

RESUMEN

Introducción: Los factores implicados en la aparición de las Lesiones Por Presión (LPP) sigue siendo un tema controvertido. Es necesario verificar la relación directa entre los Factores de Riesgo(FR) y la aparición de LPP en los pacientes y determinar intervenciones específicas. Las Redes Neuronales Artificiales (RNA) constituyen una técnica de análisis multivariante con un planteamiento distinto de la estadística convencional, que consiste en la simulación de un proceso de aprendizaje aplicado al reconocimiento de patrones.

Material y método: Estudio retrospectivo, observacional de predicción de LPP a través de una RNA. Muestra (N=285) pacientes ingresados en UCI de forma consecutiva durante más de 4 días con LPP de cualquier grado, durante un periodo de 6. Se recogieron variables de filiación, clínicos y de las lesiones por presión. Se definió el evento, objeto del estudio como la aparición de LPP de cualquier grado. Se realizó un análisis estadístico convencional uní y bivariante. p significativa <0.05 . Se diseñó una RNA modelo Perceptrón Multicapa, con una función de activación tangente hiperbólica en las capas ocultas y Softmax en la capa de salida. La partición de la serie para el aprendizaje y validación fue del 70% y el 30% de los casos respectivamente.

Resultados: (27,4%) de los casos estudiados, presentaron LPP de cualquier grado. Los FR que presentaron mayor significación estadística en relación con la aparición del evento fueron: Norton al cuarto día (9.6 vs 11.6, $p < 0.001$), APACHE (20.6 vs 17, $p = 0.001$) y ventilación mecánica en los primeros días (88.5 vs 72, $p = 0.001$). Estos datos coinciden con los encontrados en la RNA diseñada, en la que estas mismas variables, tenían una importancia normalizada del 100%, 98.7%, 60.8%, respectivamente. Sin embargo, la RNA encontró FR con una importancia normalizada entre el 15% y el 30%, que no tenían significación estadística en el análisis convencional. La exactitud de la red en el conjunto de validación fue del 70.2%.

Conclusión: Las RNA, pueden permitir diseñar nuevos estudios basados en grandes bases de datos multicéntricas que nos ayuden a resolver las incógnitas que rodean a las LPP.

ABSTRACT

Introduction: The importance of the different factors that contribute to the appearance of Pressure Injuries (LPP) remains a controversial issue: it is necessary to verify the direct relationship between Risk Factors (RF) and the appearance of LPP in patients and also to determinate specific interventions. Artificial Neural Networks (ANNs) are multivariate analysis technique with a different approach from conventional statistics which consists on simulating a learning process applied to pattern recognition.

Material and method: This study shows a retrospective, observational study of prediction of LPP through an ANN. All patients admitted consecutively to the ICU, during a period of 6 months and a stay of more than four days (N = 285), were included. Variables related to parentage, clinical and pressure injuries were also collected for the study. The event, which is the object of the study, was defined as the appearance of LPP of any grade. It has been done also a conventional univariate and two-sided statistical analysis. A significant $p < 0.05$ has been considered. A Multilayer Perceptron model RNA was designed, with a hyperbolic tangent activation function in the hidden layers and Softmax in the output layer. The partition of the series for learning and validation was 70% and 30% of the cases respectively.

Results: Of the 285 cases that were analyzed, 78 (27.4%) presented LPP of any grade. The RFs that presented the highest statistical significance in relation to the onset of the event were: Norton on the fourth day (9.6 vs 11.6, $p < 0.001$), APACHE (20.6 vs 17, $p = 0.001$) and mechanical ventilation in the first days (88.5 vs 72, $p = 0.001$). These data coincide with those found in the designed ANN, in which these same variables had a relative importance of 100%, 98.7%, and 60.8%, respectively. However, RNA found RF with a normalized importance between 15% and 30%, which did not have statistical significance in the conventional analysis. The accuracy of the network in the validation set was 70.2%.

Conclusion: RNA can allow the design of new studies based on large multicenter databases that help us solve the unknowns that surround LPP.

**Universidad de Zaragoza
Facultad de Ciencias de la Salud**

***Master en Iniciación a la Investigación en
Ciencias de la Enfermería***

Curso Académico 2019/20

TRABAJO FIN DE MASTER

**Lesiones por Presión en el paciente crítico:
*Explorando Redes Neuronales.***

**Pressure Injuries in critical patients:
*Exploring Neural Networks***

Autora: Araiz Marín, Ana Belén

Directora: Rodríguez Roca, Beatriz

Asesora: Royo Puerto, Milagros



"Hasta la fecha, no se ha diseñado un ordenador que sea consciente de lo que está haciendo; pero, la mayor parte del tiempo, nosotros tampoco lo somos".

atribuida a **Marvin Minsky**, padre de la IA

INDICE

1. INTRODUCCION	5
1.1. Lesiones o Úlceras por Presión	5
1.1.1. Definición	5
1.1.2. Escalas	5
1.1.3. Importancia	6
1.2. Redes Neuronales Artificiales (RNA)	7
1.2.1. Descripción.....	7
1.2.2. Diferencias entre una red biológica y artificial.....	10
1.2.3. Ejemplo de utilidad	12
2. HIPOTESIS y OBJETIVOS	20
3. MATERIAL Y METODOS.....	21
3.1. Fases	21
3.1.1. Obtención de la Base de Datos y Definición del evento	21
3.1.2. Ingeniería de datos	22
3.1.3. Análisis Estadístico Convencional	22
3.1.4. Red Neuronal Artificial.....	23
3.1.5. Matriz de confusión y Métricas de Rendimiento.....	23
3.2. Programas Informáticos	23
3.2.1. Análisis Estadístico	23
3.2.2. Red Neuronal	23
4. RESULTADOS	24
4.1. Descripción de la Población	24
4.2. Estadística Convencional	27
4.3. Red Neuronal Artificial.....	28
5. DISCUSIÓN	29
6. CONCLUSIONES	31
7. CONFLICTO de INTERESES, ASESORIAS y AUTORIZACIONES.....	32
8. ANEXOS	33
8.1. Anexo 1. Escalas de Valoración del riesgo de LPP.	33
8.2. Anexo 2. Patrones de entrada de la base de daos del ejemplo de utilidad.....	34
8.3. Anexo 3. Carta de aprobación del CEICA.	36
9. BIBLIOGRAFIA	37



1. INTRODUCCION

1.1. Lesiones o Úlceras por Presión

1.1.1. Definición

Las Lesiones por Presión (LPP) o úlcera por presión (UPP) se definen como una lesión localizada en la piel y/o tejido subyacente, generalmente sobre prominencias óseas, provocada por la presión y/o asociado a cizallamiento¹. Aunque es evitable, a día de hoy sigue siendo muy prevalente puesto que en su etiología están involucrados múltiples factores². Se clasifican según los tejidos dañados y la profundidad de la lesión en 4 categorías³.

En la actualidad, su prevención está basada en la minimización de los factores de riesgo, pueden ser intrínsecos o extrínsecos, susceptibles de intervención⁴, estos cuidados son responsabilidad de enfermería⁵.

La evidencia científica sugiere que la medida fundamental en la desaparición de las LPP es la prevención que comienza con la valoración del riesgo. El objetivo de esta valoración es identificar aquellos factores específicos que pueden predecir la población que tiene riesgo de desarrollar LPP y con ello aplicar un plan de cuidados que permita prevenirlo.

1.1.2. Escalas

Se han descrito en la literatura un total de 47 Escalas Valoración Riesgo LPP (EVRUPP)⁶, de las cuales 39 están dirigidas a adultos o ancianos. Únicamente unas pocas han demostrado su utilidad en contextos específicos de cuidados intensivos y no todas ellas han sido validadas a fecha de hoy⁷.

En líneas generales las escalas más utilizadas son:

- Escala Braden⁸. Validada ampliamente en el contexto hospitalario y sociosanitario. Y Junto con la escala de Waterlow⁹, según el documento técnico nº XI del GNEAUPP son las que tienen más validez demostrada en el contexto de los pacientes críticos⁶.

- Escala Norton¹⁰. Es la escala más utilizada en el sistema Aragonés de Salud¹¹ y de acuerdo al metaanálisis realizado por García et al, tiene la misma validez que la escala Braden y Waterloo en el paciente crítico¹².
- Escala EMINA¹³. Es una escala elaborada por el grupo de enfermería del Instituto Catalán de Salud. Solo ha sido validada en el ámbito hospitalario¹⁴

Un análisis comparativo de estas tres escalas se muestra en la **Tabla1.**

Tabla 1. Comparativa de escalas de valoración riesgo LPP

Número de Variables	EMINA		NORTON		BRADEN	
Variables	5		5		6	
Variables	Estado mental	0-3	Estado físico	1-4	Percepción	1-4
	Movilidad	0-3	Estado mental	1-4	Humedad	1-4
	Incontinencia	0-3	Actividad	1-4	Actividad	1-4
	Nutrición	0-3	Movilidad	1-4	Movilidad	1-4
	Actividad	0-3	Incontinencia	1-4	Nutrición	1-4
Rango de Puntuación	0 a 15		5 a 20		6 a 23	
Riesgo	Directa		Indirecta		Indirecta	
	Alto 8-15		Mínimo > 14		Sin riesgo 17-23	
	Moderado 4-7		Evidente 12-14		Bajo 15-16	
	Bajo 1-3		Alto 5-11		Moderado 13-14	
	Sin riesgo 0				Alto ≤ 12	

1.1.3. Importancia

Representan un problema de salud con un impacto significativo en la morbi-mortalidad y la calidad de vida de las personas afectadas. Es una complicación frecuente en cualquier nivel asistencial, especialmente en pacientes con problemas de movilidad y edad avanzada¹⁵.

Las LPP afectan mayoritariamente a personas mayores de 65 años. Su etiología es multifactorial: *edad, nivel de conciencia, incontinencia, movilidad, etc.* Por lo que para la mayoría de los autores hasta el 95% de los casos son evitables¹⁶.

Por otra parte, se ha cuantificado que para el sistema de salud son un impacto económico importante llegando a suponer un 5.2% del gasto sanitario total de nuestro país¹⁷. Asimismo,

no podemos olvidar las posibles repercusiones legales cuando se determine que la aparición de una LPP deriva de una mala praxis profesional⁴.

En concreto, en las Unidades de Cuidados Intensivos (UCI), según los datos que aporta el 2º estudio Nacional de prevalencia de LPP en España, las LPP tienen una prevalencia del 21.05%, mientras que se reduce a un 8'91% en la hospitalización¹⁸.

