

**Modelo de Machine Learning para la Clasificación de pacientes en términos del nivel  
asistencial requerido en una urgencia pediátrica con Área de Cuidados Mínimos**

**Ing. Gisela Isabel García Gazabón  
Ingeniera de Sistemas**

**UNIVERSIDAD TECNOLÓGICA DE BOLÍVAR  
MAESTRÍA EN INGENIERÍA  
CARTAGENA**

**Modelo de Machine Learning para la Clasificación de pacientes en términos del nivel  
asistencial requerido en una urgencia pediátrica con Área de Cuidados Mínimos**

**Gisela Isabel García Gazabón  
Ing. De Sistemas**

**TESIS DE GRADO PARA OPTAR EL TÍTULO DE MAGISTER EN  
INGENIERIA  
con énfasis en SISTEMAS Y COMPUTACIÓN**

**Director: WILLIAM CAICEDO, Ing de Sistemas M.S.c**

**UNIVERSIDAD TECNOLOGICA DE BOLÍVAR  
MAESTRÍA EN INGENIERÍA  
CARTAGENA NOVIEMBRE 2014**

## AGRADECIMIENTOS

Este es un logro que me llena de mucha satisfacción, que me ha permitido ratificar que hay que proponerse las cosas y luchar por ellas para alcanzarlas, no es fácil, y nadie puede decir que lo sea, pero el sacrificio que haces te ayuda a entender que no hay cosas imposibles solo encontrarás algunas piedras en el camino necesarias para que crezcas y aprendas a valorar, gracias Dios por ponerme en este camino y por la fortaleza en aquellos momentos que uno cree desvanecer, contigo nada es imposible; gracias hijos míos, Fabián Andrés y Gabriela, por ese tiempo que me regalaron, ese mismo que podíamos aprovechar para ayudarlos a hacer sus tareas, para jugar, para salir a divertirnos, para charlar, gracias por ser mi motivación y los angelitos que Dios me dio aquí en la tierra para que iluminaran mi camino; gracias Fabián, mi amado esposo, porque muchas veces eres mis manos, otras mis pies, y otras más mis ojos, gracias por tu comprensión y tu apoyo en aquellos momentos en que las piedras en este camino me parecían muy grande; gracias madre por tu luz desde el cielo, sé que siempre estás a mi lado; gracias padre porque junto con mi madre siempre me apoyaron y complacieron en todo.

Gracias William, tu guía y exigencias fueron parte esencial de este logro, gracias por creer en este proyecto desde la primera vez que te lo comenté en una de tus clases, gracias por acompañarme en este camino donde muchas veces te tocó mostrarme el norte para llegar, muchas gracias.

No podría dejar de darle gracias a mis compañeros, a mi amiga Carol, Cristian, Luis, Camilo y Edgar, por su amistad por la colaboración que nos brindamos a cada momento, en cada tarea, en cada trabajo que realizamos, porque estuvimos en las buenas y en las malas; gracias también Luz Estella, fuiste la Mamá de nuestro grupo, siempre preocupándote por conseguirnos las cosas, siempre pendiente de cada uno de nosotros, tu apoyo fue fundamental.

Quiero ofrecerle un agradecimiento muy especial al Dr. Pinzón, por abrirme las puertas de la Clínica donde fue posible esta investigación, gracias por ser la gran persona que es, con ese don de colaboración. Gracias también a las doctoras Doris y Katherine por la pasión y dedicación brindada a este proyecto.

## Índice General

AGRADECIMIENTOS.....	3
Índice General.....	5
Índice de Gráficas.....	7
Índice de Tablas .....	8
1. INTRODUCCIÓN.....	9
1.1 Descripción del Problema.....	9
1.2 Justificación.....	12
1.3 Estado del arte.....	13
1.3.1 Otras Aplicaciones de las Técnicas de Machine Learning en la Medicina .....	13
1.4 Objetivos .....	22
1.4.1 Objetivo General .....	22
1.4.2 Objetivos Específicos .....	22
1.5 Organización del Documento .....	23
2. GENERALIDADES.....	24
2.1 Generalidades de Machine Learning.....	24

2.2	Algunas Técnicas de Machine Learning .....	27
2.3	Algunos Conceptos Preliminares de Urgencias Médicas .....	37
3.	RECOLECCIÓN Y ANÁLISIS DEL CONJUNTO DE DATOS.....	42
3.1	Identificación de Variables.....	42
3.2	Recolección de Datos.....	51
3.3	Análisis de Datos .....	54
4.	ENTRENAMIENTO VALIDACIÓN Y PRUEBAS .....	61
4.1	Análisis de Componentes Principales .....	62
4.2	Evaluación de Técnicas.....	69
4.2.1	Máquina de Soporte Vectorial .....	70
4.2.2	Redes Neuronales (Perceptron Multicapa) .....	71
4.2.3	Regresión Logística.....	71
4.3	Pruebas .....	79
5.	CONCLUSIONES Y TRABAJOS FUTUROS .....	81
	REFERENCIAS .....	86
	ANPÉNDICE.....	94

## Índice de Gráficas

GRÁFICO 1 RED NEURONAL ARTIFICIAL.....	33
GRÁFICO 2 ESTRUCTURA DE UNA RED NEURONAL PERCEPTRON MULTICAPA.....	36
GRÁFICO 3 GRÁFICO DE SEDIMENTACIÓN COMPONENTES VS EIGENVALOR .....	67
GRÁFICO 4 GRAFICO DE SEDIMENTACIÓN COMPONENTES VS PORCENTAJE DE VARIANZA .....	68
GRÁFICO 5 ANÁLISIS ROC.....	78

## Índice de Tablas

TABLA 1. ESCALA DE PRIORIDADES TRIAGE .....	10
TABLA 2 CLASIFICACIÓN DE ENFERMEDADES REPORTADAS EN LA URGENCIA EN EL 2013 .....	42
TABLA 3 DESCRIPCIÓN DE VARIABLE.....	45
TABLA 4 VARIABLES ELIMINADAS.....	55
TABLA 5 NÚMERO DE VECES DE APLICACIÓN DE CADA ESCALA .....	57
TABLA 6 ANÁLISIS DE COMPONENTES PRINCIPALES. ....	62
TABLA 7 MATRIZ DE CONFUSIÓN .....	73
TABLA 8 MÉTRICAS PARA REDES NEURONALES .....	77
TABLA 9 MÉTRICAS PARA MAQUINAS DE SOPORTE VECTORIAL .....	78
TABLA 10 MÉTRICAS PARA REGRESIÓN LOGÍSTICA .....	78
TABLA 11 MÉTRICAS PARA LAS REDES NEURONALES CON LOS DATOS DE PRUEBA.....	80



## 1. INTRODUCCIÓN

### 1.1 Descripción del Problema

Como lo menciona la superintendencia de Salud Nacional, en su revista “Monitor Estratégico Superintendencia Nacional de Salud” y en su “Informe Anual de Gestión”, en la ciudad de Cartagena, así como en otras ciudades como Barranquilla, Medellín, Bogotá, se presenta en general un problema grave de atención en los departamentos de urgencias de las diferentes clínicas de la ciudad y se percibe por la demora en la atención y la insatisfacción de los usuarios del servicio de salud; probablemente el colapso de esta área es causado por muchos factores influyentes como la falta de infraestructura física y de recurso humano, la mala asignación de recursos, la falta de personal debidamente capacitado, desmotivación laboral y más que todo por pacientes que utilizan el servicio de urgencias de una clínica en busca de una atención eficiente en comparación con la atención brindada en las consultas externas. Esto lleva a una experiencia negativa del usuario.

Cuando un paciente llega al servicio de urgencias, el primer procedimiento que se realiza es la clasificación del padecimiento que refiere para determinar la complejidad con que llega, a esto se le conoce como Triage. El paciente que llega es clasificado por una enfermera y/o médico de acuerdo con los niveles de prioridad que maneja la clínica, y con ello se determina el tiempo de espera para la atención por parte de un médico; sin embargo debido al gran volumen de ingreso de pacientes que llegan por su voluntad o por remisión de los Centros de Atención Primaria CAP, la capacidad instalada de las clínicas y

el recurso médico asignado colapsa. Dentro del grupo de pacientes en espera, encontraremos pacientes en los que la complejidad de su cuadro puede aumentar, esto puede ocurrir por una mala aplicación del Triage, por una evolución rápida de la enfermedad que padece el paciente en el momento o por malas prácticas en los procedimientos de la clínica, como resultado, cualquiera que sea la causa se compromete la salud de un ser humano. Otro grupo de pacientes que se presenta son los de baja complejidad, para los que su estadía después de una revisión médica no duraría más de dos o tres horas. Actualmente si el paciente llega con una alta o baja complejidad es clasificado y atendido bajo el procedimiento tradicional de los departamentos de urgencias donde inicialmente se hace una evaluación rápida del paciente por medio de un interrogatorio donde se conoce su nombre, edad, motivo de consulta, enfermedad actual y antecedentes relevantes. Posteriormente se realiza un examen físico limitado al órgano que lo aqueja según lo referido por el paciente o familiar. Dentro de este examen físico se tienen en cuenta los signos vitales, la apariencia general, el estado mental y la valoración del dolor.

En Colombia el Ministerio de Protección Social estableció una escala de prioridades que determinan el Triage en todas las clínicas que manejen Salas de Urgencias (Ministerio de Protección Social Colombia, 2009), la Tabla 1 muestra la clasificación determinada.

**Tabla 1. Escala de Prioridades Triage**

<b>Escala</b>	<b>Tiempo de Respuesta</b>
Prioridad I Reanimación	Atención médica y de enfermería: inmediato, simultáneo a valoración.
Prioridad II Emergencia	Atención de enfermería: inmediato. Atención médica: 15 minutos.

<b>Escala</b>	<b>Tiempo de Respuesta</b>
Prioridad III Urgencia	Atención médica y de enfermería: menor de 30 minutos.
Prioridad IV Urgencia menor	Atención médica y de enfermería: menor de 60 minutos
Prioridad V No urgente	Tiempo de atención: 120 minutos

Las directivas médicas del Hospital Napoleón Franco Pareja-Casa del Niño han detectado, en particular, que el primer nivel de atención en la ciudad de Cartagena - ESE Cartagena de Indias, quien dirige todos los centros de atención primaria CAP, tiene poca capacidad resolutive por diferentes razones, entre otras recurso humano no especializado, escasez de equipos de biotecnología y una infraestructura hospitalaria deficiente. Por estas razones los pacientes son transferidos al hospital en busca de una mejor atención, también se presentan casos de pacientes que no se dirigen a los CAP y prefieren llegar a la clínica por sus propios medios. Lo anterior influye en el colapso del servicio de urgencia que actualmente se presenta en la clínica.

El Hospital Infantil Napoleón Franco Pareja – Casa del Niño, como parte de una solución que disminuya el tiempo de atención a pacientes en el servicio de urgencias, está reestructurando sus procedimientos a fin de establecer dos áreas de asistencia médica, estas son: Área de Cuidados Mínimos o Fast Track y el Área de Alta Complejidad. Con esto se pretende evacuar en el menor tiempo posible los casos de baja complejidad y que solo pasen al área de Alta Complejidad aquellos que se clasifiquen con una prioridad alta.

Sin embargo, la alta rotación del personal médico (Residentes e Internos cuyo tiempo de estadía es aproximadamente 2 meses), trae como consecuencia inicios constantes del programa de entrenamiento y pérdida del aprendizaje ya adquirido. Lo anterior conlleva a que por desconocimiento de los procedimientos establecidos se realice en ocasiones, una clasificación (Triage) inadecuada de los pacientes.

Tomando como base la reestructuración de los procedimientos en el Hospital Napoleón Franco Pareja – Casa de Niño, surgió la pregunta: ¿Qué aporte pueden hacer las herramientas basadas en técnicas de Machine Learning para clasificar (Triage) los pacientes de una urgencia pediátrica en términos de la atención requerida, ya sea en el área de cuidados mínimos o en el área de alta complejidad, como una herramienta de apoyo al profesional del área para tomar una decisión?

## **1.2 Justificación**

Estudios realizados en países como Estados Unidos, Nueva Zelanda, Australia, España, han demostrado que la implementación de Fast Track en las salas de urgencias, ha mejorado el flujo de los pacientes disminuyendo el tiempo de estadía de estos como se describe en varios estudios (Considine, 2008), (FitzGerald, 2009), (Laskowski, 2009), (Yoon, 2003), (Holden, 2011), pero es de destacar que estas implementaciones no tienen en cuenta el entrenamiento del personal médico, el cual se pierde cuando la rotación del personal alta.

Al incluir técnicas de Machine Learning en la reorganización del triage con el área de cuidados mínimos, estamos contribuyendo con la determinación de modelos que pueden llevar a encontrar esos patrones escondidos sobre los datos partiendo de la experiencia de los médicos y las escalas recomendadas por la literatura.

### 1.3 Estado del arte

#### **Aplicaciones de las Técnicas de Machine Learning en la Medicina**

Son muchas las aplicaciones que encontramos de técnicas de Machine learning en la medicina, varias investigaciones demuestran la importancia que han tomado estas técnicas para el diagnóstico tratamiento y pronóstico médico, sobre todo cuando se tienen grandes volúmenes de datos. Por los resultados que se han obtenido en estas investigaciones, la comunidad médica a aumentado su confianza en este tipo de herramientas, y en la literatura se encuentran estudios para detección de diferentes tipos de cáncer, en la especialidad de alergología, en enfermedades de vías respiratorias como la Neumonía, Asma, Bronquiolitis, para enfermedades cardiovasculares, para el descubrimiento de nuevas drogas, para clasificación del dolor, para evaluar tiempos de esperas y asignación de recursos médicos, entre otros, son tantas las aplicaciones en donde ha tomado fuerza las técnicas de machine Learning que hay comunidades dedicadas a alimentar repositorios para contribuir al aprendizaje y evaluación de dichas técnicas como por ejemplo existe un repositorio en línea con bases de datos para utilizar en el aprendizaje automático, mantenido por la Universidad de California en Irvine, que incluye resultados de biopsias de lesiones mamarias, predictores de cardiopatía, registros de supervivencia posquirúrgica y otras 270 bases de datos de diversas disciplinas para aprender.

(Brown, Chatterjee, Jounger, Makey, 2011) muestran un estudio de la Universidad de Stanford en el que utilizaron la resonancia magnética funcional para detectar cuando la gente experimenta dolor, mediante la detección de cambios en los patrones del flujo sanguíneo en el cerebro. Los investigadores tomaron ocho sujetos, y los colocaron en la máquina de escaneo cerebral. Luego se les aplicó una sonda de calor en los antebrazos, causando un dolor moderado y se registraron los patrones cerebrales con y sin dolor, los cuales fueron interpretados por algoritmos avanzados de informática para crear un modelo de cómo se ve el dolor. El proceso se repitió con un segundo grupo de ocho sujetos. La idea era formar una máquina de soporte vectorial lineal en un conjunto de individuos, y luego usar ese modelo de computadora para clasificar con precisión el dolor en un conjunto completamente nuevo de individuos. La máquina de soporte vectorial fue entrenada para clasificar los estímulos de calor en “Dolor” o “No Dolor”. Dentro del proceso de entrenamiento se obtuvo una precisión media del 86.6%, (a través de los ocho individuos de prueba varió del 71.4% a 100%), los estímulos clasificados como dolorosos que eran en realidad dolorosos fue del 90.3% y los clasificados como no dolorosos que eran en realidad no dolorosos fue del 85,4%.

(Prieto, 2012) presentó un nuevo procedimiento informático que ayuda al diagnóstico precoz de la enfermedad de Alzheimer. Para el estudio se utiliza una gran cantidad de imágenes (1.350) procedentes de la base de datos desarrollada en Estados Unidos dentro del proyecto ADNI, que han sido seleccionadas y estandarizadas por las Clínicas Mayo, de Rochester y de Minnesota. El procedimiento consiste en la clasificación automática de imágenes de resonancia magnética nuclear de pacientes sanos, pacientes con deterioro

cognitivo leve y pacientes que sufren la enfermedad de Alzheimer, la demencia más extendida por todo el mundo. Para el desarrollo del sistema se han utilizado diversas técnicas de procesamiento de la información como son la Transformada Discreta Wavelet (DWT), para la extracción de características de las imágenes, Análisis de Componentes Principales (PCA) para la reducción de características, y diferentes metodologías para la selección de características, como son las de Mínima-Redundancia Máxima-relevancia (mRMR) y de Información Mutua Normalizada. La clasificación de las imágenes representadas por las características seleccionadas se ha realizado utilizando Máquinas de Soporte Vectorial (SVM). Los resultados obtenidos en la clasificación de imágenes ofrecen una sensibilidad y especificidad del 98,7 por ciento para la clasificación entre personas sanas y con enfermedad de Alzheimer, y del 80 y 96 por ciento, respectivamente, cuando se incluye en la clasificación a sujetos con deterioro cognitivo leve. Hay que tener en cuenta que la comunidad científica considera como buenos los resultados superiores al 80 por ciento.

(Rojas, Herrera, Acuña, Muñoz, Ibargüen, 2007) muestra el diseño y la implementación de un prototipo de transmisión vía radio frecuencia para el análisis y supervisión de la señal cardíaca. El prototipo consta de un electrocardiógrafo portátil con transmisión inalámbrica y una herramienta computacional para la visualización y análisis de la señal obtenida de las derivaciones DI, DII y DIII, utilizando el método wavelets para eliminar componentes ajenas a la señal electrocardiográfica y métodos basados en derivadas para extraer las características propias de cada onda cardíaca que son introducidas a una SVM (Máquinas de Soporte Vectorial) para su posterior reconocimiento. Como fase de investigación se

entrenó una máquina de soporte vectorial para el reconocimiento de tres arritmias diferentes: Bloqueo de rama derecha (RBBB), bloqueo de rama izquierda (LBBB) y Wolff-Síndrome Parkinson-Blanco (WPW), además de una señal de ritmo sinusal normal (NOR). La SVM fue entrenada utilizando funciones núcleo de tipo RBF (funciones de base radial) y polinómicas. Los resultados obtenidos con las SVM son satisfactorios pues obtuvieron errores de entrenamiento y validación menores al 10 %.

(Contreras, Silveras, 2001) mostraron una investigación para evaluar tres detectores de apneas – bradicardias (detector de umbral fijo, detector umbral relativo y detector de cambios abruptos) en neonatos junto con la implementación de una red neuronal para fusionarlos. Para el estudio utilizaron una base de datos constituida por 29 electrocardiogramas de pacientes neonatos. Para el diseño de la red se implementó una red tipo backpropagation, una neurona de entrada, 20 en la capa oculta y una neurona en la capa de salida. La clasificación de los resultados para el grupo de control se estableció en base a la exactitud, sensibilidad y especificidad, para lo que se obtuvo una exactitud del 94.34%, una sensibilidad del 87.32% y una especificidad del 92.88%.

