116–132 (1985)
  18. Sugeno, M., Yasukawa, T.: A fuzzy-logic-based approach to qualitative modeling. IEEE Transactions on Fuzzy Systems, 1, 7–31 (1993)
  19. Balasko, B., Abonyi J, Feil B. Fuzzy clustering and data analysis toolbox, <http://www.fmt.vein.hu/softcomp/>
  20. Jensen, R., Shen, Q.: Are more features better? a response to attributes reduction using fuzzy rough sets. IEEE Transactions on Fuzzy Systems 17, 1456–1458 (2009)
  21. Guyon, I., Elisseeff, A.: An introduction to variable and feature selection. Journal of Machine Learning Research 3, 1157– 1182 (2003)
  22. Mendonça, L.F., Vieira, S.M., Sousa, J.M.C.: Decision tree search methods in fuzzy modeling and classification. International Journal of Approximate Reasoning 44, 106–123 (2007)

**Datos de Contacto:**

*Dr. Federico Cismondi. Engineering Systems Division, Massachusetts Institute of Technology, 77 Massachusetts Avenue, 02139 Cambridge, MA, USA.  
cismondi@mit.edu*