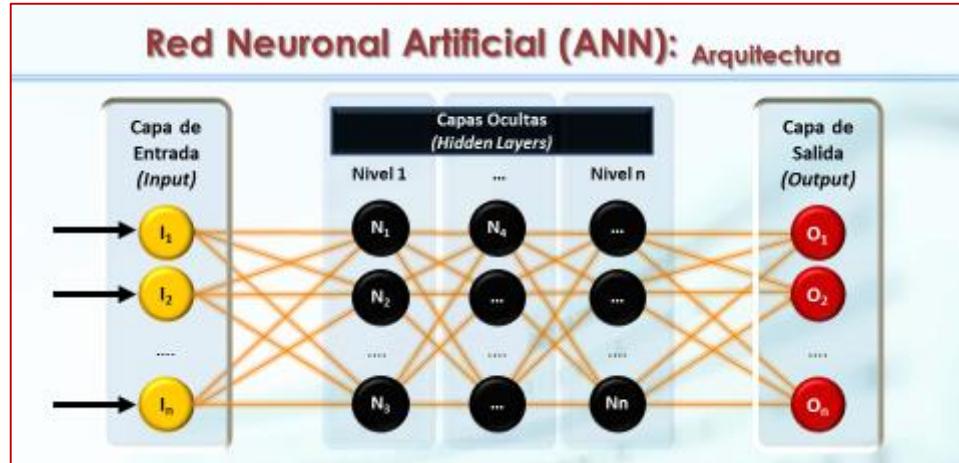
Por todo esto es necesario utilizar herramientas válidas y fiables como las EVRUPP, para aplicar los recursos humanos y materiales, especialmente a los pacientes que presente riesgo y evitar el destino de estos recursos a otros pacientes de forma innecesaria¹⁹.

1.2. Redes Neuronales Artificiales (RNA)

1.2.1. Descripción

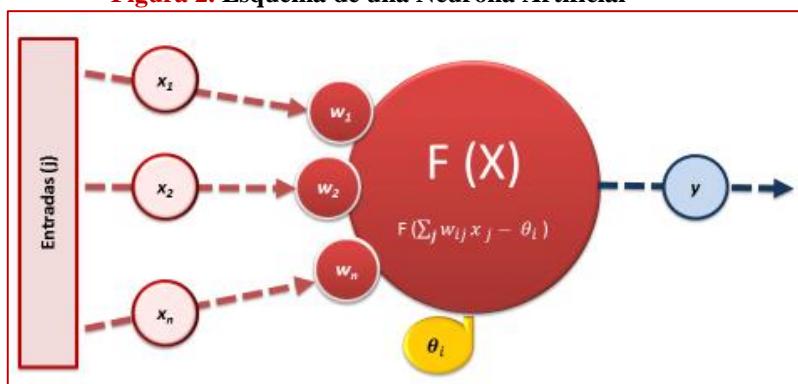
Una Red Neuronal Artificial (RNA) está formada por un conjunto de neuronas artificiales, organizadas en capas (capa de entrada, capas ocultas y capa de salida): (**Figura 1**).

Figura 1. Esquema de una Red Neuronal Artificial (RNA)



A su vez una **neurona artificial** es un procesador elemental (función matemática) tal que a partir de un vector de entrada procedente del exterior o de otras neuronas, proporciona una única respuesta o salida, en base a una *función de activación o trasferencia*. (**Figura 2**).

Figura 2. Esquema de una Neurona Artificial



Las RNA tienen una excelente capacidad para identificar patrones diagnósticos, no requieren condiciones especiales sobre la distribución o la dispersión de los datos, y son robustas ante la presencia de ruido, ya que el aprendizaje constituye una adaptación al polimorfismo que un determinado patrón puede presentar en distintas situaciones^{20,21}.

Una RNA es un modelo matemático no lineal, computacional y complejo. las RNA constituyen una técnica de análisis multivalente con un planteamiento distinto de la estadística clásica o convencional, que consiste en la simulación de un proceso de aprendizaje aplicado al reconocimiento de patrones; constituyen pues un método de análisis multivalente alternativo.

En contraste con las técnicas estadísticas tradicionales, las RNA son capaces de resolver automáticamente relaciones sin la necesidad de suposiciones a priori sobre la naturaleza de las interacciones entre las variables. Otra diferencia importante en comparación con los métodos estadísticos tradicionales, como la regresión logística, es la capacidad de aprendizaje de una RNA. Esta característica permite a la RNA pronosticar casos que nunca se han presentado a la red y se denomina generalización.

Las RNA representan un nuevo método para el modelado predictivo en ciencias médicas y son útiles para predecir relaciones complejas y dependientes del tiempo. Las RNA también pueden usarse cuando las medidas que influyen en un evento no se conocen completamente^{22,23}.



Para comprender cómo pueden equiparase los resultados de un análisis retrospectivo de *Big Data* a los obtenidos mediante ensayos clínicos aleatorizados es necesario insistir en la capacidad de las RNA de identificar patrones, que pueden pasar desapercibidos para el investigador en medio de una gran maraña de datos (“*caos*”).

La difusión de programas informáticos que pueden ejecutarse en ordenadores personales permite disponer de una herramienta de acceso a estas nuevas metodologías de investigación y pone a disposición de los profesionales clínicos nuevas vías de trabajo, hasta ahora solo asequibles a expertos programadores o ingenieros informáticos.

Prueba de todo ello es el número creciente de artículos publicados con **RNA**, especialmente en ámbito de la **Medicina Intensiva** en los últimos años, que abarcan multitud de aspectos clínicos y pronósticos: sepsis^{24, 25} mortalidad^{26,27}, patologías digestivas²⁸



1.2.2. Diferencias entre una red biológica y artificial²⁹.

Se estima que el sistema nervioso contiene alrededor de cien mil millones de neuronas, organizadas mediante una red compleja en la que las neuronas individuales pueden estar conectadas a varios miles de neuronas distintas. Se calcula que una neurona del córtex cerebral recibe información, por término medio, de unas 10.000 neuronas, y envía impulsos a varios cientos de ellas.

Desde un punto de vista funcional, las neuronas constituyen procesadores de información sencillos. Como todo sistema de este tipo, posee un canal de entrada de información, las dendritas; un órgano de cómputo, el soma, y un canal de salida, el axón.

La mayor parte de las neuronas poseen una estructura de árbol llamada dendritas de tal forma que las neuronas se unen a través de uniones denominadas sinapsis. En el tipo de sinapsis más común no existe un contacto físico entre las neuronas, sino que éstas permanecen separadas por un pequeño vacío de unas 0.2 micras.

Con relación a la sinapsis, se habla de neuronas presinápticas (las que envían las señales) y neuronas postsinápticas (las que las reciben). Las sinapsis son dirigidas, es decir, la información fluye siempre en un único sentido. (**Figura 3**).

Figura 3. Diferencias entre Red Neuronal Artificial y Red Biológica

Unidades Procesadoras	Computadora		Cerebro
	Transistores		Neurona
Tamaño	10^{-6} m (Min 1 nanómetro)		10^{-6} m
Número	Max pocos millones		100.000.000.000 (100 mil millones) (10^{14})
Interacciones Conexiones (Sinapsis)	<i>Google Brain</i> 1 millón de neuronas 10.000.000.000 de conexiones		10.000 por cada una 225.000.000.000.000.000 (225 mil billones)[§]
Frecuencia de Trabajo	Unidades de GHz		Cientos de Hz
Ejemplos: $\sqrt{3} = 1.732$ Reconocer Cara	inmediata Problema pendiente de resolución totalmente efectiva.		¿ ... ? 100 mili seg (0.1 seg) = 10^{-1} (2,5 cuadrados de un ECG)
Transmisión	Señal eléctrica		Liberación de Neurotransmisores (Bioquímica)
Anatómicas	No tienen cuerpo.		Tiene cuerpo (sentidos)
	Aprendizaje		Aprendizaje
Manejo de la Información	CUP Procesamiento RAM Memoria		Memoria, Intelecto y Conciencia
Conciencia	NO		SI

§Entre tipos de células, neuro-transmisores, neuro-moduladores, ramas axonales y espinas dendríticas, y eso no incluye la influencia de la geometría dendrítica, ni las cerca de 1 billón de células gliales que pueden o no ser importantes para el procesamiento de la información neural.

1.2.3. Ejemplo de utilidad

Para comprender mejor el funcionamiento de una RNA y las diferencias con la estadística convencional, se ha creído conveniente, diseñar un pequeño ejemplo en el que se puedan ver reflejados estos aspectos.

Se ha confeccionado una base de datos sencilla, con una serie de 160 casos (pacientes), de los que se recogerían 4 supuestas variables: 3 variables (variables 1, 2, 3) de distinta naturaleza con las que se pretende predecir un evento (variable 4). Esta base de datos completa con sus patrones de entrada en un código de colores se encuentra en el **Anexo 2**.

Las características generales/condiciones prefijadas (**tabla 2**) de dicha base son las siguientes:

- ✓ Si la variable 1 = 1, sea cual sea el resto de las variables, el evento **nunca aparece**.
- ✓ Si la variable 1 = 2 y la variable 2 > 50 y Variable 3 es Mujer, el evento **si aparece**.
- ✓ Si la variable 1 = 3 y la variable 2 > 50, el evento **si aparece**.
- ✓ Si la variable 1 = 4, el evento **si aparece**.

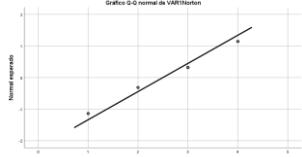
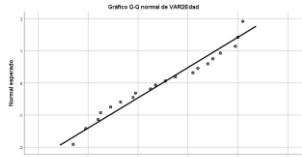
Tabla 2. Características/condiciones de la base diseñada.

Variable 1 Semicuantitativa (p.ej. Escala Norton)	Variable 2 Cuantitativa (p.ej. Edad)		Variable 3 Cualitativa (p.ej. Sexo)	Variable 4: Evento Dicotómica (p.ej. aparición de UPP)
Valor 1 (n=40)	Cualquier Valor		Cualquier valor	NO
Valor 2 (n=40)	< 50	> 50	Hombre Mujer	SI
Valor 3 (n=40)	< 50	> 50	Cualquier valor	SI
Valor 4 (n=40)	Cualquier valor		Cualquier valor	SI

Para entender el ejemplo, a partir de ahora debemos olvidarnos de que conocemos las condiciones prefijadas anteriormente, e imaginamos que vamos a realizar un estudio comparativo entre la estadística convencional y la metodología con la RNA.