(Villamil, Ayala, 2004) realizaron en la Universidad de El Bosque, fundación Cardioinfantil, un modelo para diagnóstico de pielonefritis aguda en niños, basadas en redes neuronales como técnica no invasiva que después compararían con la gamagrafía DMSA. Para el estudio usaron datos clínicos y paraclínicos de la base de datos de historias clínicas conformadas por 487 pacientes hospitalizados con sospecha diagnóstica



de infección de vías urinarias, Utilizaron un perceptrón multicapa con tres capas ocultas que tuvo un error promedio final normalizado de 0.001969 después de 7964 ciclos de aprendizaje, con una eficiencia de 99.6%, una sensibilidad de 99.63% y una especificidad del 99.53%. El modelo presentado de RNA arroja resultados convincentes, acercándose finalmente a la prueba oro con la gammagrafía, lo cual sugiere que no es necesario el uso de parámetros adicionales en el diagnóstico de la pielonefritis aguda.

(Mendez, Gil, 2008) presentaron una tesis doctoral para modelar y simular el comportamiento neurológico del tracto urinario inferior como un sistema de ayuda al diagnóstico. Esta investigación trata con el estudio de los sistemas neuroreguladores, en especial con el regulador neuronal del tracto urinario inferior. La solución en esta investigación la abordan con agentes inteligentes, cuya arquitectura la basan técnicas de minería de datos para lo que realizaron una revisión de los métodos más idóneos usados en las áreas de medicina y biología, dentro de los métodos utilizados estaban: Perceptron multicapa el cual reportó una precisión de 89,30%, sistemas neurodifusos (ANFIS) 88;00%, árbol de decisión con un 87;93% y el análisis de componentes con un 82%, la medida más aceptable se alcanzó con las redes neuronales.

(Del Campo, Arribas, Hornero, Álvarez, Marcos, 2008) muestran un estudio con 84 pacientes cuyos objetivos era: analizar la utilidad de la saturación de oxígeno y el tiempo de tránsito de pulso junto con la aplicación de una red neuronal perceptrón multicapa como ayuda diagnóstica en el síndrome de apnea hipopnea del sueño. La aplicación de una red

neuronal proporcionó una sensibilidad del 96,4%, un especificidad del 76,9%, y un área bajo la curva de 0,86 (0,76-0,92, IC95%). Con la utilización de esta red neuronal hubo 6 falsos positivos y tan sólo dos falsos negativos. Estos resultados fueron superiores al análisis por separado de cada una de las señales y a los índices oximétricos clásicos de la saturación de oxígeno.

(Serrano, 2003) muestra en la facultad de Medicina y Odontología de la Universidad de Valencia una investigación que tenía dentro de sus objetivos: 1. Desarrollar y validar un modelo matemático neuronal capaz de identificar, con la mayor sensibilidad y especificidad, la evolución a corto, medio y largo plazo del Trasplante Renal Pediátrico mediante el empleo únicamente de factores pre-trasplante. 2) Contrastar la capacidad clasificatoria que presentan las redes neuronales artificiales y en concreto el perceptron multicapa, frente a la regresión logística en el problema planteado.

Teniendo en cuenta todas estas aplicaciones y el éxito que han tenido algunas en especial, esta investigación se centrará en la evaluación específica de las Redes Neuronales, Máquinas de soporte vectorial y la Regresión Logística.

La Inteligencia Artificial ha tenido mucha aplicación en el campo de la medicina, más exactamente en actividades de diagnóstico y tratamiento se han hecho aportes importantes, en estos se observa el aporte de las técnicas de Machine Learning como Redes bayesianas, redes neuronales, Maquinas de soporte Vectorial, Arboles de decisión, y otras más, que son utilizadas como herramientas de apoyo para la toma de decisiones. Para casos donde estas herramientas han sido utilizadas y han cumplido los objetivos propuestos, la literatura provee muchos ejemplos. (J. J. Aguilera, M.J. Del Jesus, P. González, F. Herrero, M. Navío, J. Sáinz.) muestran en la investigación realizada en el centro de Urgencias Psiquiátricas del Hospital Ramón y Cajal de Madrid España el uso de algoritmo de minería de datos con dos componentes: Un algoritmo genético de extracción de reglas difusas de asociación y un algoritmo de ascensión de colinas que optimiza la regla obtenida para descubrir información sobre ritmos de horarios en la llegada al servicio de urgencias. (Abad-Grau, Ierache, Cervino,2008) realizaron una investigación en la Universidad de Granada con información del Hospital Posadas, Hospital de Haedo, Hospital Italiano, Hospital Alemán, entre otros más. Se enfocaron en Urgencias Médicas directamente enfermedades cardiovasculares y respiratorias donde aplicaron redes bayesianas, algoritmos de aprendizaje automático, árbol de decisión, el vecino más cercano y algoritmo genéticos en el modelado de sistemas expertos de Triage (clasificación) en los servicios de urgencias médicas. Las redes se construyeron teniendo en cuenta tanto los datos provenientes de experiencias de Triage como la opinión de médicos expertos en urgencias. El sistema tiene una doble finalidad: a nivel teórico para entender cómo la información requerida en el Triage puede ser modelada mediante redes bayesianas y a nivel práctico para entrenamiento y uso por el personal de Triage; en esta

investigación los mejores resultados se obtuvieron con los algoritmos de redes bayesianas.

(Wub, Zheng, Chen, 2011) reportan la utilización de técnicas de inducción de reglas y técnicas de análisis de grupos en el servicio de Urgencias del hospital de Taiwan, donde analizaron la asignación del personal médico, la clasificación que le han realizado a los pacientes así como los costos generados en la sala de urgencia, a fin de identificar si estaban aplicando bien los recursos asignados.

(Michalowski, Wilk, Farion, Pike, Rubin, Showishki) reportan el diseño de un algoritmo basado en sistemas de soporte de decisión en el Children's Hospital of Eastern Ontario (CHEO) de Canadá, diseñaron un algoritmo para determinar el Triage en la sala de urgencias, en aquellos niños con dolor o hinchazón escrotal, para ello realizaron una revisión retrospectiva de pacientes donde tuvieron en cuenta 13 atributos clínicos asociados con el dolor escrotal. Para llegar al diseño, construyeron varios modelos donde, para cada uno, variaron el número de atributos a tener en cuenta y luego los compararon utilizando Cross-Validation. (Dexheimera, Brown, Leegon, Aronsky, 2007) muestran una investigación realizada por el Departamento de Bioinformática de Vanderbilt, en Nashville (USA) donde aplicaron y compararon varias técnicas de Machine Learning (Maquinas de soporte vectorial, redes neuronales, procesos Gaussianos y una red bayesiana con aprendizaje automático) con Redes Bayesianas-construidas manualmente con conocimiento de un experto, para detectar pacientes con asma en un Departamento de Urgencias. Este estudio fue realizado en la sala de urgencias del Hospital pediátrico Vanderblit donde se tomaron las muestras durante un período de dos meses. Para evaluar el desempeño de cada técnica

se usó la curva ROC, además se midió la sensibilidad, especificidad, valores predichos positivos y valores predichos negativos. Al final se determinó que las cuatro técnicas alcanzaron una alta precisión y resaltan que las redes bayesianas con aprendizaje automático tuvo un desempeño similar a la red bayesiana construida con el conocimiento de un experto.

## 1.4 Objetivos

### 1.4.1 Objetivo General

Desarrollar un modelo de Machine Learning para la clasificación de pacientes en términos del nivel asistencial requerido en una urgencia pediátrica con Área de Cuidados Mínimos.

### 1.4.2 Objetivos Específicos

- Identificar los síntomas y los signos que pueden ser usados como predictores de gravedad para clasificar una urgencia pediátrica de acuerdo con el nivel asistencial requerido.
- Establecer cuáles son las técnicas de Machine Learning que se pueden usar para realizar la clasificación de pacientes en una Urgencia pediátrica teniendo en cuenta el nivel asistencial (alta complejidad y cuidados mínimos o Fast Track).
- Construir un conjunto de datos para entrenamiento, validación y prueba que pueda ser utilizado para determinar la técnica de Machine Learning a utilizar en el clasificador.
- Construir, entrenar y validar los clasificadores basados en los modelos identificados en la revisión literaria, y escoger el que ofrezca los mejores resultados.

- Probar el clasificador escogido con nuevos datos que permitan verificar la exactitud del mismo.

## 1.5 Organización del Documento

En el Capítulo de Generalidades encontraremos conceptos relacionados con Machine Learning y algunas de sus técnicas, así como conceptos utilizados en los servicios de Urgencias Clínicas. En el capítulo siguiente se explica la metodología aplicada para la recolección de los datos a utilizar en el proceso de entrenamiento, validación y prueba, así como el análisis de dichos datos. Luego se tiene el capítulo de entrenamiento Validación y prueba, el cual muestra el proceso realizado para bajar la dimensionalidad del conjunto de datos, el proceso de entrenamiento y validación junto con los resultados de las métricas obtenidos y el proceso de pruebas realizado. Al final encontraremos las conclusiones, los trabajos futuros y las referencias que se utilizaron para el desarrollo de este trabajo. Es importante resaltar que las gráficas aquí utilizadas, excepto las proporcionadas por de Statgraphic, no son propiedad de los participantes en esta investigación, muchos de estos gráficos fueron extraídos de las referencias relacionadas y otros directamente encontrados como imágenes en la web.

## 2. GENERALIDADES

### 2.1 Generalidades de Machine Learning

Machine learning es un conjunto de técnicas que hacen parte de la inteligencia artificial, que basadas en algoritmos buscan el aprendizaje dentro de grandes conjuntos de datos. Una característica muy importante de estos algoritmos es la predicción de nuevos casos basándose en la experiencia aprendida del conjunto de datos utilizados para su entrenamiento, a esto se le conoce en la literatura como generalización (Fernández, 2003), (Beltrán, 2008).

Dentro de la literatura (García, García, 20017), (Freitas, 2012), (García, Quintales, García Peñalvo, Martín) encontramos que el aprendizaje en Machine Learning se divide usualmente en dos tipos, el aprendizaje “supervisado” donde cada uno de las observaciones o muestras del conjunto de datos tiene relacionado una variable o un dato que indica lo que sucedió, lo que pasó, es decir las entradas están etiquetadas. Este tipo de aprendizaje se subdivide en clasificación y regresión. En clasificación las salidas del sistema son finitas y discretas y son interpretadas como la clase a la que pertenece, ejemplo “0” o “1”, “Falso” o “Verdadero”, “Si” o “No”, mientras que en la regresión, las salidas son continuas. En esta investigación nos enfocamos en el tipo de aprendizaje supervisado.



El otro tipo de aprendizaje es el “No supervisado”, en este tipo de aprendizaje, en el conjunto de datos se disponen de datos para el entrenamiento pero no se conoce o no se dispone de la salida o se conoce muy poco sobre esta, es decir no hay una variable objetivo y lo que se requiere es buscar patrones. Para determinar lo que se quiere predecir se pueden encontrar estructuras sobre los datos, dentro de estas estructuras se pueden mencionar el clustering (proceso de particionar un conjunto de datos en un conjunto de subclases significativas llamadas grupos) y la asociación (conjunto de características significativas).

Frecuentemente los expertos en machine learning recomiendan en la construcción de los modelos, separar el conjunto de datos en subconjunto para entrenamiento, validación y prueba. Con los conjuntos de datos separados para entrenamiento y prueba se escoge el modelo con menor error de validación y el conjunto de datos de pruebas se utiliza para probar el mejor modelo encontrado. Dentro de las técnicas encontradas para entrenamiento y validación, se propone en la literatura la utilización de Cross Validation (Refaelizadeh, Tang, Liu, 2008), técnica utilizada para evaluar los resultados obtenidos en el análisis realizado. La validación cruzada se divide en tres tipos; el primero, validación cruzada k Fold, consiste en dividir el conjunto de entrenamiento en k partes. Una de las partes se utiliza como dato de prueba y las k-1 restantes como datos de entrenamiento, este proceso es repetido k iteraciones y al final se realiza la media aritmética de los resultados de cada iteración y se obtienen un solo resultado. El segundo tipo de validación encontrado es el aleatorio y consiste en dividir aleatoriamente el conjunto de datos de prueba. El tercer tipo de validación cruzada es Leave one out, consiste en separar una

muestra del conjunto de datos para la validación y el resto se utiliza para el entrenamiento, este proceso se repite según el número de muestras que se tenga.

Según los expertos dentro del proceso de escogencia del modelo ideal se deben tener en cuenta la complejidad y la medida de error de los mismos, contemplando el sesgo y la varianza. Los errores que se determinan para evaluar el aprendizaje, son el “error de entrenamiento” y “error de validación” y se calculan sobre el conjunto destinado para tal fin. En la literatura (Liu, Huan, 2005),(Morelli, 2013), Fernández, et al.(2003), Beltran et al. (2008) se demuestra que cuando tenemos un error de entrenamiento bajo y un error de validación alto hubo un error por varianza, es decir se tiene un overfitting, y se entiende que el algoritmo sobre-ajustó los datos de entrenamiento y aprendió del ruido contenido en la muestra y por ello probablemente falle la generalización del modelo. Cuando se tienen un error de entrenamiento alto y un error de validación bajo se tiene un problema por sesgo, es decir underfitting. Lo indicado es buscar un nivel óptimo donde se decida la complejidad del modelo de acuerdo con los datos disponibles y no de acuerdo con la complejidad de la función que el investigador supone. Para la búsqueda de un nivel óptimo la literatura ofrece las estrategias de regularización, que es una forma de penalizar la función objetivo para evitar que esta se desvíe para aquellos datos atípicos y aberrantes. La regularización tiene como objetivo realizar un intercambio apropiado entre la fiabilidad de los datos de entrenamiento y las bondades del modelo. En procedimientos de aprendizaje supervisado, el intercambio se realiza a través de la minimización del riesgo total (Haikyn, 1999).

Otro tema importante que se debe tener claro por su importancia de aplicación en las técnicas de Machine Learning es el “Análisis de Componentes Principales”, es una técnica

estadística multivariable, desarrollado por el francés Benzecri(1980) que permite reducir la dimensionalidad de un conjunto de datos, transformando el conjunto de “p” variables originales en otro conjunto de “q” variables incorrelacionadas ( $q \leq p$ ) llamadas componentes principales. Las p variables son medidas sobre cada uno de los n individuos, obteniéndose una matriz de datos de orden nq (Vieyra, 2013)(Sellero, 2008). El método consiste en buscar combinaciones lineales de las variables originales que representen lo mejor posible a la variabilidad presente en los datos. De este modo, con unas pocas combinaciones lineales, que serán las componentes principales, sería suficiente para entender la información contenida en los datos (Otero, 2008)

## 2.2 Algunas Técnicas de Machine Learning

- **Regresión Logística**

La regresión logística es un tipo especial de regresión que se utiliza para explicar y predecir una variable categórica binaria, en función de varias variables independientes que a su vez puede ser cuantitativas o cualitativas.

Por sus características, los modelos de regresión logística permiten dos finalidades:

- a. Cuantificar la importancia de la relación existente entre cada una de las covariables o variables independientes y la variable dependiente, lo que lleva implícito también clarificar la existencia de interacción y confusión entre covariables respecto a la variable dependiente (es decir, conocer la “odds ratio” para cada covariable).

- b. Clasificar individuos dentro de las categorías (presente/ausente) de la variable dependiente, según la probabilidad que tenga de pertenecer a una de ellas dada la presencia de determinadas covariables.

No cabe duda que la regresión logística es una de las herramientas estadísticas con mejor capacidad para el análisis de datos en investigación clínica y epidemiología, de ahí su amplia utilización.

El objetivo primordial que resuelve esta técnica es el de modelar cómo influye en la probabilidad de aparición de un suceso, habitualmente dicotómico, la presencia o no de diversos factores y el valor o nivel de los mismos. También puede ser usada para estimar la probabilidad de aparición de cada una de las posibilidades de un suceso con más de dos categorías (politómico).

- Árboles de Decisión

Un árbol de decisión es una estructura en la cual cada nodo interno denota una prueba sobre uno o varios atributos, cada rama representa una salida de la prueba y los nodos hoja representan clases. La característica principal de los árboles de decisión es que son modelos de caja blanca en los cuales se puede ver directamente la frecuencia de aparición de cada atributo. Además, le permite al experto conocer el atributo con mayor poder de clasificación, es decir, aquel que se localice en el nodo raíz (Mazo, Bedoya, 2010).

- **Máquinas de Soporte Vectorial**

Las Máquinas de Soporte Vectorial (del inglés Support Vector Machine) fueron desarrolladas en 1995 por Vladimir Vapnik cuando propone un modelo matemático para la resolución de problemas de clasificación y regresión el cual llamaron Modelo MSV. Están basadas en la teoría de aprendizaje estadístico que permiten resolver problemas de clasificación y regresión de manera eficiente (Cuba, 2010), (Dexheimera et al. (2007), (Rengifo, Juménez, 2010) El éxito de las máquinas de soporte vectorial radica en tres ventajas fundamentales:

- a. Poseen una sólida fundamentación matemática.
- b. Se basan en el concepto de minimización del riesgo estructural, esto es, minimizar la probabilidad de una clasificación errónea sobre nuevos ejemplos, particularmente importante cuando se dispone de pocos datos de entrenamiento.
- c. Se disponen de potentes herramientas y algoritmos para hallar la solución de manera rápida y eficiente.

Las máquinas de soporte vectorial a diferencia de las redes neuronales, abstraen el problema desde un espacio de atributos a un espacio de patrones de características con mayor dimensión, a fin de que puedan ser separadas por un hiperplano. Así, mediante una función no lineal de mapeo apropiada, que aumente la dimensión de forma adecuada, es posible separar muestras que pertenezcan a dos categorías diferentes mediante un hiperplano (Maldonado, Weber, 2012).

- **Clasificación Linealmente Separables:**

Dentro de los conjuntos de datos que abarcamos con las máquinas de soporte vectorial, encontramos aquellos que son linealmente separables, y en ellos, minimizar la función de costos resulta muy sencillo. La hipótesis de partida es que las clases son linealmente separables y por ello existen infinitos hiperplanos que separan las muestras de una clase, de la otra. Los puntos del espacio que caen dentro de cada uno de estos hiperplanos son los que satisfacen la siguiente expresión (Reginfo, 2010).

$$h(x) = \omega^T x + b = 0$$

Donde  $\omega$  Y  $x \in \mathbb{R}^d$ , siendo  $d$  la dimensión del espacio de entrada.

