

UNIVERSIDAD NACIONAL DEL ALTIPLANO - PUNO
FACULTAD DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA



**PREDICCIÓN DE RENDIMIENTO ACADÉMICO MEDIANTE
REGRESIÓN Y REDES NEURONALES EN LOS ESTUDIANTES DE
LA ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E
INFORMÁTICA DE LA UNIVERSIDAD NACIONAL
DEL ALTIPLANO - PUNO, 2015.**

TESIS

PRESENTADA POR:

Bach. HICLER EMERSON PAJA DOMINGUEZ

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO ESTADÍSTICO E INFORMÁTICO

PUNO – PERÚ

2017

UNIVERSIDAD NACIONAL DEL ALTIPLANO - PUNO
FACULTAD DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA

**PREDICCIÓN DE RENDIMIENTO ACADÉMICO MEDIANTE REGRESIÓN Y
 REDES NEURONALES EN LOS ESTUDIANTES DE LA ESCUELA
 PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA DE LA
 UNIVERSIDAD NACIONAL DEL ALTIPLANO - PUNO, 2015.**

TESIS

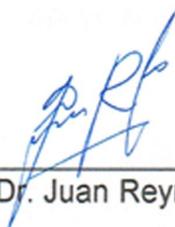
PRESENTADA POR:

Bach. HICLER EMERSON PAJA DOMINGUEZ

PARA OPTAR EL TÍTULO PROFESIONAL DE:
INGENIERO ESTADÍSTICO E INFORMÁTICO

APROBADA POR:



PRESIDENTE : 

 Dr. Juan Reynaldo Paredes Quispe

PRIMER MIEMBRO : 

 Dr. Vladimiro Ibañez Quispe

SEGUNDO MIEMBRO : _____
 Dr. Jose Oscar Huanca Frías

DIRECTOR DE TESIS : 

 M.C. Confesor Milam Vargas Valverde

ASESOR DE TESIS : 

 Dr. Reynaldo Sucari León

Área : Estadística
 Tema : Modelos predictivos uni y multivariables
 Fecha de sustentación : 18/09/2017

DEDICATORIAS

A Fabrizio, que es la razón de mi vida el tesoro más grande que Dios me regaló y el motivo del día a día.

A mis padres, Ines D. y Eugenio P., por su incomparable e incondicional apoyo, esfuerzo, y por creer en mí.

A Judith la madre de mi hijo por su respaldo y continuo apoyo.

A mis hermanas, Amercilda Q.E.P.D. que dios tenga en su santa gloria, Rosalvina y Maribel. Ustedes representan fuente de conocimiento exclusivo, gracias por hacerme sentir su apoyo siempre.

Hicler Emerson Paja Dominguez

AGRADECIMIENTOS

A Dios, por permitirme
alcanzar esta meta.

A los docentes por los
conocimientos impartidos en la
Escuela Profesional de Ing.
Estadística e Informática y a la
Universidad Nacional del Altiplano –
Puno.

A todos los que me
ayudaron en esta investigación.

Hicler Emerson Paja Dominguez

ÍNDICE

DEDICATORIAS	
AGRADECIMIENTOS	
INDICE	
RESUMEN -----	11
ABSTRACT -----	12
INTRODUCCIÓN -----	13
CAPÍTULO I PLAN DE INVESTIGACIÓN -----	15
1.1 PLANTEAMIENTO DEL PROBLEMA -----	15
1.1.1 Definición del problema -----	15
1.1.2 Formulación del Problema -----	16
1.2 OBJETIVOS -----	17
1.2.1 Objetivo General -----	17
1.2.2 Objetivos específicos -----	17
1.3 HIPÓTESIS -----	18
1.3.1 Hipótesis general -----	18
1.4 JUSTIFICACIÓN Y DELIMITACIÓN DE LA INVESTIGACIÓN -----	18
1.4.1 Justificación de la Investigación -----	18
1.4.2 Limitaciones de la Investigación -----	19
CAPÍTULO II MARCO TEORICO -----	20
2.1 ANTECEDENTES DE LA INVESTIGACIÓN -----	20
2.1.1 Antecedentes a nivel internacional -----	20
2.1.2 Antecedentes a nivel nacional -----	21