En primer lugar, se realiza un estudio descriptivo de dicha serie, mediante estadística convencional. La descripción de la población se refleja en la **Tabla 3**.

Tabla 3: Resultados descriptivos de la base diseñada

Número de casos:	N= 160	
Variable Independiente Semicuantitativa (p.ej. Escala Norton):		
Variable 1 (Como Cualitativa)		
Valor 1	40	25%
Valor 2	40	25%
Valor 3	40	25%
Valor 4	40	25%
Variable 1 (Como Cuantitativa)		
Media \pm DE	2.5 ± 1.1	
Mediana	2.5	
IQR	1.3-3.8 (3)	
Rango	1 - 4(3)	
Test de Normalidad	Prueba de Normalidad Shapiro-Wilk Hipótesis Nula (H_0) <i>La variable 1 "Norton" sigue una distribución normal con media de 2.5 y DE de 1.1</i> p < 0.001	Normalidad Grafica Grafica QQ 
	Conclusión Se rechaza la H_0 La variable 1 "Norton" NO sigue una distribución normal	Conclusión <i>El diagrama de cuantiles no es lineal y por tanto la distribución no es normal</i>
Variable Independiente Cuantitativa (p.ej. Edad):		
Variable 2		
Media \pm DE	49.8 ± 21.2	
Mediana	49	
IQR	30-69.5 (40)	
Rango	14-82 (68)	
Test de Normalidad	Prueba de Normalidad Shapiro-Wilk Hipótesis Nula (H_0) <i>La variable 2 "Edad" sigue una distribución normal con media de 49.8 y DE de 21.2</i> p < 0.001	Normalidad Grafica Grafica QQ 
	Conclusión Se rechaza la H_0 La variable 2 "Edad" NO sigue una distribución normal	Conclusión <i>El diagrama de cuantiles no es lineal y por tanto la distribución no es normal</i>
Variable Independiente Cualitativa (p.ej. Sexo):		
Variable 3		
Mujer	80	50%
Hombre	80	50%
Variable Dependiente Dicotómica, Evento (p.ej. LPP):		
Variable 4		
No Evento (p.ej. No LPP)	90	56.3%
Si Evento (p.ej. Sí LPP)	70	43.7%

DE: Desviación Estándar; **IQR:** Rango Intercuartílico; **LPP:** Lesión Por Presión

En segundo lugar, realizamos un análisis bivariante entre las tres primeras variables y la que define el evento, para ver que dice la estadística convencional respecto de la aparición del evento (**Tabla 4**)

Tabla 4: Análisis bivariante de la base diseñada

	SIN EVENTO N = 90	CON EVENTO N = 70	P value
Variable 1 (Chi-Cuadrado)			
Valor 1	40 (100%)	0 (0%)	
Valor 2	30 (75%)	10 (25%)	
Valor 3	20 (50%)	20 (50%)	
Valor 4	0 (0%)	40 (100%)	< 0.001
Variable 1 (Test no paramétrico: U de Mann-Whitney)			
Media ± DE	1.7± 0.8	3.4±0.7	< 0.001
Variable 2 (Test no paramétrico: U de Mann-Whitney)			
Media ± DE	43.6 ± 20.4	57.8 ± 19.7	< 0.001
Variable 3 (Chi-Cuadrado)			
Hombre	50 (62.5%)	30 (37.5%)	
Mujer	40 (50%)	40 (50%)	0.111

Se remarcán en sombreado azul las variables con significación estadística.

A la vista del análisis bivariante, se extraerían las siguientes conclusiones:

- ✓ La variable 1 (p.ej. la escala Norton) ya sea tratada como cualitativa o cuantitativa, muestra diferencias muy significativas en relación al evento y parece que influye especialmente en valores extremos.
- ✓ La variable 2 (p.ej. edad) también muestra diferencias muy significativas en relación al evento.
- ✓ La variable 3 (p.ej. sexo) no muestra diferencias en relación al evento y por tanto no influye en su aparición.

El siguiente paso para hacer el análisis de la RNA, sería definir los parámetros de nuestra red (**Tabla 5**).

Tabla 5: Parámetros de la RNA

Modo de Red: Multilayer Perceptron (Perceptron Multicapa)		
Capas y Neuronas		Funciones
Capas	Neuronas	Funcion de Activacion
Capa de Entrada	Todas las variables como: “Covariables”: Reescalamiento de Covariables Estandarizado: $(x - \text{media}/\text{DS})$	Identidad $y = x$ $[-\infty, +\infty]$
Capa Ocultas	Automática Neuronas: Mínimo 1 Máximo 50	Funcion de Activacion Tangente Hiperbólica $y = \tanh(x)$ $[-1, +1]$
Capa de Salida	Neuronas 2	Funcion de Activacion Softmax $\gamma(ck) = \exp(ck)/\sum_j \exp(cj)$ $[0, +1]$ y Suman 1 Funcion de Error Entropía Cruzada $P = 2^{-\text{entropiacruzada}}$ $[0, +\infty)$
Parámetros de Partición de Casos		
Training / Aprendizaje	70%	
Testing / Validación	30%	
Parámetros de Aprendizaje (algoritmo)		
Gradiente Conjugado Escalado (GCE)	$d_{i+1} = g_{i+1} + d_i \gamma_i$ $\gamma: \text{Parametro Conjugado}$	Tipo de Aprendizaje Lotes (batch) Hiperparámetros Lambda inicial 0.0000005 Sigma inicial 0.00005 Centro de intervalo 0 Desplazamiento de intervalo ± 0.5



Para una mejor compresión se explica brevemente el significado de cada uno de los parámetros:

- ✓ **Modelo de red Multilayer Perceptron (Perceptron Multicapa)** el cual se basa en un modelo de aprendizaje supervisado. Un ejemplo comparativo bastante aproximado de lo que significa, sería como si un estudiante preparase una materia, estudiando solo las preguntas y respuestas correctas de exámenes anteriores; y despues se enfrentarse al examen con preguntas nuevas, nunca vistas.
- ✓ **Capa de entrada:** Está constituida por tantas neuronas como variables se introducen en la red. Trabajan con una función de identidad ($y=x$).
- ✓ **Capa oculta:** El número de capas ocultas y las neuronas que las constituyen, lo determina la propia aplicación informática. Estas neuronas trabajarán con una función tangente hiperbólica, transforma los valores de entrada en un valor comprendido entre el -1 y el 1.
- ✓ **Capa de salida:** Estará constituida por dos neuronas que trabajan con una función Softmax, transforma los valores de entrada en un valor de salida comprendido entre el 0 y el 1 (0= no hay evento, 1= hay evento), los valores intermedios se pueden interpretar como un tanto por ciento de la probabilidad que lo haya y entre ambos suman 1.
- ✓ **La función de error,** es la que le permite a la red calcular cuánto se ha equivocado en la predicción. En nuestro diseño se utiliza la función de entropía cruzada, puede decirse que sería algo así como una medida de sorpresa. Si obtenemos una baja entropía (*sorpresa*), es que la salida, se aproxima a lo esperado, por el contrario, si obtenemos una alta entropía (*sorpresa*) la salida se aleja de lo esperado.



- ✓ **Partición**, representa el porcentaje de casos de la base de datos que divide 2 lotes: uno que dedicamos al aprendizaje y otro que dedicamos a la validación.

- ✓ **Función de aprendizaje**, es la función que utiliza la red para calcular los pesos (importancia) de cada variable y con la que sabe cuándo ha terminado de aprender. En nuestro caso es la función de gradiente conjugado escalado.

Finalmente, en base al diseño anterior e introduciendo nuestra base de datos en la RNA con la que estamos trabajando, se han obtenido los resultados que se reflejan en a (**Tabla 6**)

Tabla 6: Resultados RNA.