La resolución para dicho caso sería suponer que se tiene un conjunto de  $n$  datos separables linealmente  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  donde  $x_i \in \mathbb{R}^d$  e  $y_i \in \{-1, 1\}$ . Se cumplirá, según el lado en el que se encuentren respecto del hiperplano lo siguiente:

$$\begin{aligned} \omega^T x_i + b &> 0, \text{ para } y_i = 1, i = 1, \dots, n \\ \omega^T x_i + b &< 0, \text{ para } y_i = -1, i = 1, \dots, n \end{aligned}$$

Hay casos de datos linealmente separables en los que puede existir ruido debido a errores en la medida de los datos o por la presencia de algún dato atípico o extremo. En dichos casos no es conveniente que la máquina de soporte vectorial se ajuste totalmente a los

datos. Este punto no debería ser considerado para hallar la frontera de decisión ya que podría alterar los resultados deseados nos llevaría a clasificaciones incorrectas.

- **Clasificación Linealmente no Separable**

Cuando los datos no son linealmente separables, existe la posibilidad de transformar los datos a un espacio de mayor dimensión  $\mathcal{H}$  utilizando una función  $\mathbf{x} \rightarrow \phi(\mathbf{x}) \in \mathcal{H}$ , donde se encontrará un hiperplano que los pueda separar. La frontera de decisión resultante en el espacio de entrada ya no será lineal y vendrá dada por otro tipo de función que pueda ser polinómica de grado superior a 1, gaussiana, sigmoide, entre otras, dichas funciones se conocen como funciones núcleo o “Kernel”. Las muestras una vez proyectadas, pueden usarse como un nuevo conjunto de entrenamiento, de esta forma se buscará una frontera lineal en el espacio  $\mathcal{H}$ , dicha frontera otra en el espacio de partida  $\mathbb{R}^d$  cuya forma dependerá de la función de proyección  $\Phi$  empleada y de las muestras del conjunto de entrenamiento. Como se nota ya los datos en la formulación de la máquina de soporte vectorial sólo aparecen como producto entre las muestras  $\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$ , en este caso solo se necesita la función Kernel, tal que

$$K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$$

Teniendo esta función se puede aplicar el algoritmo de entrenamiento de la Máquina de soporte vectorial sin conocer explícitamente cual es la transformación  $\Phi$  o incluso el espacio  $\mathcal{H}$ . La única condición necesaria es que el kernel usado esté correctamente definido.

Las funciones más utilizadas son:

La Función Polinómica tiene la siguiente forma:

$$P(x) = \sum_{i=0}^n a_i x^i = a_0 + a_1 x^1 + a_2 x^2 + \dots + a_n x^n$$

La Función Gaussiana, tiene la siguiente forma:

$$f(x) = a \cdot \exp\left(\frac{-(x - b)^2}{2c^2}\right)$$

La Función Sigmoide tiene la siguiente forma:

$$K(x, x') = \tanh(s(x^T \cdot x') + r) \quad s, r \in \mathfrak{R}$$

La selección del mejor kernel para una aplicación es todavía un tema de investigación. El procedimiento más común es el de seleccionar los parámetros de kernel (el grado del polinomio  $d$  para las funciones polinomiales o el ancho del kernel para la función Gaussiana) calibrando estos parámetros en conjunto con el proceso de selección del modelo (parámetro  $C$  que controla la generalización del modelo) mediante una búsqueda de grilla

- **Generalidades de las Redes Neuronales**

La neurona es la unidad fundamental del sistema nervioso y en particular del cerebro. Cada neurona es una simple unidad procesadora que recibe y combina señales



desde y hacia otras neuronas. Si la combinación de entradas es suficientemente fuerte, la salida de la neurona se activa.

El cerebro consiste en uno o varios billones de neuronas densamente interconectadas. El axón (salida) de la neurona se ramifica y está conectada a las dendritas (entradas) de otras neuronas a través de uniones llamadas sinapsis. La eficacia de la sinapsis es modificable durante el proceso de aprendizaje de la red (Asensio, Martínez, 2009).

Desde la primera mitad del siglo XX se han empezado a desarrollar modelos computacionales que han intentado emular el comportamiento del cerebro humano. Aunque se han propuesto una gran cantidad de ellos, todos usan una estructura en red en la cual los nodos o neuronas son procesos numéricos que involucran estados de otros nodos según sus uniones. Una clase de estos modelos computacionales son las redes neuronales artificiales, las cuales se han hecho muy populares debido a la facilidad en su uso e implementación y la habilidad para aproximar cualquier función matemática. (Posee). El gráfico 1 muestra el modelo de una Red Neuronal Artificial




Gráfico 1 Red Neuronal Artificial

De la observación detallada del proceso biológico se han hallado los siguientes análogos con el sistema artificial:

- a. Las entradas  $X_i$  representan las señales que provienen de otras neuronas y que son capturadas por las dendritas.
- b. Los pesos  $W_i$  son la intensidad de la sinapsis que conecta dos neuronas.
- c. La función  $\Sigma$  es la función umbral que la neurona debe sobrepasar para activarse; este proceso ocurre biológicamente en el cuerpo de la célula.
- d. Las señales de entrada a una neurona  $X_1, X_2, X_3, \dots, X_n$  son variables continuas en lugar de pulsos discretos, como se presentan en una neurona biológica. Cada señal de entrada pasa a través de una ganancia o peso, llamado peso sináptico o fortaleza de la conexión cuya función es análoga a la de la función sináptica de la neurona biológica. Los pesos pueden ser positivos (Exitatorios) o negativos (inhibitorios), el nodo sumatorio acumula todas las señales de entradas multiplicadas por los pesos o ponderadas y la pasa a la salida a través de una función umbral o función de transferencia. Las funciones más utilizadas son la Sigmoide y Tangente hiperbólica.

Debido a que presentan un gran número de características similares a las del cerebro humano, las redes neuronales son capaces de: a) aprender de la experiencia, b). abstraer características esenciales a partir de entradas que presentan información irrelevante, c) generalizar de casos anteriores a nuevos casos, entre otros. Todo esto permite su aplicación en un gran número de áreas muy diferenciadas. (Olabe, 1998)

Las principales ventajas que representan son:

-Aprendizaje Adaptativo: Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.

-Auto-organización: Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.

-Tolerancia a fallos: La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.

-Operación en tiempo real: Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.

-Fácil inserción dentro de la tecnología existente: Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

### **Tipos de Redes Neuronales:**

#### **Perceptron Multicapa**

Es responsable de la popularidad de las redes neuronales a partir de mediados de los años ochenta, como su nombre lo indica, perceptron multicapa, tiene sus neuronas organizadas

por capas, su número es variable dependiendo de la funcionalidad de la red, pero en general se distinguen estos tipos de capas(Méndez et al. 2008):

- Una capa de entrada donde se alimenta a los datos de la red (capa 0).
- Capas ocultas cuyo número es variable.
- Una capa de salida donde se lee el resultado del cálculo de la red

El gráfico 2 ilustra la estructura de una red Perceptron Multicapa




Gráfico 2 Estructura de una Red Neuronal Perceptron Multicapa

Además del Perceptron Multicapa, existen muchos tipos de redes neuronales artificiales, dentro de las más comunes tenemos: Adaline y Madaline diseñada por Bernard Widrow en 1960, ART, diseñada por Carpenter entre 1960 y 1986, Back-propagation diseñada por Rumelhart y Parker en 1985, Hamming Network diseñada por Lippman en 1987, Hopfield Network diseñada por Hopfield en 1982.

### 2.3 Algunos Conceptos Preliminares de Urgencias Médicas

Con el objetivo de manejar el lenguaje nacional utilizado en las entidades clínicas que implican Urgencias Médicas, muchos de los conceptos presentados a continuación son tomados textualmente de la “Guías para el Manejo de Urgencias” emitido por el Ministerio de la Protección Social de Colombia, las cuales fueron elaboradas pensando en las necesidades los diferentes actores del Sistema General de Seguridad Social en Salud.

- **Área de Cuidados Mínimos:** En CM se resuelven de manera rápida, eficiente y segura procesos agudos destinados a Observación y por tanto puede contribuir a evitar saturación (Garzón, De Moya, Herrera, Caballero, Martínez, 2001).
- **Triage:** Es un método de clasificación de pacientes basado en sus necesidades terapéuticas y en los recursos disponibles. Consiste en una valoración clínica breve que determina el tiempo y la secuencia en que será atendido, con unos recursos limitados. Es un proceso dinámico que cambia tan rápidamente como lo hace el estado clínico del paciente.
- **Manejo del Dolor:** Fisiopatológicamente, el dolor se divide en dos grandes grupos: el dolor agudo (síntoma de enfermedad), cuya duración es menor d 2 semanas y que por lo general es de tipo inflamatorio, y el dolor crónico, que se definía arbitrariamente como aquel cuya duración era mayor de 3 meses, pero recientemente ha sido redefinido como aquel cuya duración supera el tiempo esperado para la curación de la causa etiológica.

- **Atención de Urgencias:** Es el conjunto de acciones realizadas por un equipo de salud debidamente capacitado y con los recursos materiales necesarios para satisfacer la demanda de atención generada por la urgencia.
- **Atención inicial de urgencias:** Son todas las acciones brindadas a una persona que presenta alguna patología de urgencia, con el ánimo de estabilizarlo en sus signos vitales. Hacer un diagnóstico de impresión y definir el destino o la conducta inmediata por seguir, tomando como base el nivel de atención y el grado de complejidad de la entidad que realiza la atención inicial de urgencia, al tenor de los principios éticos y las normas que determinan las acciones y el comportamiento del personal de salud.
- **Emergencia:** Es la situación de salud que se presenta repentinamente y que requiere de un tratamiento inmediato o atención, llevando una alta probabilidad de riesgo de vida.
- **Urgencia:** Es una situación de salud que también se presenta repentinamente, pero sin riesgo de vida y que puede requerir de una asistencia médica dentro de un período de tiempo razonable.

#### **Escaladas Pediátricas:**

**Rochester para pacientes < 90 días y Rochester para pacientes > 90 días:** El síndrome febril ocupa un lugar muy importante en Pediatría, por muchas razones pero, fundamentalmente, porque es uno de los motivos de consulta más frecuente, tanto en Atención Primaria, como en urgencias hospitalarias, por ello se utilizan los criterios de Rochester para evaluar un paciente con un cuadro de fiebre sin Foco. Los criterios de Rochester son criterios clínicos y analíticos de bajo riesgo; de forma que, si el niño cumple estos criterios, no padece infección grave (VPN: 98,9%) y puede ser controlado

de forma ambulatoria, sin precisar tratamiento antibiótico empírico (Barboza, Contte, Rodríguez, Fernández, 2007).

- **Yios para pacientes < 90 días:** Se emplea para valorar cuadros febriles y corresponde a las siglas en inglés de “escala de valoración del lactante pequeño” (Young Infant Observation Scale), se emplea para valorar a lactantes entre 1 y 3 meses de edad, según 3 parámetros: Actitud y respuesta a estimulación, coloración y perfusión periférica y respiración (Rubio, López, 2006), (Barboza, Contte, Rodríguez, Fernández, 2007).
- **Yale para pacientes entre 3-36 meses:** Igual que Rochester y YIOS se emplea para establecer infección bacteriana grave. Descrita por Mc-Carthy en 1982, sigue teniendo vigor en la actualidad y es la escala más empleada para valorar a niños entre 3 y 36 meses de vida, según 6 parámetros: Estado general, respuesta a estímulo, llanto, reacción con los padres, color e hidratación (Rubio, López, 2006), (Barboza, Contte, Rodríguez, Fernández, 2007).
- **Wood-downes modificada por ferres:** Se trata de una escala de evaluación, utilizada fundamentalmente en la valoración de la gravedad de las bronquiolitis, aunque también se ha utilizado para valoración del asma agudo, sobre todo en el ámbito infantil. Evalúa los siguientes parámetros: sibilancias, tirajes, frecuencia respiratoria, frecuencia cardíaca, entrada de aire y cianosis (Cansino, 2004), (Diaz Vazquez, 2004). Dentro del formato establecido se incluye para paciente que ingresa con sibilancia-bronquiolitis y no se dispone de pulsioximetría.
- **Westley** Escala utilizada para la valoración de pacientes con dificultad respiratoria sobre todo para la obstrucción de vías altas, tiene en cuenta los siguientes aspectos: estridor,

tiraje, ventilación, cianosis, conciencia. Dentro del formato se utilizará para para paciente que ingresa con estridor y no se dispone de pulsioximetría.

- **Wetsley modificado por mintegui** : Al igual que las escalas anteriores es utilizada para valorar pacientes con dificultad respiratorias en este caso para pacientes que ingresan con estridor y se dispone de pulsioximetría. En esta se valoran los siguientes parámetros: estridor, reracción subcostales y suprarenales, entrada de aire en los pulmones, SAT O2 Diaz Vazquez et al.( 2004).
- **Indice pulmonar de scarfone**. Escala utilizada para valorar pacientes con crisis asmática severa. Diaz Vazquez et al.( 2004).
- **Glasgow > 3 AÑOS**: Escala utilizada para medir la profundidad del coma, se basa en la respuesta verbal, motora y la apertura de los ojos ante las ordenes verbales o estímulos dolorosos (Casado, Serrano, 1997).
- **Raimondi – Glasgow modificada < 3 años**. Esta escala fue creada y aplicada para niños pequeños con traumatismo craneoencefálico, es la suma a las respuesta a tres diferentes aspectos de la exploración neurológica, respuesta motora, ocular y verbal. Casado et al. (1997)
- **Santolaya**. Esta escala fue definida con criterios de alto y bajo riesgo de infección bacteriana invasora en episodios de neutropenia febril (Rendón, Covarrubias, Noriega 2013)(Paganini, Santolaya de P, 2011)(Pérez, 2012).
- **Escala de Glasgow modificada para sepsis meningocócica**: Escala utilizada en pacientes con sospechas o diagnóstico confirmado de enfermedad meningocócica invasiva. Buñiel Álvarez et al. (2013).



- **Clasificación de asa.** Sistema de clasificación que utiliza la American Society of Anesthesiologists(ASA) para estimar el riesgo que plantea la anestesia para los distintos estados del paciente(Fajardo, Quemba, Eslava, 2005).
- **Escalas de evaluación del dolor – fisiológico-conductual (1 mes a 3 años):** Utilizada para interpretar la información que se puede entregar acerca de los aspectos del dolor como duración e intensidad del mismo y en muchos casos hasta su localización , en niños (Fernández, 2009)
- **Escala de los < ay> o de Oucher (niños 3 – 12 años) y Escala de dibujos faciales (niños de 5-12 años y adolescentes):** Desarrollada por Beber y cols. con seis fotografías de un niño con diferentes muestras de dolor creciente, desde la más tranquila a la más intensa donde se observa gritando de dolor(Malmierca, 2008)

### 3. RECOLECCIÓN Y ANÁLISIS DEL CONJUNTO DE DATOS

Se tuvo en cuenta el conocimiento de los expertos, para los aspectos que debían participar en la clasificación de un paciente en una de las dos áreas establecidas, “Alta complejidad” y “Cuidados Mínimos”. Se estableció que los criterios que se debían manejar para establecer la clasificación, estaban enmarcados en las Escalas Pediátricas que manejan los criterios adecuados según la enfermedad que padezca el paciente y la edad del mismo.

#### 3.1 Identificación de Variables.

Luego de haber determinado las bases para iniciar la investigación, se realizó un análisis de las historias clínicas de pacientes de urgencias de la clínica del año 2013, donde se analizaron 17,132 registros, tomados del sistema de información que actualmente se utiliza. El análisis de estas historias arrojó los diagnósticos más persistentes que se manejan en la urgencia, estos se muestran en la Tabla 2.

**Tabla 2 Clasificación de enfermedades reportadas en la urgencia en el 2013**

Diagnóstico	Cant de Historias	%
Infecciosas	6350	37.07
Traumáticas	2478	14.46
Infecciosas vías respiratorias	1970	11.50
Quirúrgicas	1660	9.69
Respiratorias	1290	7.53
Otras	958	5.59
(en blanco)	824	4.81
Neurológicas	556	3.25
Metabólicas	367	2.14

<b>Diagnóstico</b>	<b>Cant de Historias</b>	<b>%</b>
Hematologicas	310	1.81
Urologicas	120	0.70
Toxicologicas	112	0.65
Cardiologicas	109	0.64
Psiquiatricas	28	0.16
<b>Total</b>	<b>17132</b>	<b>100</b>

En esta tabla se observan las clasificaciones de enfermedades que se tratan en la urgencia de la clínica, esto sirvió como sustento para determinar las escalas que se debían usar para la investigación donde se analizaron los diagnósticos más predominantes.

Dentro del grupo “Infecciosas” se clasificaron diagnósticos como: Fiebre no especificada con 3,499 pacientes reportados que representan el 55% de los clasificados en este grupo, el 45% corresponden a diagnósticos como: Diarrea y Gastroenteritis de presunto origen infeccioso, Infección de vías urinarias –Sitio no especificado, Conjuntivitis viral, Estomatitis candidiásica, fiebre del dengue hemorrágico, entre otras más.

Dentro del grupo “Traumáticas”, se encontraron 265 diagnósticos donde el 29% eran por Traumatismo no especificado, el 71% restante estaba distribuido en el resto de los diagnósticos.

Dentro del grupo “Infecciosas Vías Respiratorias”, se encontraron diagnósticos de Bronquiolitis Aguda no Especificada con el 55% de los pacientes clasificados en este grupo, Neumonía con el 25% de los pacientes y Bronconeumonía no especificada con el

12% de los pacientes, el 8% de los pacientes restantes se clasificaron en diagnósticos como: Sinusitis , Rinofaringitis , Tos Ferina y otras más.

Dentro del grupo “Quirúrgicas” se encontraron 1660 pacientes clasificados en 171 diagnósticos como: cuerpos extraños en zonas diferentes del cuerpo (un diagnostico por cada zona del cuerpo afectada), Apendicitis, Abdomen Agudo, Dolor abdominal localizado, Retócele, Colostomía, entre otras.

Dentro del grupo “Respiratorias” se encontraros 1099 casos de Asmas, lo que representa el 85% de pacientes de los clasificados en este grupo, el 15% restante corresponde a diagnósticos como Displasia broncopulmonar originada en el período perinatal, Insuficiencia Respiratoria aguda, Dificultad Respiratoria del Recién nacido, entre otros casos más.

Analizando la información encontrada dentro de estos grupos se observó que los pacientes acudían al Departamento de Urgencias del Hospital debido a las enfermedades que más se destacan en los grupos: Infecciosas, Infecciosas Vías Respiratorias y Respiratorias, además se determinó que los diagnósticos de Fiebre sin foco, asma, Bronquiolitis y neumonía, debían ser la base principal para escoger las escalas que conformarían los criterios de estudio de la presente investigación.

Además de lo anterior y de la lectura de la literatura científica (Barboza, 2007)(Bohada, 2011) (Campuzano, 2004)( Díaz,2004) (Fernández, 2009) (Rendón, 2013) (Paganini, 2011) junto con el conocimiento del experto, se determinó utilizar las siguientes escalas:

- Rochester para pacientes < 90 días y Rochester para pacientes > 90 días
- Yios para pacientes < 90 días
- Yale para pacientes entre 3-36 meses
- Wood-Downes modificada por ferres
- Westley
- Wetsley modificado por Mintegui
- Indice pulmonar de Scarfone
- Glasgow > 3 años
- Raimondi – Glasgow modificada < 3 años
- Santolaya
- Sscala de Glasgow modificada para sepsis meningococica
- Clasificacion de asa
- Escalas de evaluación del dolor – fisiológico-conductual (1 mes a 3 años
- Escala de los < ay> o de Ucher (niños 3 – 12 años) y escala de dibujos faciales (niños de 5-12 años y adolescentes).

Con la escogencia de las escalas a utilizar, se identificaron también las variables que se utilizarían en esta investigación, estas variables se muestran en la Tabla 3

**Tabla 3 Descripción de Variable**

Descripción de Variables	
1	edad

Descripción de Variables	
2	sexo
3	infante con apariencia generalmente buena
4	infante previamente saludable
5	nacimiento a termino
6	no tratamiento antimicrobiano perinatal
7	no tratamiento antimicrobiano previo
8	no hospitalizacion previa
9	no tratamiento para hiperbilirrubinemia inexplicada
10	no enfermedad cronica subyacente
11	no hospitalizacion mas prolongada que la madre
12	ausencia de signos evidentes de infección de piel, tejidos, blandos, huesos, articulaciones u oídos
13	leucocitos en sangre periférica de 5000-15000/mm <sup>3</sup>
14	abastoados <1500/mm <sup>3</sup>
15	<10 leucocitos por campo en sedimento urinario
16	<5 leucocitos por campo en extensión de heces (diarrea)
17	niño previamente sano
18	sin signos de focalidad
19	no signos de toxicida sistemica*
20	recuento de leucocitos entre 5000-15000 mm <sup>3</sup>
21	uroanalisis <5 leuc x campo
22	perfusion periferica -sonrosado, extremidades calientes
23	perfusion periferica -extremidades frias moteadas
24	perfusion periferica -pálido, shock
25	estado/esfuerzo respiratorio-no deterioro/vigoroso
26	estado/esfuerzo respiratorio-compromiso respiratorio leve moderado (fr:>60), retracciones o quejoso
27	estado/esfuerzo respiratorio-dificultad respiratoria grave esfuerzo respiratorio inadecuado, apnea, fallo respiratorio
28	respuesta social-sonríe o no irritable

Descripción de Variables	
29	respuesta social-irritable, consolable
30	respuesta social-irritable, inconsolable
31	llanto-fuerte/no llora
32	llanto-sollozo
33	llanto-gemidos
34	reacción a los padres-detiene el llanto
35	reacción a los padres-llanto casi continuo
36	reacción a los padres-llanto permanente
37	conciencia-se mantiene o despierta rapido
38	conciencia-somnoliento o se despierta con dificultad
39	conciencia-no se despierta
40	color-rosado
41	color-acrocianosis o palidez distal
42	color-palido, ciatonico o moteado
43	hidratacion-normal
44	hidratacion-boca seca
45	hidratacion-mucosas secas ojos hundidos
46	estimulos sociales-sonrie
47	estimulos sociales-sonrisa breve
48	estimulos sociales-no sonrie, ansioso o inexpresivo
49	sibilancias-sibilancias no
50	sibilancias-final de la espiracion
51	sibilancias-toda la espiracion
52	sibilancias-inspiracion y espiracion
53	tirajes-tirajes no
54	tirajes-subcostal + intercostal inferior
55	tirajes-previo mas supraclavicular + aleteo nasal
56	tirajes-previo + intercostal superior + supraesternal
57	entrada de aire-buena simetrica
58	entrada de aire-regular simetrica
59	entrada de aire-muy disminuida
60	entrada de aire-torax siliente (ausencia de sibilancias)
61	cianosis-cianosis no
62	cianosis-cianosis si
63	fr- < 30 rpm
64	fr- 31 - 45 rpm
65	fr- 46 - 60 rpm
66	fr- > 60 rpm
67	fc - < 120 lpm
68	fc - > 120 lpm
69	estridor-estridor no
70	estridor-estridor al agitarse

Descripción de Variables	
71	estridor-estridor en reposo
72	tiraje-tiraje no
73	tiraje-tiraje leve
74	tiraje-moderado
75	tiraje-severo
76	ventilación-ventilacion normal
77	ventilación-disminuida
78	ventilación-muy disminuida
79	cianosis-cianosis no
80	cianosis-cianosis al agitarse
81	cianosis-cianosis en reposo
82	estridor -estridor no
83	estridor - audible en reposo con fonendo
84	estridor - audible en reposo sin fonendo
85	retracciones subcostales y supraesternales -retracciones no
86	retracciones subcostales y supraesternales -retracciones leves
87	retracciones subcostales y supraesternales -moderada severa
88	entrada de aire en los pulmones - entrada aire pulmones normal
89	entrada de aire en los pulmones - disminucion leve
90	entrada de aire en los pulmones -disminucion leve moderada
91	sat o2 - >=95
92	sat o2 - <=94
93	fr >6 años- < 21
94	fr >6 años- 21-35
95	fr >6 años- 36-50
96	fr >6 años- > 50
97	fr <6 años - < 31
98	fr <6 años - 31-45
99	fr <6 años - 46-60
100	fr <6 años - > 60
101	sibilancias – ausentes
102	sibilancias - final espiracion
103	sibilancias - toda la espiracion
104	sibilancias - inspiracion y espiracion
105	conciente ins/esp - 2-1
106	conciente ins/esp - 1-1
107	conciente ins/esp - 1-2



Descripción de Variables	
108	conciente ins/esp - 2-3
109	mus. accesorios - mus. ausente
110	mus. accesorios - +
111	mus. accesorios - ++
112	mus. accesorios - +++
113	sat o2 - 99-100
114	sat o2 - 96-98
115	sat o2 - 93-95
116	sat o2 - <93
117	apertura de ojos - apertura ojos ninguna
118	apertura de ojos - al dolor
119	apertura de ojos - a la voz
120	apertura de ojos - espontanea
121	verbal - verbal ninguna
122	verbal - sonidos inespecificos
123	verbal - palabras inadecuadas
124	verbal - confuso
125	verbal - orientado
126	motora - motora ninguna
127	motora - extension anormal
128	motora - flexion al dolor
129	motora - retirada al dolor
130	motora - localiza dolor
131	motora - obedece ordenes
132	respuesta ocular - pupilas fijas y meo* paralizados
133	respuesta ocular - pupilas fijas y meo* afectados
134	respuesta ocular - meo* intactos. pupilas reactivas
135	respuesta ocular - persigue con la mirada
136	respuesta verbal – apnea
137	respuesta verbal - respiracion espontanea
138	respuesta verbal – llora
139	respuesta motora - flacidez
140	respuesta motora - hipertonia
141	respuesta motora - alejamiento del dolor
142	respuesta motora - flexiona y extiende
143	respuesta motora - resp. motora flacidos
144	respuesta motora - actitud que mimetiza decorticacion o descerebracion
145	respuesta motora -movimientos estereotipados ante estímulos
146	respuesta motora - retirada del miembro estimulado
147	respuesta motora - movimientos debiles y perezosos

Descripción de Variables	
148	respuesta motora - movimientos alternantes suaves
149	respuesta ocular - respuesta oculocefalica ausente y pupilas fijas
150	respuesta ocular - respuesta oculocefalica alterada
151	respuesta ocular - respuesta oculocefalica intacta
152	respuesta ocular - apertura de los ojos al dolor
153	respuesta ocular - apertura espontanea de los ojos
154	respuesta ocular - focaliza y sigue el estimulo al menos 30° horizontalmente
155	respiracion y vocalizacion - resp y voc apnea
156	respiracion y vocalizacion - respiracion periodica o ataxica
157	respiracion y vocalizacion - respiracion espontanea
158	respiracion y vocalizacion - mueca
159	respiracion y vocalizacion - gemido o llanto debil
160	respiracion y vocalizacion - llanto de tono normal
161	pcr >90 mg/l
162	leucemia mieloide aguda
163	recuento de plaquetas < 50000 mm <sup>3</sup>
164	leucemia en recaida
165	recaida de tumor solido
166	hipotension arterial
167	linfoma no hodking b y de celulas grandes
168	menos de 7 dias desde la ultima quimioterapia
169	neuroblastoma etapa iv
170	lla de alto riesgo
171	hipotension (ta sistólica <75 mm hg en <4 años; <80 mm hg en >4 años)
172	gradiente de t <sup>a</sup> piel/recto >3°c o frialdad cutánea 3
173	ecg <8 o disminucion de >= 3 puntos en 1 hora
174	ausencia de meningismo
175	empeoramiento durante la ultima hora
176	equimosis diseminadas o lesiones crecientes
177	déficit de bases <= -8 mmol/l
178	clasificacion de asa
179	tas basal - <20%

Descripción de Variables	
180	tas basal - 20-30%
181	tas basal - >30%
182	llanto - ausente
183	llanto - consolable con palabras-caricias
184	llanto - no consolable
185	actividad motora espontanea - dormido-jugando-tranquilo
186	actividad motora espontanea - moderada-controlable
187	actividad motora espontanea - intensa-incontrolable
188	evaluacion verbal (2-3 años) - no expresa dolor
189	evaluacion verbal (2-3 años) - incomodo- duele sin localizar
190	evaluacion verbal (2-3 años) - se queja y localiza dolor
191	expresion facial
192	lenguaje corporal (<2años) - dormido – postura normal
193	lenguaje corporal (<2años) - hipertonia-miembros agarrotados
194	lenguaje corporal (<2años) - protege o toca zona dolorosa
195	escala de oucher
196	escala dibujos faciales
197	clasificacion triage

La variable que contiene la respuesta esperada es la variable clasificación Triage, su valores podrán ser 0 y 1, con la siguiente interpretación 1: Alta complejidad y 0: Baja complejidad.

### 3.2 Recolección de Datos

Después de haber establecido las escalas que se usarán para la investigación, se realizó un comparativo entre los criterios que evalúan las escalas y la información contenida en la historia clínica que se maneja por paciente en el software que actualmente usa la clínica, se tomaron 20 historias al azar como muestra y se pudo determinar que las

historias clínicas no contienen la información específica y detallada que evalúan las escalas, por lo tanto se decidió establecer un formato cuyo contenido está formado por los criterios que evalúa cada escala, de esta forma se diseñó el formato “Escalas de Valoración en Pediatría – hospital Infantil Napoleón Pareja”, se observa en el Anexo 1, este formato agrupa las escalas determinadas según los diagnósticos más presentes en el Departamento de Urgencias y que se usará para la recolección prospectiva de la información.

Este formato fue presentado y aceptado por la Coordinación de Calidad y Epidemiología de la clínica, ya que esta Coordinación debe cumplir con la Resolución 1441 de 2013, que resalta “...El prestador cuenta con guías para las principales patologías que atiende en cada servicio clínico...”, además, como una acción de mejora debe “Adaptar y anexar las escalas de riesgos de las 10 patologías más frecuentes a la Guía de diligenciamiento de HC”.

Para la implementación de este formato en el Departamento de Urgencias de la Clínica, fue necesario hacer una socialización del uso de las Escalas, razón por la cual fue necesario hacer reuniones con los diferentes grupos que conforman el cuerpo médico de la urgencia de la clínica, como son: Pediatras, Residentes, Internos, Rurales y Enfermeras Licenciadas. Como parte de la socialización se diseñó una guía donde se explica la utilización de cada escala.

El formato establecido y socializado con el personal médico, se desarrolló dentro del software que maneja la clínica para el manejo médico, operativo y financiero, llamado “Dinámica”, y fue habilitado como parte integral de la Historia Clínica de un paciente, donde se diligencia al ingreso y por cada evolución que se observe.

El formato empezó a operar el 12 de marzo de 2014, desde ese momento se han observado mejoras en los siguientes aspectos:

- a. La toma de decisiones tienen más soporte objetivo que subjetivo, puesto que las escalas y los scores predicen de manera confiable el verdadero estado clínico de los pacientes.
- b. Con las escalas podemos valorar de manera más eficientemente los resultados clínicos de nuestras intervenciones terapéuticas.
- c. Las escalas han permitido cumplir la reglamentación determinada por la Resolución 1441 de 2013.
- d. Optimización en la clasificación de los pacientes entre leve, moderada y graves o críticos.
- e. En la evaluación y evolución de los pacientes todo el personal del hospital utiliza los mismos parámetros para la evaluación y seguimiento de los pacientes.

- f. Permite descubrir la severidad de los casos que se presentan y la prestación del servicio de manera más oportuna y eficaz a los pacientes críticos.

Además, posteriormente se espera que las escalas permitan racionalizar el tratamiento y disminuir los costos.

El proceso de recolección de datos culminó el 07 de agosto de 2014.

### **3.3 Análisis de Datos**

Durante el proceso de recolección de datos se obtuvo un total de 1,495 formatos de escalas diligenciados, dentro de estas se identificaron 561 formatos repetidos (cifra distribuida en varios pacientes), esto obedece a las observaciones que se hacen a los pacientes en lapsos de 24, 12, 10, 8, 5, 3 horas dependiendo la gravedad de la enfermedad, esta información es reportada en el sistema de información soportado con un diligenciamiento de la escala. Al analizar la información repetida, se identificaron por paciente, aquella escala que se le aplicó al ingreso y aquellas que se aplicaron por cada evolución observada, como esta investigación está enfocada en la clasificación que se le realice al paciente al ingreso para determinar la severidad de la urgencia, se eliminaron aquellos registros que hacían parte de la evolución reportada, dejando solo aquellos aplicados al ingreso, teniendo en cuenta esto, se eliminaron 290 escalas concretando el conjunto de datos con 1205 registros.

Para el segundo análisis realizado, nos enfocamos en la identificación de las variables que se utilizaron durante la recolección de datos de las cuales no se obtuvo muestra, ya que si no aportan información, en el entrenamiento no tendrán ninguna validez, además, hay que destacar que cuando un niño llega en un estado que genera signos de alarma, es atendido directamente sin tener que aplicar una clasificación teniendo en cuenta el nivel asistencial.

Durante este segundo análisis se eliminaron las 51 variables que se detallan en la Tabla 4

**Tabla 4 Variables eliminadas**

<b>Descripción de Variables Eliminadas</b>	
1	perfusion periferica - pálido, shock
2	respuesta social - irritable, inconsolable
3	llanto - gemidos
4	reaccion a los padres llanto permanente
5	conciencia - no se despierta
6	color - palido, ciatonico o moteado
7	tiraje – severo
8	ventilación - muy disminuida
9	cianosis - cianosis al agitarse
10	cianosis - cianosis en reposo
11	conciencia - alterada
12	entrada de aire en los pulmones - disminucion leve moderada
13	verbal - palabras inadecuadas
14	motora - extension anormal
15	respuesta ocular - pupilas fijas y meo* paralizados
16	respuesta motora - hipertonia
17	respuesta motora - resp. motora flacidos
18	respuesta motora - actitud que mimetiza decorticacion o descerebracion
19	respuesta motora -movimientos estereotipados ante estímulos

Descripción de Variables Eliminadas	
20	respuesta motora - retirada del miembro estimulado
21	respuesta motora - movimientos debiles y perezosos
22	respuesta motora - movimientos alternantes suaves
23	respuesta ocular - respuesta oculocefalica ausente y pupilas fijas
24	respuesta ocular - respuesta oculocefalica alterada
25	respuesta ocular - respuesta oculocefalica intacta
26	respuesta ocular - apertura de los ojos al dolor
27	respuesta ocular - apertura espontanea de los ojos
28	respuesta ocular - focaliza y sigue el estimulo al menos 30° horizontalmente
29	respiracion y vocalizacion - resp y voc apnea
30	respiracion y vocalizacion - respiracion periodica o ataxica
31	respiracion y vocalizacion - respiracion espontanea
32	respiracion y vocalizacion - mueca
33	respiracion y vocalizacion - gemido o llanto debil
34	respiracion y vocalizacion - llanto de tono normal
35	leucemia mieloides aguda
36	leucemia en recaida
37	recaida de tumor solido
38	hipotension arterial
39	menos de 7 dias desde la ultima quimioterapia
40	neuroblastoma etapa iv
41	lla de alto riesgo
42	hipotension (ta sistólica <75 mm hg en <4 años; <80 mm hg en >4 años)
43	gradiente de tª piel/recto >3°C o frialdad cutánea 3
44	ecg <8 o disminucion de >= 3 puntos en 1 hora
45	ausencia de meningismo
46	empeoramiento durante la ultima hora
47	equimosis diseminadas o lesiones crecientes
48	déficit de bases <= -8 mmol/l



Descripción de Variables Eliminadas	
49	clasificación de asa
50	llanto - no consolable
51	actividad motora espontanea - intensa-incontrolable

Por la eliminación de estas variables se observó la eliminación completa de las escalas: “Coma para Neonatos”, “Escala de Glasgow modificada para Sepsis Meningocócica”, y “Clasificación de Asa”. La tabla 5 muestra el número de veces que se aplicó cada escala.