Sumario Casos Procesados (N=160)																																																							
Usados																																																							
Training / Aprendizaje																																																							
Testing / Validación																																																							
Validos																																																							
Excluidos																																																							
Información de Red																																																							
Arquitectura: <i>Capa Entrada : Capas Ocultas: Capa Salida</i>																																																							
Diagrama 																																																							
Pesos y Sesgos (Bias) <table border="1"> <thead> <tr> <th rowspan="2">Predictor</th> <th colspan="4">Pronosticado</th> </tr> <tr> <th>Capa oculta 1</th> <th>Capa de salida</th> <th>[Evento01=0]</th> <th>[Evento01=1]</th> </tr> </thead> <tbody> <tr> <td>Capa de entrada (Sesgo)</td> <td>4,311</td> <td>,398</td> <td>2,726</td> <td>1,000</td> </tr> <tr> <td>VAR2Edad</td> <td>5,602</td> <td>,381</td> <td>-3,034</td> <td>-,040</td> </tr> <tr> <td>VAR1Norton</td> <td>-1,084</td> <td>3,969</td> <td>-6,459</td> <td>-,067</td> </tr> <tr> <td>VAR3Sexo</td> <td>-5,153</td> <td>3,621</td> <td>,110</td> <td>,831</td> </tr> <tr> <td>Capa oculta 1 (Sesgo)</td> <td></td> <td></td> <td>-,569</td> <td>-,168</td> </tr> <tr> <td>H(1:1)</td> <td></td> <td></td> <td>-5,903</td> <td>5,420</td> </tr> <tr> <td>H(1:2)</td> <td></td> <td></td> <td>-5,316</td> <td>5,907</td> </tr> <tr> <td>H(1:3)</td> <td></td> <td></td> <td>7,042</td> <td>-6,948</td> </tr> <tr> <td>H(1:4)</td> <td></td> <td></td> <td>-,226</td> <td>,435</td> </tr> </tbody> </table>		Predictor	Pronosticado				Capa oculta 1	Capa de salida	[Evento01=0]	[Evento01=1]	Capa de entrada (Sesgo)	4,311	,398	2,726	1,000	VAR2Edad	5,602	,381	-3,034	-,040	VAR1Norton	-1,084	3,969	-6,459	-,067	VAR3Sexo	-5,153	3,621	,110	,831	Capa oculta 1 (Sesgo)			-,569	-,168	H(1:1)			-5,903	5,420	H(1:2)			-5,316	5,907	H(1:3)			7,042	-6,948	H(1:4)			-,226	,435
Predictor	Pronosticado																																																						
	Capa oculta 1	Capa de salida	[Evento01=0]	[Evento01=1]																																																			
Capa de entrada (Sesgo)	4,311	,398	2,726	1,000																																																			
VAR2Edad	5,602	,381	-3,034	-,040																																																			
VAR1Norton	-1,084	3,969	-6,459	-,067																																																			
VAR3Sexo	-5,153	3,621	,110	,831																																																			
Capa oculta 1 (Sesgo)			-,569	-,168																																																			
H(1:1)			-5,903	5,420																																																			
H(1:2)			-5,316	5,907																																																			
H(1:3)			7,042	-6,948																																																			
H(1:4)			-,226	,435																																																			
Sumario del Modelo																																																							
Aprendizaje	Error de Entropía Cruzada	0.055																																																					
	Predicciones Incorrectas (%)	0%																																																					
	Regla de Parada	1 paso consecutivo sin disminuir error																																																					
	Tiempo de Entrenamiento	0:00:00:08																																																					
Validación	Error de Entropía Cruzada	0.00																																																					
	Predicciones Incorrectas (%)	0%																																																					
Matriz de Clasificación y Métricas de Rendimiento																																																							
Aprendizaje	Matriz <table border="1"> <thead> <tr> <th rowspan="2">Observado</th> <th colspan="2">Predicho por RNA</th> </tr> <tr> <th>No</th> <th>Si</th> </tr> </thead> <tbody> <tr> <td>No</td> <td>58</td> <td>0</td> </tr> <tr> <td>Si</td> <td>0</td> <td>50</td> </tr> </tbody> </table>		Observado	Predicho por RNA		No	Si	No	58	0	Si	0	50																																										
Observado	Predicho por RNA																																																						
	No	Si																																																					
No	58	0																																																					
Si	0	50																																																					
EXACTITUD (Accuracy) (Diagnostic Accuracy) VN + VP/Total 100%																																																							
Matriz <table border="1"> <thead> <tr> <th rowspan="2">Observado</th> <th colspan="2">Predicho por RNA</th> </tr> <tr> <th>No</th> <th>Si</th> </tr> </thead> <tbody> <tr> <td>No</td> <td>32</td> <td>0</td> </tr> <tr> <td>Si</td> <td>0</td> <td>20</td> </tr> </tbody> </table>		Observado	Predicho por RNA		No	Si	No	32	0	Si	0	20																																											
Observado	Predicho por RNA																																																						
	No	Si																																																					
No	32	0																																																					
Si	0	20																																																					
EXACTITUD (Accuracy) (Diagnostic Accuracy) VN + VP/Total 100%																																																							
Importancia Normalizada de las Variables																																																							
Variable 1 "Norton"	0.508	100%																																																					
Variable 2 "Edad"	0.309	60.8%																																																					
Variable 3 "Sexo"	0.183	35.9%																																																					



A la vista de los resultados obtenidos con la RNA, extraeríamos las siguientes conclusiones.

- ✓ La RNA obtenida muestra una **exactitud** del 100%, o sea, sería capaz de predecir el resultado del evento en todos los casos.
- ✓ La variable 1 (*p.ej. la escala Norton*) es muy importante en la predicción del evento, como se refleja en el valor del 100% en la importancia normalizada.
- ✓ La variable 2 (*p.ej. edad*) influye en la aparición del evento en el 60% de los casos.
- ✓ La variable 3 (*p.ej. sexo*) influye en casi un 36% de los casos, a diferencia de lo que se reflejaba en la estadística convencional que no mostraba diferencias estadísticamente significativas en relación a la aparición de los casos.



2. HIPOTESIS y OBJETIVOS

Hipótesis de Trabajo.

Diseño de una red neuronal para la predicción de la aparición de LPP

Objetivos

Objetivo principal:

- **Explorar** la creación de una red neuronal partiendo de un ejemplo en la predicción de LPP en paciente crítico.

Objetivos secundarios:

- **Profundizar** en el conocimiento de la estadística convencional
- **Analizar** las diferencias observadas entre la estadística convencional y la RNA



3. MATERIAL Y METODOS.

Se presenta un estudio retrospectivo, observacional de predicción de LPP a través de una RNA.

3.1. Fases

El estudio contempla las siguientes fases:

3.1.1. Obtención de la Base de Datos y Definición del evento

Se obtuvo una base de datos anonimizada extraída del programa informático de estancia en UCI (ICCA). Con los datos de todos los ingresos consecutivos, de más de cuatro días de estancia en UCI, durante 6 meses.

Tras la obtención de la Base de Datos, se realizaron tareas de limpieza y pre-procesamiento: resolviendo problemas de ausencia de datos, datos inconsistentes o erróneos (p. ej. tiempos negativos).

Se recogieron los datos englobados en los siguientes apartados.

- ✓ **Datos de Filiación:** edad, sexo, fecha de nacimiento.
- ✓ **Datos Clínicos:** tipo de paciente (médico o quirúrgico), motivo de ingreso (insuficiencia respiratoria, sepsis, infarto...), días de estancia, procedencia (061, urgencias, otro hospital...), ventilación mecánica (sí o no), APACHE y exitus (sí o no)
- ✓ **Datos de LPP:** Norton al ingreso (N_0), al 4º día (N_4) y al 7º día (N_7), aparición (sí o no) y grado según sistema de clasificación de la NPUAP/EPUAP¹

El evento objeto de estudio se define como la aparición de LPP de cualquier grado.



3.1.2. Ingeniería de datos

La Ingeniería de Datos consiste en el proceso de transformación (redefinición) de las variables independientes de “datos sin procesar” a “vectores de atributos = entradas”. Puede suponer el 70-75% del tiempo de creación de una RNA. Entre las posibilidades que contempla están:

- ✓ *Recodificación de variables tanto continuas como categóricas*
- ✓ *Creación de variables sintéticas mediante: agrupamiento, operadores, funciones o combinación de atributos.*
- ✓ *Cálculos y recodificación de tiempos, etc.*

3.1.3. Análisis Estadístico Convencional

El Análisis Estadístico Convencional será descriptivo e inferencial bivariante de los datos, tanto globales como respecto del evento.

Para las **variables cuantitativas** se obtendrán parámetros de tendencia central (media aritmética, geométrica y armónica y moda), medidas de dispersión (desviación estándar, error estándar, coeficiente de variación rango y varianza) y medidas de forma (coeficiente de kurtosis o aplastamiento y coeficiente de asimetría). Se evaluará la normalidad de la distribución de datos continuos utilizando gráficos Q-Q plots y la prueba de Shapiro-Wilk.

Para **variables cualitativas** se calculará la distribución de frecuencias según las categorías (respuestas) existentes en cada una de ellas.

Se utilizarán las siguientes pruebas en el contraste de hipótesis: Chi-cuadrado de Pearson derivado de tablas de contingencia para variables cualitativas; “t” de Student o Test No Paramétricos (U de Mann-Whitney) para variables cuantitativas, en función de su distribución de normalidad.



3.1.4. Red Neuronal Artificial.

Se trabajará de una RNA diseñada con las características descritas en el apartado 2.

3.1.5. Matriz de confusión y Métricas de Rendimiento.

El Software nos proporcionará una matriz de confusión a partir de la cual se pueden obtener todas las métricas de rendimiento deseadas (sensibilidad, especificidad, valor predictivo...) de las que nosotros solo utilizaremos la **exactitud** definida como:

$$\text{Exactitud} = \frac{\text{Verdaderos positivos} + \text{Verdaderos negativos}}{\text{total}} = 0 - 100\%$$

3.2. Programas Informáticos

3.2.1. Análisis Estadístico

Para el tratamiento de datos se utilizará: el paquete estadístico IBM® SPSS® Statistics versión 26.0. (©Copyright IBM Corporation 1989 to 2013, Chicago, IL, USA).

Un p-valor Wald de $p < 0,05$ se considerará significativo.

3.2.2. Red Neuronal

Para el diseño y validación de la Red Neuronal Artificial se usará el programa IBM® Neural Network versión 26.0.

4. RESULTADOS.

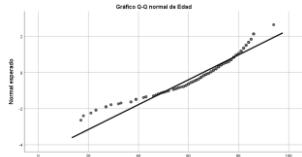
Aplicando la metodología anteriormente descrita, se han obtenido los resultados que se detallan a continuación.

4.1. Descripción de la Población

Los resultados descriptivos de la serie estudiada se demuestran en la (**Tabla 7**).

Tabla 7. Descripción de la población

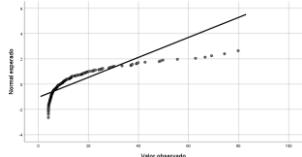
N= 285

Datos Demográficos	
Genero:	
Mujer	95 33.3%
Hombre	190 66.7%
Edad (años):	
Media ± DE	65.8± 14.5
Mediana	69.0
IQR	59.8 - 77 (17)
Min-Max (Rango)	17 - 94 (77)
Asimetría	-1.1
Kurtosis	1.2
Test de Normalidad	
Prueba de Normalidad Shapiro-Wilk Hipótesis Nula (H₀) <i>La variable Edad sigue una distribución normal con media de 65.8 y DE de 14.5</i> p < 0.001	
Normalidad Grafica Grafica QQ 	
Conclusión <i>Se rechaza la H₀. La variable Edad NO sigue una distribución normal</i>	
Patologías, Procedimientos y Evolución	
Tipo Paciente	
Medico	191 67.0%
Quirúrgico	94 33.0%
Patología:	
Neumológica	77 27.0%
Digestiva	62 21.8%
Neurológica	43 15.1%
Cardiaca	31 10.9%
Nefrológica	19 6.7%
Traumática	14 4.9%
Otras	39 13.7%
Procedencia:	
Planta	96 33.7%
Urgencias	73 25.6%
Quirófano	62 21.8%
Otro Hospital	41 14.4%
061	13 4.6%
Oxigenoterapia	
Nada / O ₂	67 23.5%
VMNIV	39 13.7%
VMIV	179 62.8%

DE: Desviación Estándar; **IQR:** Rango Intercuartílico; **Min:** Mínimo; **Max:** Máximo;

O₂: Gafas nasales; **VMNIV:** Ventilación Mecánica No Invasiva; **VMIV:** Ventilación Mecánica Invasiva.