**Tabla 5 Número de veces de aplicación de cada escala**

Ítem	Escala	Cantidad
1	Rochester para pacientes <90 días (fiebre sin foco) define pacientes con bajo riesgo de infección bacteriana	17
2	Criterios de rochester para pacientes >90 días	12
3	Yios para pacientes <90 días (fiebre sin foco) permite identificar riesgo de enfermedad bacteriana grave	49
4	Yale para pacientes entre 3-36 meses (fiebre sin foco) permite identificar riesgo de enfermedad bacteriana grave	62
5	Wood-downes modificada por ferres (paciente que ingresa con sibilancias - bronquiolitis y no se dispone de pulsioximetría)	472
6	Westley (paciente que ingresa con estridor no se dispone de pulsioximetría)	6
7	Wetsley modificado por mintegui (paciente que ingresa con estridor y se dispone de pulsioximetría)	23
8	Índice pulmonar de scarfone (paciente que ingresa con sibilancias - crisis asmática y se dispone de pulsioximetría)	512
9	Glasgow > 3 años (valoración del nivel de conciencia)	27
10	Raimondi - glasgow modificada < 3 años	31
11	Escala de coma para neonatos	0
12	Santolaya (alto o bajo riesgo de infección bacteriana invasora en episodios de neutropenia febril)	2
13	Escala de glasgow modificada para sepsis meningocócica	0
14	Clasificación de asa	0
15	Escalas de evaluación del dolor – fisiológico-conductual (1 mes a 3 años)	5

Ítem	Escala	Cantidad
16	Escala de los < ay> o de ouchter (niños 3 – 12 años)	22
17	Escala de dibujos faciales (niños de 5-12 años y adolescentes)	23

Dentro del análisis realizado de las variables eliminadas, se llega a la siguiente conclusión:

- a. Existen variables como “llanto –Gemidos”, ”Conciencia-No despierta”, “Color Pálido, catiónico o moteado”, “Pálido-Shock, que pertenecen al grupo de YIOS y YALE, que también se pueden encontrar en otras patologías como dificultad respiratoria, asma, entre otros, además la mayoría de fiebres sin focos no son pacientes críticos, es posible que se den por virosis del momento o porque el familiar refiere que el paciente tiene muchos días con esta, es decir, son fiebres sin foco pero sin signos de alarma que se ingresan para descartar que la fiebre viene por una causa que se tenga que hospitalizar, como por ejemplo una infección de vías urinaria que es frecuente en los lactantes.
- b. Los criterios de Westley como, “Tiraje – Severo”, “Ventilación –Muy disminuida”, “Cianosis – al agitarse”, “Cianosis – en reposo”, “Conciencia – alterada”, se eliminan por que no se presentaron pacientes con este criterio evaluados por esta escala, para los pacientes que se han presentado cianóticos la causa no ha estado relacionada con la patología en que se aplica esta escala. Además esta escala no se aplica en muchos casos porque se dispone pulsioximetría.
- c. Los criterios de Raimondi y Glasgow que se eliminaron como: “Verbal-Palabras inadecuadas”, “Motora-Extensión anormal”, “pupilas fijas y Meoparalizado”, Hipertonía, están relacionados generalmente a pacientes que llegan con compromiso

- cerebral severo para lo que no se presentan muchos casos y cuando se presentan son tratados inmediatamente.
- d. La escala de Coma para Neonatos fue eliminada en su totalidad por no presentarse ningún caso de observación en el tiempo de recolección de datos, esto se debe porque la aplicación de esta escala se presenta generalmente, cuando se encuentra un trauma craneoencefálico en edades mayores como lactantes, escolares y prescolares.
  - e. La escala de Santolaya también fue eliminada porque se observó que los pacientes con neutropenia febril son pacientes que llegan con antecedentes de procesos tumorales que cursan con un proceso febril y tienen disminución de las células neutrófilos. Los casos que se presentan, por su condición, pasan directamente a revisión pediátrica.
  - f. Para el caso de la escala de Glasgow modificada para Sepsis Meningococica, no se encontraron registros porque la Sepsis Meningococica no es frecuente, se presentan brotes muy esporádicamente.
  - g. Para los otros casos de variables eliminadas, obedeció a la no utilización de los criterios porque no se presentaron casos.

### **Conclusiones**

Con la identificación de las escalas que se utilizarán para la clasificación de pacientes en la urgencia, se determinaron las variables a utilizar para evaluar un paciente según su grado de severidad. El listado inicial de 197 variables fue sometido a dos análisis que permitieron determinar el listado final de las mismas, llegando un conjunto de 146 variables, para lo que se tuvo en cuenta la experiencia de médicos y enfermeras en el proceso de eliminación. Dentro de todo este proceso de utilizar unos criterios que

permitan medir la severidad de una enfermedad o la evolución del paciente, es muy importante y primordial tener claro que el juicio del experto (en este caso el médico) es crucial para tomar una decisión definitiva sobre el estado de un paciente, para ello, el experto tendrá en cuenta también los antecedentes de base del paciente, por ejemplo si se presenta una bronquiolitis leve en un prematuro, este se hospitaliza, no por la bronquiolitis sino por su estado de prematuro. También influye la parte social como por ejemplo el acceso a los servicios médicos, además las condiciones socioeconómicas que puedan intervenir con la exacerbación de los síntomas del paciente o con el curso del cuadro clínico, también tendrán en cuenta los contactos epidemiológicos.

#### 4. ENTRENAMIENTO VALIDACIÓN Y PRUEBAS

Una vez obtenido el conjunto de datos apto para iniciar el proceso de escogencia de la técnica de Machine Learning que se usará para desarrollar el Clasificador de pacientes objeto de esta investigación, se realizó un tercer análisis teniendo en cuenta el número de variables y el número de ejemplos recolectados. Nuestro conjunto de datos está formado 146 variables y 1205 observaciones, como se observa nuestro conjunto de datos tiene una alta dimensionalidad y esto implica comprometer la eficiencia del clasificador escogido por tener un modelo con una complejidad alta que nos podría llevar a un overfitting, además se debe tener en cuenta que por el número de variables obtenidas, se puede estar corriendo el riesgo de tener atributos ruidosos que pueden tener el mismo peso que los atributos relevantes. Como solución a este problema se utilizó la técnica Análisis de Componentes Principales que nos permitió reducir la dimensionalidad del conjunto de datos preservando en lo posible, la aleatoriedad de los datos del conjunto original.

#### 4.1 Análisis de Componentes Principales

Dentro de esta investigación se utilizó el análisis de componentes principales el cual permite reducir la dimensionalidad de un conjunto de datos, transformando el conjunto de “p” variables originales en otro conjunto de “q” variables incorrelacionadas ( $q \leq p$ ) llamadas componentes principales

Para aplicar este análisis en esta investigación se utilizó una herramienta para el análisis de datos llamada Statgraphics. Como se comentó en el capítulo anterior, al finalizar el análisis de los datos se contaba con 146 variables y 1205 observaciones, de estas observaciones, teniendo en cuenta lo recomendado en la literatura se tomó el 80% para el proceso de entrenamiento y validación, por ello se cuenta con 964 observaciones para esta etapa, las cuales se tomaron como insumo para el Análisis de Componente Principales. El 20% restante se reservó exclusivamente para pruebas. Para el cálculo de los componentes principales se utilizó únicamente el conjunto de entrenamiento, a partir de esto se define la matriz de transformación que posteriormente será aplicada a los datos de prueba, lo anterior siguiendo las buenas prácticas registradas por la literatura (Ng, 2010)(Neal, 2014)(Yaser Abu\_Mostafa, 2012) con el fin de no contaminar los datos reservados para prueba. Statgraphic arrojó el siguiente resultado Tabla 6:

**Tabla 6 Análisis de Componentes Principales.**

Componente Número	Eigenvalor	Porcentaje de Varianza	Porcentaje Acumulado
1	8.052860000000000000	5.554	5.554
2	7.023500000000000000	4.844	10.397
3	6.242110000000000000	4.305	14.702
4	5.560840000000000000	3.835	18.537
5	5.129350000000000000	3.537	22.075

Componente Número	Eigenvalor	Porcentaje de Varianza	Porcentaje Acumulado
6	4.064560000000000000	2.803	24.878
7	3.823460000000000000	2.637	27.515
8	3.485030000000000000	2.403	29.918
9	3.363630000000000000	2.32	32.238
10	3.307600000000000000	2.281	34.519
11	3.109640000000000000	2.145	36.664
12	3.061940000000000000	2.112	38.776
13	3.017040000000000000	2.081	40.856
14	3.013150000000000000	2.078	42.934
15	2.675320000000000000	1.845	44.779
16	2.658580000000000000	1.834	46.613
17	2.651640000000000000	1.829	48.442
18	2.606340000000000000	1.797	50.239
19	2.367310000000000000	1.633	51.872
20	2.225960000000000000	1.535	53.407
21	2.211910000000000000	1.525	54.932
22	2.166760000000000000	1.494	56.427
23	1.995230000000000000	1.376	57.803
24	1.881310000000000000	1.297	59.1
25	1.863560000000000000	1.285	60.385
26	1.735440000000000000	1.197	61.582
27	1.695710000000000000	1.169	62.752
28	1.676580000000000000	1.156	63.908
29	1.603520000000000000	1.106	65.014
30	1.548940000000000000	1.068	66.082
31	1.482150000000000000	1.022	67.104
32	1.467840000000000000	1.012	68.116
33	1.434880000000000000	0.99	69.106
34	1.359930000000000000	0.938	70.044
35	1.349520000000000000	0.931	70.975
36	1.311820000000000000	0.905	71.879
37	1.252320000000000000	0.864	72.743
38	1.229430000000000000	0.848	73.591
39	1.198950000000000000	0.827	74.418
40	1.193940000000000000	0.823	75.241
41	1.161680000000000000	0.801	76.042
42	1.087360000000000000	0.75	76.792
43	1.073400000000000000	0.74	77.532
44	1.061770000000000000	0.732	78.265
45	1.051270000000000000	0.725	78.99

Componente Número	Eigenvalor	Porcentaje de Varianza	Porcentaje Acumulado
46	1.0257600000000000	0.707	79.697
47	1.0226900000000000	0.705	80.402
48	1.0090000000000000	0.696	81.098
49	0.9865360000000000	0.68	81.779
50	0.9712330000000000	0.67	82.448
51	0.9593030000000000	0.662	83.11
52	0.9425660000000000	0.65	83.76
53	0.9374730000000000	0.647	84.407
54	0.8944100000000000	0.617	85.023
55	0.8742240000000000	0.603	85.626
56	0.8524390000000000	0.588	86.214
57	0.8436880000000000	0.582	86.796
58	0.8373820000000000	0.578	87.374
59	0.8231100000000000	0.568	87.941
60	0.8099040000000000	0.559	88.5
61	0.7957440000000000	0.549	89.049
62	0.7867890000000000	0.543	89.591
63	0.7629670000000000	0.526	90.117
64	0.7600730000000000	0.524	90.642
65	0.7510260000000000	0.518	91.16
66	0.6957290000000000	0.48	91.639
67	0.6826450000000000	0.471	92.11
68	0.6733160000000000	0.464	92.575
69	0.6476720000000000	0.447	93.021
70	0.6217220000000000	0.429	93.45
71	0.6141870000000000	0.424	93.874
72	0.5815390000000000	0.401	94.275
73	0.5700800000000000	0.393	94.668
74	0.5460900000000000	0.377	95.044
75	0.5296710000000000	0.365	95.41
76	0.5099680000000000	0.352	95.761
77	0.4888680000000000	0.337	96.099
78	0.4666200000000000	0.322	96.42
79	0.4516360000000000	0.311	96.732
80	0.4287800000000000	0.296	97.028
81	0.3991120000000000	0.275	97.303
82	0.3720430000000000	0.257	97.559
83	0.3497270000000000	0.241	97.801
84	0.3427130000000000	0.236	98.037
85	0.3283920000000000	0.226	98.263



Componente Número	Eigenvalor	Porcentaje de Varianza	Porcentaje Acumulado
86	0.303862000000000000	0.21	98.473
87	0.272639000000000000	0.188	98.661
88	0.250499000000000000	0.173	98.834
89	0.224775000000000000	0.155	98.989
90	0.202698000000000000	0.14	99.129
91	0.165126000000000000	0.114	99.242
92	0.162612000000000000	0.112	99.355
93	0.136826000000000000	0.094	99.449
94	0.104844000000000000	0.072	99.521
95	0.094825500000000000	0.065	99.587
96	0.081793100000000000	0.056	99.643
97	0.064566800000000000	0.045	99.688
98	0.060876700000000000	0.042	99.73
99	0.057953600000000000	0.04	99.769
100	0.057147500000000000	0.039	99.809
101	0.033078400000000000	0.023	99.832
102	0.031964000000000000	0.022	99.854
103	0.029784000000000000	0.021	99.874
104	0.024420300000000000	0.017	99.891
105	0.023390500000000000	0.016	99.907
106	0.022329400000000000	0.015	99.923
107	0.021580400000000000	0.015	99.938
108	0.020995800000000000	0.014	99.952
109	0.017909900000000000	0.012	99.964
110	0.015291600000000000	0.011	99.975
111	0.013706200000000000	0.009	99.984
112	0.012849500000000000	0.009	99.993
113	0.006211870000000000	0.004	99.998
114	0.003578510000000000	0.002	100
115	0.000000000000020404	0	100
116	0.000000000000012555	0	100
117	0.000000000000009319	0	100
118	0.000000000000006068	0	100
119	0.000000000000002878	0	100
120	0.000000000000000783	0	100
121	0.000000000000000653	0	100
122	0.000000000000000407	0	100
123	0.000000000000000360	0	100
124	0.000000000000000313	0	100
125	0.000000000000000180	0	100

Componente Número	Eigenvalor	Porcentaje de Varianza	Porcentaje Acumulado
126	0.0000000000000000113	0	100
127	0.0000000000000000076	0	100
128	0.0000000000000000047	0	100
129	0.0000000000000000007	0	100
130	0.0000000000000000000	0	100
131	0.0000000000000000000	0	100
132	0.0000000000000000000	0	100
133	0.0000000000000000000	0	100
134	0.0000000000000000000	0	100
135	0.0000000000000000000	0	100
136	0.0000000000000000000	0	100
137	0.0000000000000000000	0	100
138	0.0000000000000000000	0	100
139	0.0000000000000000000	0	100
140	0.0000000000000000000	0	100
141	0.0000000000000000000	0	100
142	0.0000000000000000000	0	100
143	0.0000000000000000000	0	100
144	0.0000000000000000000	0	100
145	0.0000000000000000000	0	100

En la tabla 6 se observan los valores propios de cada uno de los 145 componentes, así como su correspondiente porcentaje de varianza y el porcentaje acumulado de esta, además se evidencia, para este caso, los 145 componentes que en conjunto explican el 100% de la variabilidad de los datos originales. Como el propósito del análisis es obtener un número reducido de los componentes que expliquen la mayor variabilidad posible de los datos, se decidió tener en cuenta apartes sugeridos en la literatura para determinar dicho número de componentes:

- a. Aquellos cuyo valor propio estuviera sobre o igual a 1, con esto se pueden obtener 48 componentes que tienen el 81.098% de la variabilidad explicada de los datos, el

gráfico 3 muestra este comportamiento. En este gráfico se puede observar que la curva empieza a descender más pronunciadamente cuando en el eje de las “Y” se obtienen valores por debajo de “1”. Verificando esto con la tabla 6 se pudo determinar el número de componentes que se deben tener en cuenta, el cual es visualizado en el eje de las “X” del gráfico 3.

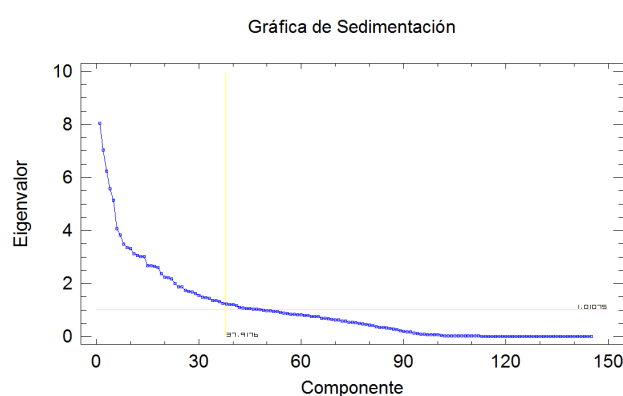


Gráfico 3 Gráfico de Sedimentación Componentes Vs Eigenvalor

- b. Teniendo en cuenta el 85.023% de la variabilidad explicada, para lo que se obtienen 54 componentes.
- c. Teniendo en cuenta el 95 % de la variabilidad explicada donde se obtienen 74 componentes.

Se escogen hasta estos valores de varianza acumulada, indicados en los ítems a, b y c porque se observa que el aporte de cada componente, después del número indicado en cada uno de ellos y expresado en términos del porcentaje de varianza, no es mucho, como lo muestra la gráfica 4 donde se observa en el eje “Y” el porcentaje de varianza y en el eje

“X” el número de componentes, nótese como la curva va descendiendo a medida que aumenta el número de componentes y disminuye la varianza..

Teniendo en cuenta el número de componentes obtenido en cada uno de los análisis realizados, se decidió armar tres conjunto de datos partiendo del resultado de cada uno de ellos, es decir, un primer conjunto con 48 componentes, un segundo conjunto con 54 componentes y un tercer conjunto con 74 componentes.




Gráfico 4 Grafico de Sedimentación Componentes Vs Porcentaje de Varianza

De este análisis, también se obtuvo los vectores propios, que se usarán como punto de partida para la etapa de prueba donde serán combinados con el conjunto de datos reservados para dicha etapa (el 20% de todo el conjunto de datos originales) para sacar el conjunto datos final con que se probará el clasificador seleccionado.

Statgraphics también facilita la matriz de componentes con los correspondientes valores normalizados para cada observación original que se tenía (el conjunto de datos de 964

observaciones), esto sirvió como insumo para iniciar el proceso de selección de la técnica de machine Learning a utilizar, dentro de la cuales, como ya lo mencionamos, usaremos: Regresión Logística, Maquinas de soporte vectorial y Redes Neuronales.

#### 4.2 Evaluación de Técnicas.

Las técnicas escogidas para esta investigación son Máquinas de soporte vectorial, Regresión Logística y Redes Neuronales. Para realizar la evaluación de las técnicas se utilizaron los conjuntos de datos provenientes del análisis de componentes, es decir se utilizó la matriz de componentes con sus respectivos valores normalizados, este conjunto está compuesto por 964 observaciones con dos clases identificadas: 1. Alta complejidad y 0. Baja complejidad o cuidados mínimos.

Para la evaluación de las técnicas se utilizó el programa Orange 2.7, el cual utiliza las librerías de Python para el análisis de datos. Los parámetros indicados para cada una de las técnicas, fueron obtenidos experimentalmente basados en aquellas observaciones con mejores resultados, donde se tomó como referencia para compararlas, las métricas especificadas al final de este capítulo para evaluar las técnicas. Al iniciar el proceso de asignación de parámetros se escogieron valores para el número de neuronas en la capa oculta entre 5 y 90, con factor de regularización de 0.9 a 0,3 obteniendo un F1 entre 82% y 83%. Para las máquinas de soporte vectorial se inició experimentado con un polinomio de grado 1 donde se observó un F1 82%, posteriormente con la función de base radial se iniciaron pruebas con el parámetro “g” entre 0.01 y 0.008, y el parámetro “C” entre 0.9 y

0.3, obteniendo valores de F1 entre 80,13% 81,028%. Estos valores no se incluyen en las tablas, como se había mencionado, solo se tabularon aquellos donde se observaron mejores resultados de las métricas dentro de cada técnica. En las siguientes secciones se presentan estas observaciones.