Tabla 7 continuación. Descripción de la población

Evolución	
Estancia	
Media \pm DE	13.2 \pm 12.7
Mediana	8.7
IQR	5.7 - 15.0 (9.3)
Min-Max (Rango)	4 - 79.8 (75.9)
Asimetría	2.7
Kurtosis	8.7
Test de Normalidad	Prueba de Normalidad Shapiro-Wilk Hipótesis Nula (H_0) <i>La variable Estancia sigue una distribución normal con media de 13.2 y DE de 12.7</i> p< 0.001
	Normalidad Gráfica Grafica QQ 
Exitus	Conclusión <i>Se rechaza la H_0. La variable Estancia NO sigue una distribución normal</i>
Si	64 22.5%
No	221 77.6%

DE: Desviación Estándar; **IQR:** Rango Intercuartílico; **Min:** Mínimo; **Max:** Máximo.

Tabla 7 continuación. Descripción de la población

ESCALAS: APACHE y NORTON				
APACHE				
Test de Normalidad	Media \pm DE	18.0 ± 8.4		
	Mediana	17.0		
	IQR	12.0 – 23.0 (11.0)		
	Min-Max (Rango)	2.0 – 45.0 (43.0)		
	Asimetría	0.7		
	Kurtosis	0.4		
	Prueba de Normalidad Shapiro-Wilk Hipótesis Nula (H_0) <i>La variable APACHE sigue una distribución normal con media de 13.2 y DE de 12.7</i> $p < 0.001$		Normalidad Grafica Grafica QQ 	
	Conclusión <i>Se rechaza la H_0. La variable APACHE NO sigue una distribución normal</i>		Conclusión <i>El diagrama de cuantiles no es lineal y por tanto la distribución no es normal</i>	
N1: NORTON al ingreso				
Test de Normalidad	Media \pm DE	10.6 ± 3.2		
	Mediana	10.0		
	IQR	7.0 – 13.0 (6.0)		
	Min-Max (Rango)	5.0 – 17.0 (12.0)		
	Asimetría	0.1		
	Kurtosis	-1.4		
	Prueba de Normalidad Shapiro-Wilk Hipótesis Nula (H_0) <i>La variable Norton N1 sigue una distribución normal con media de 10.6 y DE de 10.2</i> $p < 0.001$		Normalidad Grafica Grafica QQ 	
	Conclusión <i>Se rechaza la H_0. La variable Norton N1 NO sigue una distribución normal</i>		Conclusión <i>El diagrama de cuantiles no es lineal y por tanto la distribución no es normal</i>	
N4: NORTON al 4º día				
Test de Normalidad	Media \pm DE	11.0 ± 3.2		
	Mediana	11.0		
	IQR	8.0 – 14.0 (6.0)		
	Min-Max (Rango)	5.0 – 18.0 (13.0)		
	Asimetría	0.1		
	Kurtosis	-1.1		
	Prueba de Normalidad Shapiro-Wilk Hipótesis Nula (H_0) <i>La variable Norton N4 sigue una distribución normal con media de 11.0 y DE de 3.2</i> $p < 0.001$		Normalidad Grafica Grafica QQ 	
	Conclusión <i>Se rechaza la H_0. La variable Norton N4 NO sigue una distribución normal</i>		Conclusión <i>El diagrama de cuantiles no es lineal y por tanto la distribución no es normal</i>	

DE: Desviación Estándar; **IQR:** Rango Intercuartílico; **Min:** Mínimo; **Max:** Máximo.

4.2. Estadística Convencional

En la **Tabla 8**, se muestran los resultados del análisis bivariante de todas las variables estudiadas con respecto al evento.

Tabla 8. Análisis bivariante

	SIN LPP N = 207	CON LPP N = 78	P value
Datos Demográficos			
Sexo¹:			
Mujer	68 (32.9%)	27 (34.6%)	0.778
Varón	139 (67.1%)	51 (65.4%)	
Edad²:			
Media	64.0 ± 15.3	68.4 ± 12.9	0.022
Patologías, Procedimientos y Evolución			
Tipo de paciente¹:			
Médico	141 (68.1%)	50 (64.1%)	0.521
Quirúrgico	66 (31.9%)	28 (35.9%)	
Tipo de Patología¹:			
Neumológica	57 (27.5%)	20 (25.6%)	
Digestiva	37 (17.9%)	25 (32.1%)	
Neurológica	39 (18.8%)	4 (5.1%)	
Cardiaca	24 (11.6%)	7 (9.0%)	
Nefrológica	13 (6.3%)	6 (7.7%)	
Traumática	9 (4.3%)	5 (6.4%)	
Otras	28 (13.5%)	11 (14.1%)	
Procedencia¹:			
Planta	65 (31.4%)	31 (39.7%)	
Urgencias	58 (28.0%)	15 (19.2%)	
Quirófano	43 (20.8%)	19 (24.4%)	
Otro Hospital	30 (14.5%)	11 (14.1%)	
061	11 (5.3%)	2 (2.6%)	
Ventilación¹:			
Nada / O ₂	58 (28.0%)	9 (11.5%)	
VMNIV	33 (15.9%)	6 (7.7%)	
VMIV	116 (56.1%)	63 (80.8%)	
Escalas			
APACHE²			
Media	17.0 ± 8.4	20.6 ± 8.0	0.001
N1²			
Media	10.8 ± 3.3	10.0 ± 3.2	0.070
N4²			
Media	11.6 ± 3.3	9.6 ± 2.7	<0.001

1: Chi-cuadrado y 2: Test no Paramétricos: U de Mann-Whitney; **O₂**: Gafas nasales;
VMNIV: Ventilación Mecánica No Invasiva; **VMIV**: Ventilación Mecánica Invasiva;

N₁: Norton primer día de ingreso; **N₄**: Norton cuarto día de ingreso.

Se remarcán en sombreado azul las variables con significación estadística.

4.3. Red Neuronal Artificial

Los resultados de la RNA se exponen en la **Tabla 9** con el mismo modelo utilizado en el ejemplo de la introducción. La exactitud de la RNA creada en el conjunto de aprendizaje y de validación fue del 75.3% y del 70.2% respectivamente.

Tabla 9. Red neuronal de predicción de LPP

Sumario Casos Procesados (N=285)																																																																																				
Usados	285																																																																																			
Training / Aprendizaje	158 65.3%																																																																																			
Testing / Validación	84 34.7%																																																																																			
Validos	242																																																																																			
Excluidos	43																																																																																			
Información de Red																																																																																				
Arquitectura: <i>Capa Entrada : Capas Ocultas: Capa Salida</i>	9:3:2																																																																																			
Diagrama 	Pesos y Sesgos (Bias) <table border="1"> <thead> <tr> <th rowspan="3">Predictor</th> <th colspan="4">Estimaciones de parámetro Pronosticado</th> </tr> <tr> <th colspan="2">Capa oculta 1</th> <th colspan="2">Capa de salida</th> </tr> <tr> <th>H(1:1)</th> <th>H(1:2)</th> <th>H(1:3)</th> <th>[Evento=NO] [Evento=SI]</th> </tr> </thead> <tbody> <tr> <td>Capa de entrada (Sesgo)</td> <td>.412</td> <td>.379</td> <td>-.809</td> <td></td> </tr> <tr> <td>Edad</td> <td>.043</td> <td>.372</td> <td>-.366</td> <td></td> </tr> <tr> <td>APACHE</td> <td>.370</td> <td>.257</td> <td>.810</td> <td></td> </tr> <tr> <td>Norton1dia</td> <td>-.111</td> <td>.036</td> <td>.005</td> <td></td> </tr> <tr> <td>Norton4dia</td> <td>-.017</td> <td>-.875</td> <td>-.088</td> <td></td> </tr> <tr> <td>TipoPaciente</td> <td>-.119</td> <td>-.633</td> <td>.438</td> <td></td> </tr> <tr> <td>Tipopatología</td> <td>-.350</td> <td>.729</td> <td>-.1306</td> <td></td> </tr> <tr> <td>Procedencia</td> <td>.526</td> <td>.215</td> <td>.132</td> <td></td> </tr> <tr> <td>VentilacionMecanica</td> <td>-.801</td> <td>.692</td> <td>-.751</td> <td></td> </tr> <tr> <td>Sexo</td> <td>.249</td> <td>.288</td> <td>.305</td> <td></td> </tr> <tr> <td>Capa oculta 1 (Sesgo)</td> <td></td> <td></td> <td></td> <td>.147 -.651</td> </tr> <tr> <td>H(1:1)</td> <td></td> <td></td> <td></td> <td>.611 -.077</td> </tr> <tr> <td>H(1:2)</td> <td></td> <td></td> <td></td> <td>-.742 .405</td> </tr> <tr> <td>H(1:3)</td> <td></td> <td></td> <td></td> <td>-.746 .553</td> </tr> </tbody> </table>	Predictor	Estimaciones de parámetro Pronosticado				Capa oculta 1		Capa de salida		H(1:1)	H(1:2)	H(1:3)	[Evento=NO] [Evento=SI]	Capa de entrada (Sesgo)	.412	.379	-.809		Edad	.043	.372	-.366		APACHE	.370	.257	.810		Norton1dia	-.111	.036	.005		Norton4dia	-.017	-.875	-.088		TipoPaciente	-.119	-.633	.438		Tipopatología	-.350	.729	-.1306		Procedencia	.526	.215	.132		VentilacionMecanica	-.801	.692	-.751		Sexo	.249	.288	.305		Capa oculta 1 (Sesgo)				.147 -.651	H(1:1)				.611 -.077	H(1:2)				-.742 .405	H(1:3)				-.746 .553
Predictor	Estimaciones de parámetro Pronosticado																																																																																			
	Capa oculta 1		Capa de salida																																																																																	
	H(1:1)	H(1:2)	H(1:3)	[Evento=NO] [Evento=SI]																																																																																
Capa de entrada (Sesgo)	.412	.379	-.809																																																																																	
Edad	.043	.372	-.366																																																																																	
APACHE	.370	.257	.810																																																																																	
Norton1dia	-.111	.036	.005																																																																																	
Norton4dia	-.017	-.875	-.088																																																																																	
TipoPaciente	-.119	-.633	.438																																																																																	
Tipopatología	-.350	.729	-.1306																																																																																	
Procedencia	.526	.215	.132																																																																																	
VentilacionMecanica	-.801	.692	-.751																																																																																	
Sexo	.249	.288	.305																																																																																	
Capa oculta 1 (Sesgo)				.147 -.651																																																																																
H(1:1)				.611 -.077																																																																																
H(1:2)				-.742 .405																																																																																
H(1:3)				-.746 .553																																																																																
Sumario del Modelo																																																																																				
Aprendizaje	Error de Entropía Cruzada	78.3																																																																																		
	Predicciones Incorrectas (%)	24,7%																																																																																		
	Regla de Parada	1 paso consecutivo sin disminuir error																																																																																		
	Tiempo de Entrenamiento	0:00:00:29																																																																																		
Validación	Error de Entropía Cruzada	44.6																																																																																		
	Predicciones Incorrectas (%)	29.8%																																																																																		
Matriz de Clasificación y Métricas de Rendimiento																																																																																				
Aprendizaje	<table border="1"> <thead> <tr> <th colspan="2"></th> <th colspan="2">Matriz</th> <th colspan="2">Predicho por RNA</th> </tr> <tr> <th colspan="2"></th> <th>No</th> <th>Si</th> <th colspan="2"></th> </tr> <tr> <th rowspan="2">Observado</th> <th>No</th> <td>108</td> <td>8</td> <th colspan="2">93.1%</th> </tr> </thead> <tbody> <tr> <th>Si</th> <td>31</td> <td>11</td> <th colspan="2">26.2%</th> </tr> </tbody> </table>							Matriz		Predicho por RNA				No	Si			Observado	No	108	8	93.1%		Si	31	11	26.2%																																																									
		Matriz		Predicho por RNA																																																																																
		No	Si																																																																																	
Observado	No	108	8	93.1%																																																																																
	Si	31	11	26.2%																																																																																
EXACTITUD (Accuracy) (Diagnostic Accuracy) VN + VP/Total																																																																																				
75.3%																																																																																				
		<table border="1"> <thead> <tr> <th colspan="2"></th> <th colspan="2">Matriz</th> <th colspan="2">Predicho por RNA</th> </tr> <tr> <th colspan="2"></th> <th>No</th> <th>Si</th> <th colspan="2"></th> </tr> <tr> <th rowspan="2">Observado</th> <th>No</th> <td>53</td> <td>6</td> <th colspan="2">89.8%</th> </tr> </thead> <tbody> <tr> <th>Si</th> <td>19</td> <td>6</td> <th colspan="2">24.0%</th> </tr> </tbody> </table>							Matriz		Predicho por RNA				No	Si			Observado	No	53	6	89.8%		Si	19	6	24.0%																																																								
		Matriz		Predicho por RNA																																																																																
		No	Si																																																																																	
Observado	No	53	6	89.8%																																																																																
	Si	19	6	24.0%																																																																																
<table border="1"> <thead> <tr> <th colspan="2"></th> <th colspan="2">Matriz</th> <th colspan="2">Predicho por RNA</th> </tr> <tr> <th colspan="2"></th> <th>No</th> <th>Si</th> <th colspan="2"></th> </tr> <tr> <th rowspan="2">Observado</th> <th>No</th> <td>53</td> <td>6</td> <th colspan="2">89.8%</th> </tr> </thead> <tbody> <tr> <th>Si</th> <td>19</td> <td>6</td> <th colspan="2">24.0%</th> </tr> </tbody> </table>							Matriz		Predicho por RNA				No	Si			Observado	No	53	6	89.8%		Si	19	6	24.0%																																																										
		Matriz		Predicho por RNA																																																																																
		No	Si																																																																																	
Observado	No	53	6	89.8%																																																																																
	Si	19	6	24.0%																																																																																
<table border="1"> <thead> <tr> <th colspan="2"></th> <th colspan="2">Matriz</th> <th colspan="2">Predicho por RNA</th> </tr> <tr> <th colspan="2"></th> <th>No</th> <th>Si</th> <th colspan="2"></th> </tr> <tr> <th rowspan="2">Observado</th> <th>No</th> <td>53</td> <td>6</td> <th colspan="2">89.8%</th> </tr> </thead> <tbody> <tr> <th>Si</th> <td>19</td> <td>6</td> <th colspan="2">24.0%</th> </tr> </tbody> </table>							Matriz		Predicho por RNA				No	Si			Observado	No	53	6	89.8%		Si	19	6	24.0%																																																										
		Matriz		Predicho por RNA																																																																																
		No	Si																																																																																	
Observado	No	53	6	89.8%																																																																																
	Si	19	6	24.0%																																																																																
<table border="1"> <thead> <tr> <th colspan="2"></th> <th colspan="2">Matriz</th> <th colspan="2">Predicho por RNA</th> </tr> <tr> <th colspan="2"></th> <th>No</th> <th>Si</th> <th colspan="2"></th> </tr> <tr> <th rowspan="2">Observado</th> <th>No</th> <td>53</td> <td>6</td> <th colspan="2">89.8%</th> </tr> </thead> <tbody> <tr> <th>Si</th> <td>19</td> <td>6</td> <th colspan="2">24.0%</th> </tr> </tbody> </table>							Matriz		Predicho por RNA				No	Si			Observado	No	53	6	89.8%		Si	19	6	24.0%																																																										
		Matriz		Predicho por RNA																																																																																
		No	Si																																																																																	
Observado	No	53	6	89.8%																																																																																
	Si	19	6	24.0%																																																																																
EXACTITUD (Accuracy) (Diagnostic Accuracy) VN + VP/Total		70.2%																																																																																		
Importancia Normalizada de las Variables																																																																																				
Norton 4	0.211	100%																																																																																		
APACHE	0.208	98.7%																																																																																		
Tipo de patología	0.155	73.6%																																																																																		
Ventilación Mecánica	0.129	60.8%																																																																																		
Edad	0.094	44.4%																																																																																		
Tipo de paciente	0.063	29.7%																																																																																		
Sexo	0.059	28.1%																																																																																		
Procedencia	0.052	24.7%																																																																																		
Norton 1	0.028	13.3%																																																																																		

N4: Norton cuarto día de ingreso; N1:Norton primer día de ingreso



5. DISCUSIÓN

A día de hoy la importancia de los diferentes factores implicados en la aparición de las LPP sigue siendo un tema controvertido³⁰ por ello hay una necesidad de verificar la relación directa entre los FR y la aparición de LPP en los pacientes, para así poder determinar intervenciones específicas. Ya que, aunque existan aspectos en los que no podremos incidir directamente, hay que tener en cuenta que la intervención eficaz ante una única variable podría modificar el resultado^{5, 31}. Aunque las causas de la aparición de LPP se diga que es multifactorial, solo se han asociado a la aparición de estas el uso de drogas vasoactivas, el tiempo de hospitalización y la ausencia de anemias².

El desarrollo de las LPP produce complicaciones al individuo hospitalizado; además de prolongar el tratamiento y la rehabilitación, disminuye la calidad de vida, causa dolor y aumenta la mortalidad³²

En la literatura se encuentran muchos estudios que hablan sobre la dificultad en unidades de cuidados intensivos de valorar correctamente las lesiones de los pacientes como de su predicción, se generan valoraciones muy desiguales según el profesional que la aplica^{2, 11, 33, 34}.

La conclusión que podemos sacar a la vista de todos ellos, es la necesidad de obtener nuevos instrumentos de medida para poder determinar de mejor manera el riesgo de un paciente de padecer una LPP.

En nuestro estudio, se describe un análisis de diferentes factores que pueden estar relacionados con la aparición de LPP, siguiendo una metodología estadística convencional y una metodología novedosa como son las RNA. Esta última, ya dijimos que puede considerarse una forma de análisis multivariante alternativo.

Según la estadística convencional, los factores analizados los que presentaron mayor significación estadística fueron: Norton al cuarto día ($p < 0.001$), APACHE ($p = 0.001$) y ventilación mecánica en los primeros días ($p = 0.001$). Estos datos son congruentes con los encontrados en la RNA diseñada, en la que estas mismas variables, tenían una importancia normalizada del 100%, 98.7%, 60.8%, respectivamente.



Pero al igual que ocurría en el ejemplo realizado al principio del TFM, encontramos variables que no tenían significación estadística en el análisis convencional (Sexo, Tipo de paciente, Procedencia, Norton al primer día), las cuales en el análisis de importancia normalizado de la RNA les adjudica una importancia entre el 15-30% aproximadamente.

Puede resultar muy llamativo que, tanto en la estadística convencional ($p = 0.070$) como en la RNA creada (importancia $N_1 = 13.3\%$), de todas las variables que se han analizado, la que menos importancia tenga, sea al Norton del día del ingreso. Pero posiblemente, como ya hemos apuntado, lo más importante ante la aparición de las UPP, es la necesidad de una prevención adecuada, por lo que el Norton al ingreso podría no ser el factor más determinante.

Este trabajo, de ninguna manera pretende dar la respuesta a todas las preguntas que rodean la valoración del riesgo de padecer LPP: ¿Cuáles son los factores de riesgo?, ¿El estado hemodinámico, el uso de drogas vasoactivas, el estado nutricional?, ¿Cuál es la mejor escala de valoración: Norton, EMINA, Braden...? Pero sí que pretende, introducir una nueva metodología y visión de afrontar este problema.

Recientemente en un artículo publicado en Medicina Intensiva, Nuñez et al³⁵ inciden en que la medicina intensiva es un campo ideal para el empleo de técnicas conocidas como *Big Data Analysis* (BDA) y *Machine Learning* (ML), que pueden permitir en el futuro mejorar nuestra capacidad de investigación clínica y dirigir de manera más precisa las terapias que proporcionamos a nuestros pacientes. Estos mismos autores apuntan que la proyección de las posibilidades de la utilización de RNA se ve incrementada si los datos que utilizan provienen de una gran base de datos multicentrica, entonces las conclusiones que pueden extraerse pueden equiparse a los obtenidos de un ensayo multicentrico, mejorando la utilización de estas grandes bases de datos de manera más eficiente, o permitiendo diseñar nuevos estudios.

Por ello creemos que, si alguna utilidad puede llegar a tener el presente TFM, es ayudar a diseñar nuevos estudios multicentrico con ingentes cantidades de datos (Big Data) que permitan dar respuesta a las múltiples incógnitas que todavía existen.



6. CONCLUSIONES.

A la vista del trabajo presentado y de los resultados expuestos, podemos extraer las siguientes conclusiones:

- La estadística convencional puede tener discrepancias significativas con la nueva metodología de análisis multivariante mediante Redes Neuronales Artificiales.
- Las Redes Neuronales Artificiales son nuevas herramientas metodológicas de investigación, al alcance de los profesionales sanitarios que pueden ayudarles en el diseño de estudios clínicos.
- Es necesario, afrontar nuevos estudios basados en grandes bases de datos multicéntricas y analizados mediante Redes Neuronales Artificiales que nos ayuden a resolver las incógnitas que rodean a las Lesiones Por Presión.