#### 4.2.1 Máquina de Soporte Vectorial

Para las máquinas de soporte vectorial se hicieron pruebas con diferentes tipos de kernel:

##### Polinomial

$$(g x * y + c)^d$$

Para este análisis se utilizaron los diferentes valores:

- a.  $g=0.0068$ ;  $c=0.1$ ;  $d=2$  **SMV Type C-SVM : cost (C)=1.90**
- b.  $g=0.00500$ ;  $c=0.1$ ;  $d=3$  **SMV Type C-SVM : cost (C)=0.80**

##### Función de base radial

$$\exp(-g|x - y|^2)$$

- a.  $g=0.007$  **SMV Type C-SVM : cost (C)=0.60**
- b.  $g=0.006$  **SMV Type C-SVM : cost (C)=0.60**
- c.  $g=0.004$  **SMV Type C-SVM : cost (C)=0.30**

### Sigmoide

$$\tanh(g \cdot x + c)$$

- a.  $g=0.004$ ,  $c=0.1$  SMV Type C-SVM : cost (C)=0.30

#### 4.2.2 Redes Neuronales (Perceptron Multicapa)

- a. Neuronas en la capa oculta= 100; factor de regularización=0.5, iteraciones= 1000
- b. Neuronas en la capa oculta= 150; factor de regularización=0.2; iteraciones=1000
- c. Neuronas en la capa oculta= 250; factor de regularización=0.3; iteraciones=1000
- d. Neuronas en la capa oculta= 250; factor de regularización=0.6; iteraciones=1000
- e. Neuronas en la capa oculta= 250; factor de regularización=0.1; iteraciones=1000

#### 4.2.3 Regresión Logística

- a. Costo de error de entrenamiento= 0.60
- b. Costo de error de entrenamiento= 0.80
- c. Costo de error de entrenamiento= 0.40
- d. Costo de error de entrenamiento= 0.20
- e. Costo de error de entrenamiento= 0.05
- f. Costo de error de entrenamiento= 0.01

Dentro del proceso de evaluación de las técnicas se utilizó la validación cruzada conocida como K-fold Cross Validation, que consiste en dividir el conjunto de ejemplos de que se dispone, en k conjuntos disjuntos de igual tamaño  $T_1 \dots T_k$ , (para esta investigación se utilizó un k de 10). Se realizan k experimentos, usando como conjunto de entrenamiento la iteración i-ésima  $U_{j \neq i} T_j$  y como conjunto de test  $T_i$ . Cada algoritmo da lugar a una muestra de k estimaciones del error, y las diferencias entre dos algoritmos se juzgan mediante un contraste acerca de las diferencias entre las medias o las medianas del error muestral.

Para cada una de las técnicas en cada una de las pruebas realizadas (variando los parámetros) se obtuvo la correspondiente matriz de confusión partiendo de los parámetros mostrados en la tabla 11, donde, teniendo en cuenta que la clase positiva es la clase cuyo valor tomamos como “1”: Clasificación para alta complejidad” y la clase negativa es la “0”: Clasificación para baja complejidad o cuidados mínimos y además utilizando las ecuaciones que se muestran a continuación, se calcularon la métricas para evaluar las técnicas utilizadas. Estas métricas fueron: Precisión, Recall y valor-F.

$$\text{Precision} = \frac{VP}{VP + FP}$$

$$\text{Recall} = \frac{VP}{VP + FN}$$

$$F1 = 2 * \frac{\text{Precisión} * \text{Recall}}{\text{Precisión} + \text{Recall}}$$



Tabla 7 Matriz de Confusión

Predicción/Real	Positiva	Negativa
Positiva	VP	FP
Negativa	FN	VN

Donde, VP: verdaderos positivos, VN: verdaderos negativos, FP: falsos positivos, FN: falsos negativos.

Como se mencionó en el análisis de componentes principales, se realizaron pruebas sobre tres conjuntos de datos, con 48, 54 y 74 componentes respectivamente, a continuación se muestran todos los valores obtenidos por cada conjunto de datos, aplicando los parámetros mencionados en cada una de las técnicas:

**Valores obtenidos para el conjunto de datos con 48 componentes principales:**

**Pruebas con Máquina de Soporte Vectorial**

**a. Polinomial,  $(g x * y + c)^d$**

g	c	d	Cost	Precision	Recall	F1
0.0068	0.1	2	1.9	0.88690476	0.76410256	0.82093664
0.0050	0.1	3	0.8	0.90259740	0.35641026	0.51102941

**b. Función de base radial,  $\exp(-g|x - y|)^2$**

g	Cost	Precision	Recall	F1
0.007	0.6	0.83109920	0.79487179	0.81258191

<b>g</b>	<b>Cost</b>	<b>Precision</b>	<b>Recall</b>	<b>F1</b>
0.006	0.6	0.82573727	0.78974359	0.80733945
0.004	0.3	0.83289125	0.80512821	0.81877445

**c. Sigmoide,  $\tanh(g \times y + c)$**

<b>g</b>	<b>c</b>	<b>Cost</b>	<b>Precision</b>	<b>Recall</b>	<b>F 1</b>
0.004	0.1	0.3	0.83289125	0.80512821	0.81877445

**Pruebas con Redes Neuronales - Perceptron Multicapa**

<b>Neuronas en la Capa Oculta</b>	<b>Factor de Regularización</b>	<b>Precision</b>	<b>Recall</b>	<b>F 1</b>
100	0.5	0.84391534	0.81794872	0.83072917
150	0.2	0.83589744	0.83589744	0.83589744
250	0.3	0.82531646	0.83589744	0.83057325
250	0.6	0.83727034	0.81794872	0.82749676
250	0.1	0.83505155	0.83076923	0.83290488

**Pruebas con Regresión Logística**

<b>Costo de error de entrenamiento</b>	<b>Precision</b>	<b>Recall</b>	<b>F1</b>
0.6	0.802	0.769	0.785
0.8	0.802	0.769	0.785
0.4	0.802	0.769	0.785
0.2	0.803	0.772	0.790
0.5	0.800	0.780	0.790
0.1	0.800	0.790	0.800

**Valores obtenidos para el conjunto de datos con 54 componentes principales**

**Pruebas con Maquinas de Soporte Vectorial**

**a. Polinomial,  $(g x * y + c)^d$**

<b>g</b>	<b>C</b>	<b>d</b>	<b>Cost</b>	<b>Precision</b>	<b>Recall</b>	<b>F 1</b>
0.0068	0.1	2	1.9	0.892537313	0.766666667	0.824827586
0.0050	0.1	3	0.8	0.903474903	0.600000000	0.721109399

**b. Función de base radial,  $\exp(-g|x - y|)^2$**

<b>g</b>	<b>Cost</b>	<b>Precision</b>	<b>Recall</b>	<b>F 1</b>
0.007	0.6	0.84468665	0.79487179	0.81902246
0.006	0.6	0.83923706	0.78974359	0.81373844
0.004	0.3	0.82849604	0.80512821	0.81664499

**Pruebas con Redes Neuronales (Perceptron Multicapa)**

<b>Neuronas en la Capa Oculta</b>	<b>Factor de Regularización</b>	<b>Precision</b>	<b>Recall</b>	<b>F 1</b>
100	0.5	0.83376623	0.82307692	0.8283871
150	0.2	0.84196891	0.83333333	0.83762887
250	0.3	0.8372093	0.83076923	0.83397683
250	0.6	0.83905013	0.81538462	0.82704811
250	0.1	0.85602094	0.83846154	0.84715026

**Pruebas con Regresión Logística**

Costo de error de entrenamiento	Precision	Recall	F1
0.6	0.806	0.767	0.786
0.8	0.804	0.767	0.785
0.4	0.804	0.767	0.785
0.2	0.802	0.767	0.784
0.5	0.809	0.779	0.794
0.1	0.805	0.795	0.800

**Valores obtenidos para el conjunto de datos con 74 componentes principales**

**Pruebas con Máquinas de Soporte Vectorial**

**a. Polinomial,  $(g x * y + c)^d$**

g	c	D	Cost	Precision	Recall	F 1
0.0068	0.1	2	1.9	0.87755102	0.77179487	0.82128240
0.0050	0.1	3	0.8	0.91071429	0.39230769	0.5483871

**b. Función de base radial,  $\exp(-g|x - y|)^2$**

g	Cost	Precision	Recall	F
0.007	0.6	0.84139785	0.8025641	0.82152231
0.006	0.6	0.84182306	0.80512821	0.82306684
0.004	0.3	0.83113456	0.80769231	0.81924577

**c. Sigmoide,  $\tanh(g x*y + c)$**

g	c	Cost	Precision	Recall	F 1
0.004	0.1	0.3	0.83113456	0.80769231	0.81924577

**Pruebas con Redes Neuronales (Perceptron Multicapa)**

Neuronas en la Capa Oculta	Factor de Regularización	Precision	Recall	F 1
100	0.5	0.82828283	0.84102564	0.8346056
150	0.2	0.84061697	0.83846154	0.83953787
250	0.3	0.84050633	0.85128205	0.84585987
250	0.6	0.83678756	0.82820513	0.83247423
250	0.1	0.85051546	0.84615385	0.84832905

**Pruebas con Regresión Logística**

Costo de error de entrenamiento	Precision	Recall	F 1
0.6	0.842	0.792	0.816
0.8	0.842	0.792	0.816
0.4	0.844	0.790	0.816
0.2	0.840	0.792	0.815
0.5	0.838	0.795	0.816
0.1	0.823	0.810	0.817

Los mejores resultados de las métricas obtenidas por cada una de las técnicas aplicadas y sobre el conjunto de 74 componentes se muestran a continuación, así como el gráfico 5 Análisis ROC.

- **Redes Neuronales**

**Tabla 8 Métricas para Redes Neuronales**

Precision	Recall	F 1
0.851	0.846	0.848

- Máquinas de Soporte Vectorial

**Tabla 9 Métricas para Maquinas de Soporte Vectorial**

Precision	Recall	F 1
0.831	0.808	0.819

- Regresión Logística

**Tabla 10 Métricas para Regresión Logística**

Precision	Recall	F 1
0.823	0.810	0.817




Gráfico 5 Análisis ROC

**Conclusión**

Inicialmente se utilizó el análisis de componentes principales para reducir la dimensionalidad del conjunto de datos destinado para entrenamiento. Para el proceso de entrenamiento y validación se aplicaron diferentes técnicas de machine Learning asignando diferentes valores de parámetros en cada una de ellas, luego se evaluó su desempeño utilizando las medidas precisión, recall y F1. El mejor F1 con un 85% se obtuvo con las Redes Neuronales con 250 neuronas en la capa oculta, factor de regularización=0.1 y 1000 iteraciones aplicados al conjunto de datos con 74 componentes principales.

También se tuvo en cuenta al análisis ROC, mostrado en el gráfico 5, en este se observa un desplazamiento de la curva hacia arriba y hacia a la izquierda, tendiendo a una probabilidad de clasificación correcta del 85% con las redes neuronales, el cual fue el clasificador que muestra mayor área bajo la curva.

### 4.3 Pruebas

Para la fase de pruebas utilizamos el conjunto de datos predeterminado para ello, este conjunto corresponde al 20% de los datos del conjunto original, el cual contiene 241 observaciones y 146 variables. Las variables que se tuvieron en cuenta fueron las mismas variables identificadas en la recolección de datos y las utilizadas en el proceso de análisis de componentes.

Antes de iniciar el proceso de prueba con la técnica escogida y con el objetivo de tener el conjunto de datos reservado para este fin con las mismas condiciones con que se obtuvo el conjunto de datos para entrenamiento y validación, se transformaron los datos para obtener 74 componentes principales (número de componentes principales obtenidos al aplicar análisis de componentes principales sobre el conjunto de entrenamiento explicado en la sección 4.1). La transformación consistió en normalizar el conjunto de datos de prueba y luego multiplicarlo por la matriz de pesos (matriz formada por los 74 componentes escogidos como columnas y 146 filas correspondientes a las variables del conjunto original) obtenida en el análisis de componentes realizado sobre el conjunto de entrenamiento, el resultado de estas operaciones fue un conjunto de pruebas con 74 componentes principales y 241 observaciones.

Teniendo en cuenta que la técnica escogida fue la red neuronal, Perceptron Multicapa, se inició el proceso de prueba utilizando los datos del conjunto de datos de prueba. Los valores de las métricas obtenidos se muestran en la tabla 11, donde se observa un F1 de 84% muy parecido al resultado obtenido en la etapa de entrenamiento y validación.

**Tabla 11 Métricas para las Redes Neuronales con los Datos de Prueba**

<b>Precision</b>	<b>Recall</b>	<b>F1</b>
0.89	0.81	0.84

Los valores obtenidos en las métricas para la clase 1, generan resultados satisfactorios, F1= 84% , 89% en precision y un recall de 81%.



## 5. CONCLUSIONES Y TRABAJOS FUTUROS

### 5.1 Conclusiones

La clasificación de las urgencias en las clínicas de la ciudad es un problema que va en aumento, pero como se ha demostrado durante el desarrollo de esta investigación desde diferentes perspectivas, podemos aportar soluciones tendientes a la mejora continua del proceso de clasificación para el ingreso de los pacientes en un Departamento de Urgencias.

Dentro del proceso de división de la sala de urgencia de la Clínica en dos áreas fundamentales, en área de cuidados mínimos y área de alta complejidad, la construcción del formato “Escalas de Valoración en Pediatría” es el pilar que ayudará a Pediatras, Residentes, Internos, Rurales y Enfermeras Licenciadas, a optimizar la valoración realizada a sus pacientes, aspecto fundamental teniendo en cuenta que los pacientes tratados son niños y que la gran mayoría no alcanza a expresar lo que realmente sienten, además, ayudará a mantener un criterio objetivo dentro del cuerpo médico.

Si bien es cierto que las escalas de valoración pediátrica nos ayudaron a identificar las variables a utilizar en esta investigación, también se debe tener en cuenta que el Hospital Napoleón Franco Pareja – “Casa del Niño”, es una fundación que cobija a los niños de la clase más necesitada de Cartagena, y por ellos existen muchas otras variables que afectan e influyen actualmente sobre la decisión que toma un médico, de hospitalizar o no un

paciente, por ello en trabajos futuros se deberá hacer un estudio preliminar, que permita identificar todas estas variables y adicionarlas a los procesos ejecutados en esta investigación, lo que ayudará a mejorar los resultados. Además de la identificación de otras variables también se notó durante la investigación, la escases de observaciones para la clase 1: alta complejidad, así como la poca y en algunos casos nula, recolección de datos para algunas variables, las cuales fueron anuladas de la investigación, esto se debió al poco tiempo de recolección de datos, ya que aunque fue una recolección prospectiva, hay enfermedades como Sepsis Meningococica, de la que pueden presentarse uno o dos casos en el año. También se detectó la anulación de variables, porque por su severidad cuando un niño la presenta, se trata como alta complejidad sin tener que pasar por un proceso de clasificación. El inicio de este trabajo en el departamento de urgencias puede ser considerado la primera fase de muchas investigaciones que de seguro se adelantarán para reforzar este Departamento, por ello, en trabajos futuros se debe aumentar el número de observaciones para la clase 1, actividad fácil de conseguir, porque el formato que se estableció para la recolección de datos, hace parte del procedimiento de clasificación de pacientes en el Hospital.

Un aspecto para destacar, fue la utilización del análisis de componentes principales, que permitió disminuir de 145 variables a 74 componentes principales, esto permitió disminuir la dimensionalidad del conjunto de datos sin poner en riesgo los resultados esperados, además utilizando todos los criterios identificados para evaluar el nivel asistencia de un paciente en la Urgencia.

Durante el desarrollo de esta investigación se realizaron pruebas con varias técnicas, como son, Regresión Logística, Maquinas de Soporte Vectorial y Redes Neuronales, durante las pruebas se notó siempre que los mayores valores de la métricas fueron obtenidas por las redes neuronales, luego le seguían las máquinas de soporte vectorial y por último la regresión logística. Cabe resaltar, que las máquinas de soporte vectorial superaron a la Regresión logística solo con la función polinomial hasta grado 3, después de este grado, se obtuvieron resultados pocos satisfactorios, también sucedió con la función de base radial, aunque con esta última se alcanzaron mejor resultados pero no llegaron a superar a la función polinomial de grado 3. Además se observó que los resultados de validación y pruebas están muy cercanos, no hay evidencia de overfitting.

Es claro que el conocimiento y la formación de un médico es el eje fundamental para un diagnóstico, pero como hemos visto en las investigaciones mencionadas en el estado del arte y en el capítulo “Generalidades”, el uso herramientas que involucren técnicas de Machine Learning en el campo de la medicina han dado muy buenos resultados, y como se observó en el desarrollo de esta investigación, las redes neuronales hacen un aporte importante a la hora de utilizar estas herramientas en la toma de decisiones, aunque también pueden ser considerada una herramienta para el entrenamiento de Residentes e Internos, cuya rotación en el Hospital es alta, esto ayudará en la reducción del tiempo de espera de los paciente por una atención debido a una buena clasificación, y agilizará la curva de aprendizaje al vincular a Residentes e internos dentro del Departamento de Urgencias de la clínica.

## 5.2 Trabajos Futuros

Para que los trabajos futuros en esta área tengan un aporte significativo al trabajo ya realizado a partir de esta investigación, se deben seguir aplicando esfuerzos para obtener datos con calidad dentro de la historia clínica de cada paciente, para ello se debe contar con que el médico tenga en cuenta la importancia de la información relacionada con aspectos socio-económicos y con los criterios clínicos definidos como base para la clasificación a realizar.

Se debe seguir ampliando el formato construido, “Escala de Valoración en Pediatría” para que abarque un mayor porcentaje, los diagnósticos realizados en Urgencias y establecer procesos de auditoria dirigidos por el Departamento de Calidad del Hospital Napoleón Franco Pareja – “Casa del Niño”, que permitan verificar y a la vez garantizar la confiabilidad de la información en el proceso de diligenciamiento del formato.

También sería interesante proponer en trabajos futuros que en estos apliquen la metodología utilizada en esta investigación para la construcción de herramientas que incluyan técnicas de Machine Learning que apoyen la implementación y uso del enfoque Fast Track para mejorar la atención en la urgencia. Además, partir del formato establecido, obtener un conjunto de datos más grandes que incluyan las variables que se eliminaron por falta de muestra y sobre todo que se amplíen las muestras de la clase “1” esto mejoraría el proceso de entrenamiento de las técnicas y se obtendrían mejores

resultados, volver a aplicar las técnicas Machine Learning escogidas en esta investigación y adicionar otras, a fin de obtener mejores resultados.

Por último se debe considerar ampliar el formato establecido para la recolección de datos incluyendo aquellas variables socioeconómicas que afectan la decisión de hospitalización de un paciente e incluir otras escalas para que abarquen en un mayor porcentaje, los diagnósticos realizados en Urgencias.

## REFERENCIAS

- A. Trisancho Garzón, E. Pino de Moya, M. Herrera Carranza, F. Caballero García, F. J. Martínez Marcos,. (2001). Área de Cuidados Mínimos. Un complemento. *emergencias*(13), 320-324.
- Adolfo González, M. A. (2000). Redes neuronales para identificación y predicción de series de tiempo. *Revista del Centro de Investigación. Universidad La Salle*, 4(14), 45-65.
- Agustin, S. D. (2003). Aplicación de las Redes Neuronales Artificiales a la Predicción del Resultado a Corto, Medio y Largo Plazo del Transplante Renal Pediátrico. *Cibernetia - Tesis Doctoral - Facultad de medicina i Odontologia*.
- Belén Guadalupe Barboza, P. F. (2007). Fiebre si foco en niños de 0-36 meses. *Revista de Posgrado de la Via Cátedra de Medicina*.(173).
- Beltrán, R. (2008). Complejidad de Modelos: Sesgo y Varianza.
- Bohada, M. J. (2011). Modelado de Conocimiento en la Asistencia Médica. *Revista Colombiana de, Volumen 2(-Número 18)*, 102-109.
- Campuzano, A. C. (2004). Bronquiolitis. *Pediatr Integral*, VIII(1), 4956.
- Claudia X. Mazo\*, O. F. (2010). PESPAD: una nueva herramienta para la predicción de la estructura secundaria de la proteína basada en árboles de decisión. *Ingeniería y Competitividad*, , 12(2), 9-22.
- Concha, M. F. (2012). Hybrid Support Vector Machines to Classify Traffic Accidents in the Región Metropolitana de Santiago. *Journal of Technological Possibilism*, 43-57.

- Contrara, E. O. (2011). Implementación de una Red Neuronal para la Detección de eventos de Apneas-Bradycardias en Neonatos. *Maestría en ingeniería Biomédica - Universidad Simón Bolívar*.
- Cubas, S. V. (2010). *Tesis Doctoral: Arquitectura de Búsqueda Basada en Tecnicas Soft Computing para la Resolucion de Problemas Combinatorios en Diferentes Dominios de Aplicacion*. Valencia.
- De la Hoz Manotas, A. K.-P.-P. (2013). Técnicas de ML en medicina cardiovascular. *Memorias. Desarrollo Humano, 11(20), 41-46*.
- DíazVazquez. (2004). Mesa Redonda: Actualización en Urgencias de Pediatría. *BOLETÍN DE LA SOCIEDAD DE PEDIATRÍA DE ASTURIAS, CANTABRIA, CASTILLA Y LEÓN, 44(188)*.
- F. del Campo Matías, J. d. (2008). APLICACIÓN DE UNA RED NEURONAL A LAS SEÑALES DE SATURACIÓN DE OXÍGENO Y DEL TIEMPO DE TRÁNSITO DE PULSO COMO AYUDA DIAGNÓSTICA EN EL SÍNDROME DE APNEA DEL SUEÑO. *XLI CONGRESO NACIONAL DE LA SEPAR, 44, 177 - 216*.
- F. Malmierca Sánchez, J. P. (2008). Curso de Formación Continuada en Dolor en Pediatría.
- Fernández, D. Y. (2009). *Valoración y tratamiento del dolor en Urgencias de Pediatría*. Barcelona: Hospital Sant Joan de Déu (Barcelona).
- Fernández, J. M. (2003). Boosting Con Redes Neuronales RBF. Análisis Sesgo - Varianza en un problema de Clasificación. *VI Congreso Galego de Estatística e Investigación de Operacións*. Universidad de Vigo.

Freitas, D. A. (2002). Data Mining and Knowledge Discovery With Evolutionary algorithms. En D. A. Freitas. Springer.

García, M. M. (2007). Capítulo 6 Modelos de Estimación Software basado en técnicas de Aprendizaje Automático. En I. R. Javier Tuya, *Técnicas Cuantitativa para la Gestión en la ingeniería del software*. Netbiblo.

Gerard FitzGerald, George A Jelinek, Deborah Scott, Marie Frances Gerdtz. (2009). Emergency department triage revisited. *Emerg Med J*.

Homero Rendón-García, G. C.-E.-A. (2013). Criterios de Alto Riesgo en Neutropenia Febril de Niños con Leucemia Aguda Linfoblástica. *30(1)*, 2-7.

Hugo A. Fajardo Rodríguez, J. Q. (2005). Escalas de Predicción e Infección de Sitio Quirúrgico en 15 625 Cirugías 2001-2003. *Rev. Salud pública.*, 7, 89 -98.

Hugo Galán Asensio, A. M. (s.f.). Inteligencia artificial. Redes neuronales y Aplicaciones. Madrid.

Hugo Paganini, M. E. (2011). Diagnóstico y tratamiento de la neutropenia febril en niños con cáncer. *Revista Chilena de Infectología Pediátrica(20)*, 10-38.

J Considine, M. K. (2008). Effect of emergency department fast track on emergency department length of stay: a case-control study. *Emerg Med J*, 25(12).

J. J. Aguilera, M. D. (s.f.). [http://sci2s.ugr.es/keel/pdf/keel/congreso/agu03\\_maeb03.pdf](http://sci2s.ugr.es/keel/pdf/keel/congreso/agu03_maeb03.pdf).

(Ministerio de) Obtenido de

[http://sci2s.ugr.es/keel/pdf/keel/congreso/agu03\\_maeb03.pdf](http://sci2s.ugr.es/keel/pdf/keel/congreso/agu03_maeb03.pdf)

J.A. Souto Rubio, J. L. (2006). Síndrome febril sin focalidad, Unidad de Cuidados Intensivos Pediátricos, Hospital Infantil Virgen del Rocío. Sevilla. *Pediatr Integral*, X(4), 255 - 262.



Jordan Peck, Stephan Gaehde, James Benneyan. (2011). *Using Precision to Improve Patient Flow in a Health Care Delivery Chain*. Obtenido de DSpace @Mit:

<http://hdl.handle.net/1721.1/84017>

Jorge Pérez Matera, M. (2012). Neutropenia febril en pediatría. *Precop SCP*, 12(3), 33-45.

José Cristóbal Buñuel Álvarez, A. E.-L. (2013). Guía de Práctica Clínica sobre el Manejo de la Enfermedad Meningocócica Invasiva. Ministerio de Sanidad, Servicios Sociales e Igualdad.

José Otero, L. S. (s.f.). Diseños experimentales y tests estadísticos, tendencias actuales en Machine Learning.

Juan Casado flores, A. S. (1997). *Coma en Pediatría diagnóstico y tratamiento*. Madrid - España: Dias de Santos S.A.

Judith W Dexheimer, L. E. (2007). Comparing Decision Support Methodologies for Identifying Asthma Exacerbations.

Justin E. Brown, N. C. (2011). Towards a Physiology-Based Measure of Pain: Patterns of Human Brain Activity Distinguish Painful from Non-Painful Thermal Stimulation. *Plos One*(0024124).

Kang Shouqiang, W. Y. (octubre 2013). A Method of Optimizing Kernel Parameter of Sphere Structured Support Vector Machine. 8(10).

Liu, L. T. (2005). Bias Analysis in Text Classification for Highly Skewed Data. Arizona State University: Department of Computer Science & Engineering.

**Leonardo R. Morelli.** Adaptación de arquitecturas profundas a problemas no estacionarios. 2013.

Marek Laskowski, Robert D. McLeod\*, Marcia R. Friesen, Blake W. Podaima, Attahiru S. Alfa. (2009). Models of Emergency Departments for Reducing Patient. *ABM and Queuing Models for EDs, 4.*

María M. Abad-Grau, J. S. (2008). Aplicación de Redes Bayesianas en el Modelado de un Sistema Experto de Triage en Servicios de Urgencias Médicas. *Biomedical Informatics.*

María N. Moreno García\*, L. A. (s.f.). Aplicación de Técnicas de Minería de Datos en la Construcción y Validación de Modelos Predictivos y Asociativos a Partir de Especificaciones de Requisitos de Software. Universidad de Salamanca. Departamento de Informática y Automática.

Méndez, D. G. (2008). Modelado y Simulación del comportamiento Neurológico del Tracto Urinario Inferior. Sistema de Ayuda al diagnóstico. *Tesis Doctoral Universidad de Alicante.* Departamento de Tecnología informática y Computación.

Ministerio de la Protección Social. (2009 3a Edición). *Guía para Manejo de Urgencias tomo III.* Bogotá D.C Colombia.

Morelli, L. R. (2013.). Adaptación de arquitecturas profundas a problemas no estacionarios. .

Moreno Villamil, E. (-M. (s.f.). UN MODELO PARA DIAGNOSTICO DE PIELONEFRITIS AGUDA EN NIÑOS BASADOS EN REDES NEURONALES: UN ACERCAMIENTO AL FUTURO DE LAS HERRAMIENTAS DE APOYO EN EL DIAGNOSTICO CLINICO. *24th INTERNATIONAL*

*CONGRESS OF PEDIATRICS CANCUN, MEXICO AUGUST 15 – 20, 2004 RESEARCH PAPER.*

Universidad de El Bosque, Fundación Cardioinfantil.

Neal, R. (2014). *Assignment No. 3 del curso STA 414/2104: Statistical Methods for Machine Learning and Data Mining, Universidad de Toronto.* Obtenido de <http://www.utstat.utoronto.ca/~radford/sta414/ass3.pdf>

Ng, A. (2010). *Notas de la clase "Dimensionality Reduction - Advice for applying Principal Component Analysis", curso Machine Learning Stanford - Couseara.* Obtenido de <https://d396qusza40orc.cloudfront.net/ml/docs/slides/Lecture14.pdf>

Olabe, X. B. (s.f.). *Redes Neuronales Artificiales y sus Aplicaciones.*

Otero, V. R. (s.f.). *Reconocimiento de Localizaciones mediante Máquinas de Soporte Vectorial.* Madrid - España: Escuela Politécnica Superior Ingeniero Industrial.

Payam Refaelizadeh, L. T. (2008). *Cross-Validation.* Arizona State University: File Path://ppdys1108/Womat3/Production/PRODENV/0000000005/0000008302/0000000016/.

Pervys Rengifo Rengifo, L. J. (2010). *Al Interior de una Máquina de Soporte Vectorial. Revista de Ciencias Universidad del Valle, 14, 73-85.*

Pilar González Martín, A. D. (s.f.). *UNA APLICACIÓN DEL ANÁLISIS DE COMPONENTES PRINCIPALES EN EL ÁREA EDUCATIVA. (I. d. Sociales, Ed.) Revista de Economía(9), 55 - 72.*

Posee, M. G. (s.f.). *Introducción a las Redes de Neuronas Artificiales.* tutorial, Universidad da Coruña, Tecnologías de la información y las Comunicaciones.

Prieto, A. (2012). *Desarrollan un sistema informático que ayuda al diagnóstico precoz del Alzheimer*. Obtenido de [www.saludymedicina.org](http://www.saludymedicina.org):

[http://www.saludymedicina.org/web/ventana\\_del\\_paciente/desarrollan-un-sistema-informatico-que-ayuda-al-diagnostico-precoz-del-alzheimer](http://www.saludymedicina.org/web/ventana_del_paciente/desarrollan-un-sistema-informatico-que-ayuda-al-diagnostico-precoz-del-alzheimer)

Richard J. Holden. (2011). Lean Thinking in Emergency Departments: A Critical Review. *Annals of Emergency Medicine*, 57(3).

Sebastián Maldonado, R. W. (2012). Modelos de Selección de Atributos para Support Vector Machines. *REVISTA DE INGENIERIA DE SISTEMAS*, XXVI.

Sellero, C. S. (2008 - 2009). Análisis multivariante - Master en Técnicas Estadísticas.

Sven Oredsson, H. J. (2011). A systematic review of triage-related. *Trauma, Resuscitation and Emergency Medicine*, 9.

Sven Oredsson, H. J. (2011). A systematic review of triage-related interventions to improve patient flow in emergency departments. *Trauma, Resuscitation and Emergency Medicine*.

Torres, L. C. (s.f.). EL Perceptron - Redes Neuronales Artificiales. *Inteligencia Artificial, Facultad de Ingeniería de Sistema UNAL*.

Vieyra, M. V. (2013). Análisis de componentes principales en imágenes de Teledetección. Argentina.

W.T. Lin, Y. W. (2011). Analysis by data mining in the emergency medicine triage database at a Taiwanese. *Expert Systems with Applications*, 38, 11078 - 11084.

Wilmer H. Rujas V., J. F. (2007). Análisis y Supervisión de la Señal Cardíaca con Transmisión. *Red de Revistas Científicas de América Latina, el Caribe, España y Portugal Sistema de Información Científica*, 151-156.

Wojtek Michalowski, S. W. (s.f.). *Development of a Decision algorithm to Support Emergency Triage of Scrotal pain and its Implementation in the Met System.*

Yaser S. Abu-Mostafa, M. M.-I.-T. (2012). *Learning From Data*. páginas 173 - 177.

Yoon, P. (2003). Emergency Department Fast-Track System. *HTA Initiative*(10).

ANPÉNDICE


1. Formato Escalas de Valoración en pediatría

NOMBRE					
EDAD					
SEXO					
IDENTIFICACION					
DIRECCION					
<b>ROCHESTER PARA PACIENTES &lt; 90 DIAS (fiebre sin foco) Define pacientes con bajo riesgo de infección bacteriana</b>					
CRITERIOS CLINICOS			SI	NO	
INFANTE CON APARIENCIA GENERALMENTE BUENA					
INFANTE PREVIAMENTE SALUDABLE					
NACIMIENTO A TERMINO					
NO TTO ANTIMICROBIANO PERINATAL					
NO TTO ANTIMICROBIANO PREVIO					
NO HOSPITALIZACION PREVIA					
NO TTO PARA HIPERBILIRRUBINEMIA INEXPLICADA					
NO ENFERMEDAD CRONICA SUBYACENTE					
NO HOSPITALIZACION MAS PROLONGADA QUE LA MADRE					
AUSENCIA DE SIGNOS EVIDENTES DE INFECCIÓN DE PIEL,TEJIDOS BLANDOS, HUESOS ARTICULACIONES U OÍDOS					
LEUCOCITOS EN SANGRE PERIFÉRICA DE 5000-15 000/MM3					
ABASTONADOS < 1500/MM3					
< 10 LEUCOCITOS POR CAMPO EN SEDIMENTO URINARIO.					
< 5 LEUCOCITOS POR CAMPO EN EXTENSIÓN DE HECEAS (DIARREA)					
<b>CRITERIOS DE ROCHESTER PARA PACIENTES &gt; 90 DIAS</b>					
NIÑO PREVIAMENTE SANO					
SIN SIGNOS DE FOCALIDAD					
NO SIGNOS DE TOXICIDAD DISTEMICA*					
RECUENTO DE LEUCOCITOS ENTRE 5-15000 MM3					
UROANALISIS < 5 LEUC X CAMPO					
* <b>SIGNOS DE TOXICIDAD SISTEMICA:</b> ALTERACION DEL ESTADO DE CONCIENCIA, DIFICULTAD RESPIRATORIA, TAQUICARDIA, BRADICARDIA, CIANOSIS, PALIDEZ EXTREMA, LLENADO CAPILAR > 3 SEG, PIEL MARMOREA Y FRIA, DISTENSION ABDOMINAL.					
<b>DEBEN CUMPLIRSE SIEMPRE PARA ESTABLECER QUE ES UN PACIENTE DE BAJO RIESGO</b>					
<b>YIOS PARA PACIENTES &lt; 90 DIAS (fiebre sin foco) Permite identificar riesgo de enfermedad bacteriana Grave</b>					
PERFUSION PERIFERICA	SONROSADO, EXTREMIDADES CALIENTES	1	EXTERMIDADES FRIAS MOTEADAS	2	PÁLIDO, SHOCK 3
ESTADO/ESFUERZO RESPIRATORIO	NO DETERIORO/VIGOROSO	1	COMPROMISO RESPIRATORIO LEVE-MODERADO (FR:>60), RETRACCIONES O QUEJOSO	2	DIFICULTAD RESPIRATORIA GRAVE ESFUERZO RESPIRATORIO INADECUADO, APNEA , FALLO RESPIRATORIO 3
RESPUESTA SOCIAL	SONRÍE O NO IRRITABLE	1	IRRITABLE, CONSOLABLE	2	IRRITABLE, INCONSOLABLE 3
<b>INTERPRETACION: &lt; 7 NO CRITERIOS DE SEVERIDAD / &gt; 7 SEVERIDAD</b>					
<b>YALE PARA PACIENTES ENTRE 3-36 MESES (fiebre sin foco) Permite identificar riesgo de enfermedad bacteriana Grave</b>					
	NORMAL(1)		MODERADA (3)		GRAVE (5)
LLANTO	FUERTE/NO LLORA		SOLLOZO		GEMIDOS
REACCION A LOS PADRES	DETIENE EL LLANTO		LLANTO CASI CONTINUO		LLANTO PERMANENTE
CONCIENCIA	SE MANTIENE O DESPIERTA RAPIDO		SOMNOLIENTO O SE DESPIERTA CON DIFICULTAD		NO SE DESPIERTA