7. CONFLICTO de INTERESES, ASESORIAS y AUTORIZACIONES.

Declaramos no tener ningún conflicto de intereses.

El trabajo ha sido tutorizado por Dña. Beatriz Rodríguez Roca, Profesora Interina de la Facultad de Ciencias de la Salud de la Universidad de Zaragoza.

El trabajo ha contado con la asesoría directa de Milagros Royo Puerto, enfermera de UCI del Hospital Clínico Universitario Lozano Blesa y miembro del Grupo Nacional para el Estudio y Asesoramiento en Úlceras por Presión y Heridas Crónicas (GNEAUPP).

El trabajo contó con la aprobación de la Supervisión de Enfermería, Sra. Marta Palacios Laseca, y la Jefatura del Servicio, Prof. Miguel Ángel Suárez Pinilla, del Servicio de Medicina Intensiva del Hospital Clínico Universitario “Lozano Blesa”, con fecha 4 de diciembre de 2018.

El presente TFM fue presentado para su aprobación por el Comité de Ética de la Investigación de la Comunidad Autónoma de Aragón (CEICA). Aprobado en su reunión del día 02/12/2020, Acta Nº 23/2020. (**Anexo 8.3**)

8. ANEXOS

8.1. Anexo 1. Escalas de Valoración del riesgo de LPP.

BRADEN ⁸					
	Puntos	1	2	3	4
Variables	<i>Percepción sensorial</i>	Completamente limitada	Muy limitada	levente	No alterada
	<i>Exposición Humedad</i>	Completamente húmeda	Muy húmeda	ocasionalmente	Raramente húmeda
	<i>Actividad</i>	En cama	En silla	Camina ocasionalmente	Camina con frecuencia
	<i>Movilidad</i>	Completamente inmóvil	Muy limitada	Ligeramente limitada	Sin limitaciones
	<i>Nutrición</i>	Muy pobre	Probablemente inadecuada	Adeuada	Excelente
	<i>Fricción y cizallamiento</i>	Es un problema	Es un problema potencial	Sin problema	

Interpretación	Puntuación		Riesgo	
		17-23	Sin riesgo	
		15-16	Bajo	
		13-14	Moderado	
		≤ 12	Alto	

NORTON ¹¹					
	Puntos	1	2	3	4
Variables	<i>Estado físico</i>	Muy malo	Regular	Mediano	Bueno
	<i>Estado mental</i>	Estupor /coma.	Confuso	Apático	Alerta
	<i>Actividad</i>	Encamado	Sentado	Camina con ayuda	Ambulante
	<i>Movilidad</i>	Inmóvil	Muy limitada	Disminuida	Total
	<i>Incontinencia</i>	Urinaria + fecal	Urinaria o fecal	Ocasional	Ninguna

Interpretación	Puntuación		Riesgo	
		>14	Mínimo	
		12-14	Evidente	
		5-11	Alto riesgo	

EMINA ¹³					
	Puntos	0	1	2	3
Variables	<i>Estado mental</i>	Orientado	Desorientado, apático o pasivo	Letárgico o hipercinético	Comatoso
	<i>Movilidad</i>	Completa	Ligeramente limitada	Limitación importante	Inmóvil
	<i>Humedad r/c incontinencia</i>	No	Urinaria o fecal ocasional	Urinaria o fecal habitual	Urinaria y fecal
	<i>Nutrición</i>	Correcta	Ocasionalmente incompleta	Incompleta	No ingesta
	<i>Actividad</i>	Deambula	Deambula con ayuda	Siempre necesita ayuda	No deambula

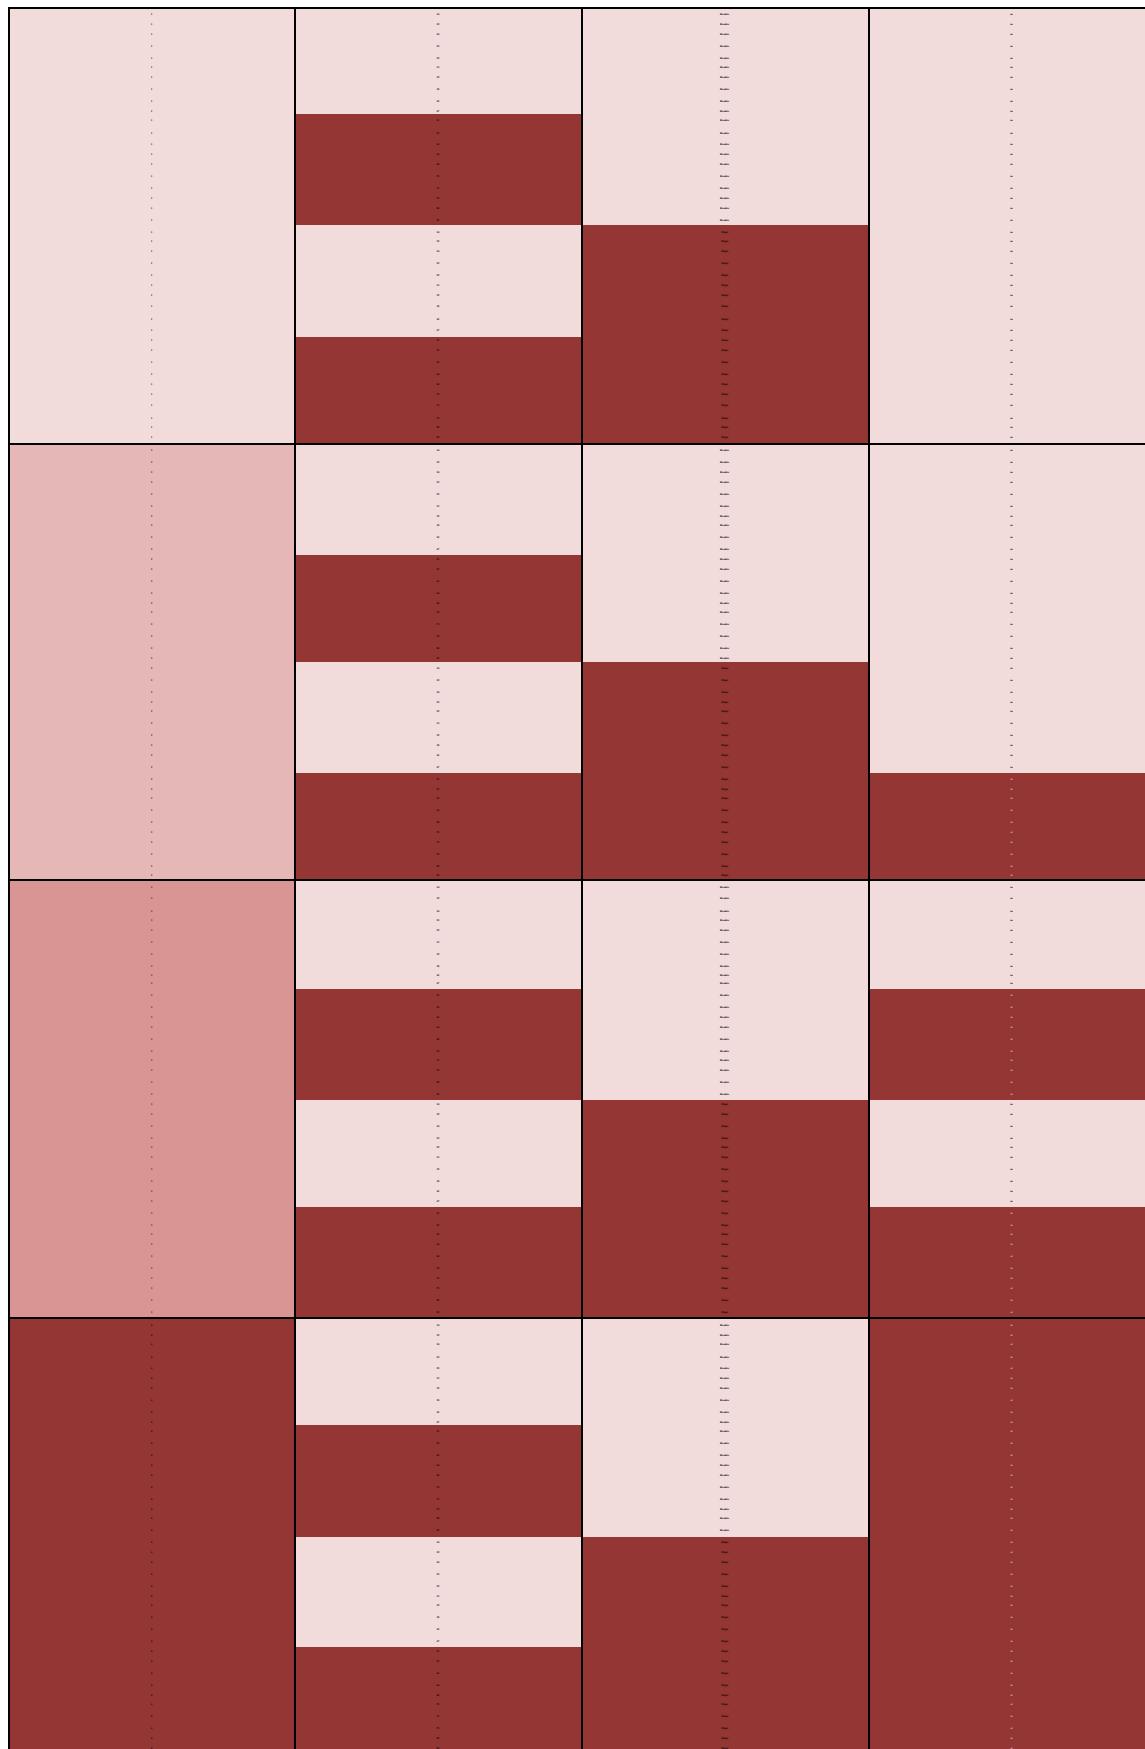
Interpretación	Puntuación		Riesgo	
		8-15	Alto	
		4-7	Moderado	
		1-3	Bajo	
		0	Sin riesgo	



8.2. Anexo 2. Patrones de entrada de la base de datos del ejemplo de utilidad.

A continuación, se muestra una tabla simplificada con los **patrones de entrada** de la base de datos en código de colores, y la base completa en un mínimo tamaño.

Variable 1 Semicuantitativa (p.ej. Escala Norton)	Variable 2 Cuantitativa (p.ej. Edad)		Variable 3 Cualitativa (p.ej. Sexo)		Variable 4: Evento Dicotómica (p.ej. aparición de UPP)
Valor 1 (n=40)	Cualquier Valor		Cualquier valor		NO
Valor 2 (n=40)	< 50	> 50	Hombre	Mujer	SI
Valor 3 (n=40)	< 50	> 50	Cualquier valor		SI
Valor 4 (n=40)	Cualquier valor		Cualquier valor		SI





8.3. Anexo 3. Carta de aprobación del CEICA.



**Informe Dictamen Favorable
Trabajos académicos**

C.P. - C.I. PI20/571

2 de diciembre de 2020

Dña. María González Hinjos, Secretaria del CEIC Aragón (CEICA)

CERTIFICA

1º. Que el CEIC Aragón (CEICA) en su reunión del día 02/12/2020, Acta N° 23/2020 ha evaluado la propuesta del Trabajo:

Título: Lesiones por presión en el paciente crítico: Explorando Redes Neuronales.

Alumna: Ana Belén Araiz Marín

Directora: Beatriz Rodríguez Roca

Versión protocolo: noviembre/2020

2º. Considera que

- El proyecto se plantea siguiendo los requisitos de la Ley 14/2007, de 3 de julio, de Investigación Biomédica y los principios éticos aplicables.
- El Tutor/Director garantiza la confidencialidad de la información, la correcta obtención de los datos, el adecuado tratamiento de los datos en cumplimiento de la legislación vigente y la correcta utilización de los recursos materiales necesarios para su realización.

3º. Por lo que este CEIC emite **DICTAMEN FAVORABLE** a la realización del proyecto.

Lo que firmo en Zaragoza

GONZALEZ Firmado digitalmente
HINJOS por GONZALEZ
MARIA-DNI 03857456B
03857456B Fecha 2020.12.04
13:30:37 +01'00'

Maria González Hinjos
Secretaria del CEIC Aragón (CEICA)

9. BIBLIOGRAFIA

¹ National Pressure Ulcer Advisory Panel, European Pressure Ulcer Advisory Panel and Pan Pacific Pressure Injury Alliance. (2014). *Prevention and Treatment of Pressure Ulcers: Quick Reference Guide*. Emily Haesler. Australia: Cambridge Media: Osborne Park.

² Olivera, AC., Porto, C., Almeida, AD., Santos, AC. (2015). Úlcera por presión: incidencia y factores demográficos, clínicos y nutricionales en pacientes de una unidad de cuidados intensivos. *Nutrición Hospitalaria*, 32, 2242-2252.

³ Wada, A., Teixeira, N., Ferreira, MC., (2010). Ulceras por Pressao. *Medicina*, 89(3),170-177.

⁴ Shahin, ES., Dassen, T., Halfens, RJ. (2009). Incidence, prevention and treatement of pressure ulcers in intensive care patients: a longitudinal study. *Int J Nurs Stud*, 46, 413-421.

⁵ Roca, A., Velasco, MC., Rubio, L., García, N., Anguera, N., (2012). Úlceras por presión en el enfermo crítico: detección de factores de riesgo. *Enfermería Intensiva*, 23(4), 155-163.

⁶ Pancorbo, PL., García, FP., Soldevilla, JJ., Martinez, F. (2008). Valoración del riesgo de desarrollar UPP: uso clínico en España y metaanálisis de la efectividad de las escalas. *Gerokomos*, 19(2), 84-98.

⁷ Pancorbo, Pl., García-Fernandez, FP., Soldevilla, JJ., Blasco García, C. (2009). Escalas e Instrumentos de valoración del riesgo de desarrollo úlceras por Presion. Serie Documentos Técnicos GNEAUPP nº XI Grupo Nacional Para el Estudio y Asesoramiento en Úlceras por Presión y Heridas Crónicas. Logroño.

⁸ Braden, B., Bergstrom, NA. (1987). Conceptual schema for the study of the etiology of pressure sores. *Rehabil Nurs*, 12(1), 8-12.

⁹ Waterlow J. (1985). A risk assessment card. *Nursing Times*, 81 (49), 51-55.

¹⁰ Norton, D., Exton-Smith, AN., McLaren, R. (1962). *An investigation of geriatric nursing problems in hospital*. National Corporation for the care of old people. London: Curchill Livingstone.

¹¹ Romanos, B., Casanova N. (2017). La escala de Norton modificada por el INSALUD y sus diferencias en la práctica clínica. *Gerokomos*, 28(4), 194-199.

¹² García, FP., Pancorbo, PL., Soldevilla, JJ., Rodriguez, MC. (2013). Valoración del riesgo de desarrollar UPP en las unidades de cuidados críticos: revisión sistemática con metaanálisis. *Gerokomos*, 24(2), 82-89.

¹³ Fuentelsaz, C. (2001). Validación de la Escala EMINA: un instrumento de valoración del riesgo de desarrollar úlceras por presión en pacientes hospitalizados. *Enfermería Clínica*, 11(3), 97-103.

¹⁴ Rodriguez, MC., Garcia, FP., Plaza, F., De La Casa, F., Martinez, C., Noguera, A., et al. (2005). Validación de la escala EMINA. *Gerokomos*, 16(3), 174-182.

¹⁵ Verdú, J., Nolasco, A., García, C. (2003). Análisis y evolución de la mortalidad por úlceras por presión en España. Periodo 1987-1999. *Gerokomos*, 14, 212-226.

¹⁶ Soldevilla, JJ., Navarro, S. (2006). Aspectos relacionados con las Úlceras por presión. *Gerokomos*, 17(4), 203-204.

¹⁷ Soldevilla, JJ., Torra, JE., Postt, J., Védu, J., San Miguel, L., Mayán, JM. (2007). The burden of pressure ulcers in Spain. *Wounds*, 19(7), 201-206.

¹⁸ Soldevilla JJ., Torra, JE., Rueda, J., Martínez, F., Verdú, J., Mayán, JM., et al. (2006). Estudio Nacional de Prevalencia de Ulceras Por Presión en España, 2005 Epidemiología y variables definitorias de las lesiones y pacientes. *Gerokomos*, 17, 154-172.

¹⁹ Martínez, F., Soldevilla, JJ., Verdú, J., Segovia, T., García, FP., Pancorbo, PL. (2007). Cuidados de la piel y prevención de UPP en el paciente encamado. *Rev ROL Enf*, 30(12), 801-808.

²⁰ Egea, JM. (1994). Redes neuronales: concepto, fundamentos y aplicaciones en el laboratorio clínico. *Quim Clin*, 13(5), 221-228.

²¹ Mayo, CS., Matuszak, MM., Schipper, MJ., Jolly, S., Hayman, JA. (2017). Ten Haken RK. Big Data in designing clinical trials: Opportunities and challenges. *Front Oncol*, 7, 187-231.

²² Traeger, MA., Geldner, G., Morin, AM., Putzke, C., Wulf, H., Eberhart, LH. (2003) Artificial neural networks. Theory and applications in anaesthesia, intensive care and emergency medicine. *Anaesthesist*, 52(11), 1055–1061.

²³ Gholipour, K., Asghari-Jafarabadi, M., Lezadi, S., Jannati, A., Keshavarz, S. (2018). Modelling the prevalence of diabetes mellitus risk factors based on artificial neural network and multiple regression. *East Mediterr Health J*, 24(8), 770-777.

²⁴ Feng M, McSparron JI, Kien DT, Stone DJ, Roberts DH, Schwartzstein RM, Vieillard-Baron A, Celi LA. (2018). Transthoracic echocardiography and mortality in sepsis: analysis of the MIMIC-III database. *Intensive Care Med*. 44(6), 884-892.

²⁵ Shen, Y., Ru, W., Huang, X., & Zhang, W. (2018). Time-related association between fluid balance and mortality in sepsis patients: interaction between fluid balance and haemodynamics. *Scientific reports*, 8(1), 10390.

²⁶ Waudby-Smith IER, Tran N, Dubin JA, Lee J (2018) Sentiment in nursing notes as an indicator of out-of-hospital mortality in intensive care patients. *PLoS ONE*, 13(6): e0198687.

²⁷ Sandfort, V., Johnson, A., Kunz, L. M., Vargas, J. D., & Rosing, D. R. (2019). Prolonged Elevated Heart Rate and 90-Day Survival in Acutely Ill Patients: Data From the MIMIC-III Database. *Journal of intensive care medicine*, 34(8), 622–629.

²⁸ Aboelsoud, M., Siddique, O., Morales, A., Seol, Y., & Al-Qadi, M. (2018). Early biliary drainage is associated with favourable outcomes in critically-ill patients with acute cholangitis. *Przeglad gastroenterologiczny*, 13(1), 16–21.

²⁹ Grupo de Topología Computacional y Matemática Aplicada (CATAM). Conceptos básicos en redes neuronales. Disponible en: <http://grupo.us.es/gtocoma/pid/pid10/RedesNeuronales.htm>

³⁰ Nijs, N., Toppets, A., Defloor, T., Bernaerts, K., Milisen, K., Van Den Berghe, G. (2009). Incidence and risk factors for pressure ulcers in the intensive care unit. *J Clin Nurs*, 18, 1258-1266.

³¹ Manzano, F., Navarro, MJ., Roldan, D., Moral, MA., Leyva, I., Guerrero, C., et al. (2010). Pressure ulcer incidence and risk factors in ventilated intensive care patients. *J Crit Care*, 25, 469-476.

³² Makai, P., Koopmanschap, M., Bal, R., Nieboer, A. (2010). Cost effectiveness of a pressure ulcer quality collaborative. *Cost Eff Resour Alloc*, 1(8), 11-24.

³³ Tomazini, A., Nascimento, T., Moura, T., Brunet, NM., Edla, M. (2015). Evaluación de las escalas de riesgo para úlcera por presión en pacientes críticos: una cohorte prospectiva. *Rev Latino-Am Enfermagem*, 23(1), 28-35.

³⁴ Valls-Matarínn, J., Cotillo, M., Pujol, M., Ribal, R., Sandalinas, I. (2016). Diferenciación entre lesiones cutáneas asociadas a la humedad y úlceras por presión mediante el uso de fotografías en un área de críticos. *Enfermería Clínica*, 6(5), 268-274

³⁵Núñez, A., Armengol, MA., Sánchez, M. (2019). Big Data Analysis y Machine Learning en medicina intensiva. *Med Intensiva*, 43(7), 416-426.