COLOR	ROSADO		ACROCIAANOSIS O PALIDEZ DISTAL		PALIDO, CIANOTICO O MOTEADO		
HIDRATACION	NORMAL		BOCA SECA		MUCOSAS SECAS OJOS HUNDIDOS		
ESTIMULOS SOCIALES	SONRIE		SONRISA BREVE		NO SONRIE, ANSIOSO O INEXPRESIVO		
<b>INTERPRETACION:</b> <10 NORMAL /11-16: OBSERVACIÓN DOMICILIARIA /11-16:INGRESO A OBSERVACION (EXÁMENES COMPLEMENTARIOS) > 16: INGRESO HOSPITALARIO CON ESTUDIOS COMPLETOS DE SEPSIS							
<b>PACIENTE CON SINTOMAS RESPIRATORIOS:</b>							
<b>WOOD-DOWNES MODIFICADA POR FERRES (Paciente que ingresa con sibilancias – Bronquiolitis y no se dispone de pulsioximetria)</b>							
SIBILANCIAS	0. NO		1. FINAL DE LA ESPIRACION		2.TODA LA ESPIRACION	3. INSPIRACION Y ESPIRACION	
TIRAJES	0.NO		1.SUBCOSTAL + INTERCOSTAL INFERIOR		2. PREVIO MAS SUPRACLAVICULAR + ALETEO NASAL	3.PREVIO+INTERCOSTAL SUPERIOR + SUPRAESTERNAL	
ENTRADA DE AIRE	0.BUENA SIMETRICA		1.REGULAR SIMETRICA		2. MUY DISMINUIDA	3.TORAX SILIENTE (AUSENCIA DE SIBILANCIAS)	
CIANOSIS	0.NO		1.SI				
FR	0. < 30 RPM		1. 31-45 RPM		2. 46-60 RPM	3. > 60 RPM	
FC	0. <120 LPM		1. >120 LPM				
<b>INTERPRETACION:</b> LEVE: 1-3; MODERADA: 4-7; GRAVE: 8 O MÁS.							
<b>WESTLEY (paciente que ingresa con estridor no se dispone de pulsioximetria)</b>							
ESTRIDOR	0.NO		1. AL AGITARSE		2. EN REPOSO		
TIRAJE	0. NO		1. LEVE		2.MODERADO	3. SEVERO	
VENTILACIÓN	0. NORMAL		1. DISMINUIDA		2.MUY DISMINUIDA		
CIANOSIS	0. NO		4. AL AGITARSE		5. EN REPOSO		
CONCIENCIA	0.NORMAL		5. ALTERADA				
<b>INTERPRETACION:</b> LEVE: 2 O MENOS; MODERADA:3-8; GRAVE: 8 O MAS							
<b>WETSLEY MODIFICADO POR MINTEGUI (Paciente que ingresa con estridor y se dispone de pulsioximetria)</b>							
ESTRIDOR	0.NO				1. AUDIBLE EN REPOSO CON FONENDO	2. AUDIBLE EN REPOSO SIN FONENDO	
RETRACCIONES SUBCOSTALES Y SUPRAESTERNALES	0. NO				1. LEVES	2. MODERADA SEVERA	
ENTRADA DE AIRE EN LOS PULMONES	0. NORMAL				1. DISMINUCIÓN LEVE	2. DISMINUCIÓN LEVE - MODERADA	
SAT O2	0. >=95				1. <=94		
<b>INTERPRETACION:</b> LEVE: 2 O MENOS; MODERADA:3-4; GRAVE: 5 O MAS							
<b>INDICE PULMONAR DE SCARFONE (Paciente que ingresa con sibilancias – crisis asmática y se dispone de pulsioximetria)</b>							
PUNTOS		FR >6 AÑOS	FR < 6 AÑOS	SIBILANCIAS	COCIENTE INS/ESP	MUSCULOS ACCESORIOS	SAT O2
0		< 21	< 31	AUSENTES	2-1	AUSENTE	99-100
1		21-35	31-45	FINAL ESPIRACION	1-1	+	96-98
2		36-50	46-60	TODA LA ESPIRACION	1-2	++	93-95
3		> 50	> 60	INSPIRACION Y ESPIRACION	2-3	+++	< 93
<b>INTERPRETACION:</b> LEVE: 1-8; MODERADA: 9-13; GRAVE: 14-15.							
<b>GLASGOW &gt; 3 AÑOS (Valoración del nivel de conciencia)</b>							
APERTURA DE OJOS	1.NINGUN A		2. AL DOLOR		3. A LA VOZ	4.ESPONTANEA	
VERBAL	1.NINGUN A		2. SONIDOS INESPECIFICOS		3. PALABRAS INADECUADAS	4. CONFUSO	5. ORIENTADO
MOTORA	1.NINGUN A		2. EXTENSION ANORMAL		3. FLEXION AL DOLOR	4. RETIRADA AL DOLOR	5.LOCALIZA DOLOR
<b>INTERPRETACION:</b> 13-15 LEVE; 9-12: MODERADO; >12: SEVERO							
<b>RAIMONDI – GLASGOW MODIFICADA &lt; 3 AÑOS</b>							
RESPUESTA		1. PUPILAS FIJAS Y		2.PUPILAS FIJAS Y	3. MEO INTACTOS.		4. PERSIGUE CON LA

OCULAR	MEO* PARALIZADOS	MEO AFECTADOS	PUPILAS REACTIVAS	MIRADA
RESPUESTA VERBAL	1. APNEA	2. RESPIRACION ESPONTANEA	3. LLORA	
RESPUESTA MOTORA	1. FLACIDEZ	2. HIPERTONIA	3. ALEJAMIENTO DEL DOLOR	4. FLEXIONA Y EXTIENDE
*MEO: MUSCULOS EXTRAOCULARES.				
PUNTAJE MINIMO:3 – MAXIMO: 11				
<b>ESCALA DE COMA PARA NEONATOS</b>				
RESPUESTA MOTORA	0. FLACIDOS	1. ACTITUD QUE MIMETIZA DECORTICACION O DESCEREBRACION		
	2.MOVIMIENTOS ESTEREOTIPADOS ANTE ESTIMULOS	3. RETIRADA DEL MIEMBRO ESTIMULADO		
	4. MOVIMIENTOS DEBILES Y PEREZOSOS	5. MOVIMIENTOS ALTERNANTES SUAVES		
RESPUESTA OCULAR	0. RESPUESTA OCULOCEFALICA AUSENTE Y PUPILAS FIJAS	1. RESPUESTA OCULOCEFALICA ALTERADA		
	2. RESPUESTA OCULOCEFALICA INACTA	3. APERTURA DE LOS OJOS AL DOLOR		
	4. APERTURA ESPONTANEA DE LOS OJOS	5. FOCALIZA Y SIGUE EL ESTIMULO AL MENOS 30° HORIZONTALMENTE		
RESPIRACION Y VOCALIZACION	0. APNEA	1. RESPIRACION PERIODICA O ATAXICA		
	2. RESPIRACION ESPONTANEA	3. MUECA		
	4. GEMIDO O LLANTO DEBIL	5. LLANTO DE TONO NORMAL		
PUNTUACION MINIMA: 0 MAXIMA:15				
<b>SANTOLAYA (Alto o bajo riesgo de infección bacteriana invasora en episodios de neutropenia febril)</b>				
1.PCR >90 MG/L	2.LEUCEMIA MIELOIDE AGUDA	3.RECUENTO DE PLAQUETAS < 50.000 MM3	4.LEUCEMIA EN RECAIDA	5.RECAIDA DE TUMOR SOLIDO
6.HIPOTENSION ARTERIAL	7.LINFOMA NO HODKING B Y DE CELULAS GRANDES	8.MENOS DE 7 DIAS DESDE LA ULTIMA QUIMIOTERAPIA	9.NEUROBLASTOMA ETPA IV	10.LLA DE ALTO RIESGO
INTERPRETACION: <b>BAJO RIESGO</b> : AUSENCIA DE FACTORES DE RIESGO ; PRESENCIA DE ITEM 3 Y 8 COMO FACTOR UNICO <b>ALTO RIESGO</b> : DOS O MAS FACTORES DE RIESGO O PRESENCIA DE 1,2,4,5,6,7,9 ,10 COMO FACTOR UNICO				
<b>ESCALA DE GLASGOW MODIFICADA PARA SEPSIS MENINGOCOCICA</b>				
HIPOTENSIÓN (TA SISTÓLICA < 75 MM HG EN < 4 AÑOS; < 80 MM HG EN > 4 AÑOS)	3	GRADIENTE DE Tª PIEL/RECTO > 3°C O FRIALDAD CUTÁNEA 3		3
ECG < 8 O DISMINUCIÓN DE ≥ 3 PUNTOS EN 1 HORA	3	AUSENCIA DE MENINGISMO		2
EMPEORAMIENTO DURANTE LA ÚLTIMA HORA	2	EQUIMOSIS DISEMINADAS O LESIONES CRECIENTES		1
DÉFICIT DE BASES ≤ -8 MMOL/L	1			
INTERPRETACION: < 0 = 6: SEPSIS APARENTEMENTE NO GRAVE CON CRITERIOS DE MAL PRONOSTICO 7-8: SEPSIS MENINGOCÓCICA GRAVE. >10: MENINGOCOCEMIA FULMINANTE PRESUMIBLEMENTE MORTAL				
<b>CLASIFICACION DE ASA</b>				
I	PACIENTE NORMAL			
II	ENFERMEDAD SISTEMICA LEVE			
III	ENFERMEDAD SISTEMICA SEVERA QUE LIMITA LA ACTIVIDAD, NO INCAPACITANTE			
IV	ENFERMEDAD SISTEMICA SEVERA QUE ES UNA AMENAZA CONSTANTE PARA LA VIDA			
V	MORIBUNDO, NO SE ESPERA QUE SOBREVIVA SIN LA CIRUGIA			
ASA < 0 = 2 : PACIENTES DE BAJO RIESGO // ASA > 0 = 3: ALTO RIESGO				
<b>ESCALAS DE EVALUACIÓN DEL DOLOR – FISIOLÓGICO-CONDUCTUAL (1 MES A 3 AÑOS)</b>				
<b>PARÁMETRO</b>	<b>VALORACION</b>	<b>PUNTOS</b>		
<b>TAS BASAL</b>	<20%	0		
	20-30%	1		
	>30%	2		
<b>LLANTO</b>	AUSENTE	0		
	CONSOLABLE CON PALABRAS-CARICIAS	1		
	NO CONSOLABLE	2		

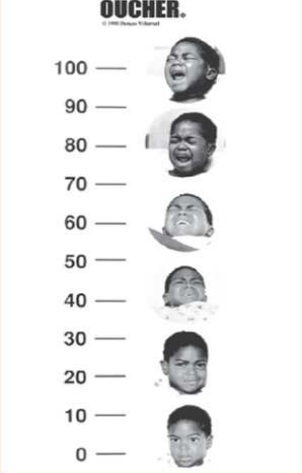


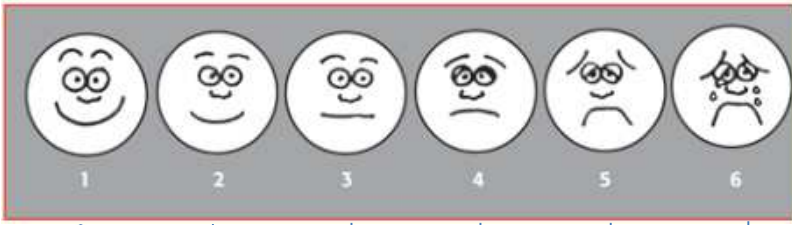
ACTIVIDAD MOTORA ESPONTANEA	DORMIDO-JUGANDO-TRANQUILO	0
	MODERADA-CONTROLABLE	1
	INTENSA-INCONTROLABLE	2
EXPRESION FACIAL		0
		1
		2
EVALUACION VERBAL (2-3 AÑOS)	NO EXPRESA DOLOR	0
	INCOMODO- DUELE SIN LOCALIZAR	1
	SE QUEJA Y LOCALIZA DOLOR	2
LENGUAJE CORPORAL (<2AÑOS)	DORMIDO – POSTURA NORMAL	0
	HIPERTONIA-MIEMBROS AGARROTADOS	1
	PROTEGE O TOCA ZONA DOLOROSA	2

INTERPRETACIÓN: 0=NO DOLOR; 1-2=LEVE;3-5=MODERADO; 6-8=INTENSO; 9-10= INSOPORTABLE

**SCALA DE LOS <AY> O DE OUCHER (NIÑOS 3 – 12 AÑOS) Y ESCALA DE DIBUJOS FACIALES (NIÑOS DE 5-12 AÑOS Y ADOLESCENTES)**

**OUCHER.**  
© 1998 Thomas Y. Barnard





↓  
**0**

↓  
**2**

↓  
**4**

↓  
**6**

↓  
**8**

↓  
**10**

**PUNTUACIÓN:** 0 ES SIN DOLOR, 2 DOLOR LEVE, 4-6 DOLOR MODERADO Y 8-10 DOLOR INTENSO

## 2. Guía para la utilización de las escalas en la urgencia

1. Paciente < de 90 días con fiebre sin foco: SI  NO 
  - BAJO RIESGO de infección bacteriana: ROCHESTER para pacientes < de 90 días
  - ALTO RIESGO de enfermedad bacteriana grave: YIOS para pacientes < de 90 días
2. Paciente > de 90 días con fiebre sin foco: SI  NO 
  - ROCHESTER para pacientes > de 90 días
  - YALE para pacientes entre 3-36 meses
3. Paciente con síntomas respiratorios (sibilancias) con probable bronquiolitis: SI  NO 
  - WOOD – DOWNES MODIFICADA POR FERRES
4. Paciente que ingresa con estridor en el cual sospecha CRUP (Laringotraqueobronquitis) SI  NO 
  - WESTLEY
  - WESTLEY MODIFICADO POR MINTEGUI
5. Paciente que ingresa por cuadro de sibilancias y sospeche Crisis Asmática SI  NO 
  - INDICE PULMONAR DE SCARFONE
6. Paciente con cuadro de trauma craneoencefálico o enfermedad sistémica grave donde quiera valorar nivel de conciencia SI  NO 
  - GLASGOW > 3 AÑOS
  - RAIMONDI - GLASGOW MODIFICADA < 3 AÑOS
7. Paciente neonato en coma SI  NO 
  - ESCALA DE COMA PARA NEONATOS
8. Paciente con cuadro clínico compatible con infección bacteriana invasora asociado a neutropenia febril SI  NO 
  - SANTOLAYA
9. Paciente con sepsis meningococcica SI  NO 
  - ESCALA DE GLASGOW MODIFICADA PARA SEPSIS MENINGOCOCICA

### SIEMPRE DEBE REALIZAR LA CLASIFICACION DE ASA

10. Paciente que ingresa con cuadro de dolor SI  NO 
  - ESCALAS DE EVALUACION DEL DOLOR – FISIOLÓGICO-CONDUCTAL (1 MES A 3 AÑOS)
  - ESCALA DE LOS <AY> O DE OUCHER (3-12 AÑOS)
  - ESCALA DE DIBUJOS FACIALES (5-12 AÑOS Y ADOLESCENTES)

### 3. Código Fuente

```

from sklearn.cross_validation import KFold

import numpy as np

import Orange

from sklearn import cross_validation

import xglib

from sklearn.metrics import classification_report

class PML:

    def __init__(self,inputs,hidden,output):

        #creación de red para clasificación...

        self._inputs=inputs

        self._hidden=hidden

        self._output=output

        self.network=xglib.mlpreater1(inputs,hidden,output,0,1)

    def learn(self,xinputs,youtput,weightdecay):

        xy=np.ones((xinputs.shape[0],xinputs.shape[1]+1))

        xy[:,0:xinputs.shape[1]]=xinputs

        xy[:,xinputs.shape[1]]=youtput

        xyz=xy.tolist()

        rep = xglib.mlptrainlbfgs(self.network,xyz,len(xy),weightdecay,5,0.01,1000)

```

```

def pred(self,xinput):
    xtest=xinput[0].tolist()
    ytest=[0]
    y = xalglib.mlpprocess(self.network, xtest, ytest)
    return y[0]

```

```

def pred1(self,xinput):
    yresul=np.zeros(xinput.shape[0])
    ytest=[xinput.shape[0]]
    for i in range(xinput.shape[0]):
        xtest=xinput[i].tolist()
        y = xalglib.mlpprocess(self.network, xtest, ytest)
        yresul[i]=y[0]
    return yresul

```

#cargar datos de entrenamiento y validación

\_aplicarcrossvalidationdatosdeentrenamientoyvalidacion=0

datareader = Orange.data.Table('i:\gisela\compentrenamiento.txt')

ds=np.array(datareader)

data=np.zeros((964,75))

for i in range(964):

    for j in range(75):

        data[i,j]=ds[i][j]

```
#Intanciar red neuronal.

neuralnetwork=PML(74,250,1)

#Aplicando validación cruzada!

if _aplicarcrossvalidationdatosdeentrenamientoyvalidacion==1:

    #Aplicar Cross validation

    kfold = cross_validation.KFold(data.shape[0], n_folds=10)

    xtrain=[]

    ytrain=[]

    ypred=[]

    MSEcv=np.zeros((10))

    _con=0

    for train, test in kfold:

        data_train=data[train]

        xtrain=data_train[:,0:74]

        ytrain=data_train[:,74]

        data_test=data[test]

        xvalid=data_test[:,0:74]

        yvalid=data_test[:,74]

    #Entrenar la red con los datos de validación

    neuralnetwork.learn(xtrain,ytrain,0.1)
```

```

#Predecir con los datos de validación.

ypred=neuronalnetwork.pred1(xvalid)

yground=[round(ypred[i],0) for i in range(ypred.shape[0])]

print classification_report(yvalid, yground)

MSEcv[_con]=np.average([(ypred[i]-y[i])**2 for i in range(y.shape[0])])

_con=_con+1

#Cargar los datos para test!

tablapesos=np.loadtxt('i:\gisela\pesoscomponentes.txt',skiprows=1,delimiter='\t')

tabladataest=np.loadtxt('i:\gisela\prueba.txt',skiprows=1,delimiter='\t')

#Extraer las columnas de entradas

datatest=tabladataest[:,0:tabladataest.shape[1]-1]

datestnormalizada=np.zeros((datatest.shape[0],datatest.shape[1]))

#Normalizando la tabla de test (x-media)/desviacion standar.

for col in range(datatest.shape[1]):

    media=np.average(datatest[:,col])

    desvstd=np.std(datatest[:,col])

    for fil in range(datatest.shape[0]):

        if desvstd==0:

            datestnormalizada[fil,col]=0

```

```
else:
```

```
    datestnormalizada[fil,col]=(datatest[fil,col]-media)/desvstd
```

```
#trasformar entradas en función de componentes principales!
```

```
datatransformada=np.dot(datestnormalizada,tablapesos)
```

```
#Adicionar columna de etiquetas.
```

```
datapred = tabladatatest[:,tabladatatest.shape[1]-1]
```

```
#Entrenar la red neuronal con todos los datos de entrenamiento!
```

```
xtrain=data[:,0:74]
```

```
ytrain=data[:,74]
```

```
neuronalnetwork.learn(xtrain,ytrain,0.1)
```

```
#Aplicar predicción sobre "dataparaanálisis":
```

```
ypred=neuronalnetwork.pred1(datatransformada)
```

```
yground=[round(ypred[i],0) for i in range(ypred.shape[0])]
```

```
print classification_report(datapred, yground)
```