2.1.3	Antecedentes a nivel local -----	21
2.2	RENDIMIENTO ACADÉMICO -----	22
2.2.1	Definición de Rendimiento académico-----	22
2.2.2	Factores del Rendimiento Académico Universitario-----	25
2.3	REDES NEURONALES ARTIFICIALES-----	27
2.3.1	Definición de Redes Neuronales Artificiales -----	27
2.3.2	Elementos de una red neuronal artificial -----	34
2.3.3	Estructura de una red neuronal artificial-----	41
2.3.4	Ventajas de las redes neuronales artificiales -----	43
2.3.5	Clasificación de las RNA -----	44
2.3.6	Perceptrón Multicapa-----	48
2.3.7	Algoritmo Backpropagation. -----	50
2.3.8	Metodología de diseño de redes neuronales -----	53
2.4	REGRESIÓN LINEAL MÚLTIPLE -----	53
2.5	VALIDACIÓN DE LOS MODELOS DE PREDICCIÓN -----	62
2.6	DEFINICIÓN DE TÉRMINOS BÁSICOS -----	63
2.7	OPERACIONALIZACIÓN DE VARIABLES -----	66
CAPÍTULO III MÉTODOS Y MATERIALES-----		67
3.1	TIPO Y MÉTODO DE ESTUDIO -----	67
3.2	DISEÑO DE ESTUDIO -----	67
3.3	POBLACIÓN Y MUESTRA-----	67
3.4	MÉTODOS, TÉCNICAS E INSTRUMENTOS DE RECOPIACIÓN DE DATOS -----	69
CAPÍTULO IV RESULTADOS Y DISCUSIÓN DE LA INVESTIGACIÓN -----		74
4.1	LAS VARIABLES PREDICTORAS DEL RENDIMIENTO ACADÉMICO	74

4.1.1	Discusión de las variables.-----	74
4.1.2	Descripción de variables-----	81
4.1.3	Matriz de correlaciones de las variables-----	82
4.1.4	Selección de variables predictoras -----	83
4.2	MODELO DE REGRESIÓN LINEAL MÚLTIPLE APLICADO A LA PREDICCIÓN DEL RENDIMIENTO ACADÉMICO -----	84
4.2.1	Análisis de regresión lineal múltiple en R -----	84
4.3	MODELO DE REDES NEURONALES APLICADO A LA PREDICCIÓN DEL RENDIMIENTO ACADÉMICO-----	90
4.3.1	Selección de variables. -----	90
4.3.2	Recolección de datos.-----	90
4.3.3	Preparación de datos-----	91
4.3.4	Conjunto de entrenamiento, validación y prueba -----	92
4.3.5	Selección de la configuración interna -----	92
4.3.6	Criterio de evaluación -----	94
4.3.7	Entrenamiento de la red neuronal-----	94
4.3.8	Uso y análisis de redes predicción de rendimiento académico	95
4.4	ANÁLISIS DE LOS RESULTADOS DE LAS TÉCNICAS -----	97
4.5	DISCUSIÓN DE LOS RESULTADOS -----	98
	CONCLUSIONES-----	100
	RECOMENDACIONES Y SUGERENCIAS -----	101
	BIBLIOGRAFIA -----	102
	ANEXOS -----	105

ÍNDICE DE TABLAS

Tabla N° 01. Escala de rendimiento académico	24
Tabla N° 02. Clasificación de los valores de R^2	58
Tabla N° 03. Coeficiente Durbin - Watson	61
Tabla N° 04. Operacionalización de variables	66
Tabla N° 05. Número de estudiantes ingresantes matriculados por años	68
Tabla N° 06. Número de registros por semestre y periodo académico.....	68
Tabla N° 07. Técnicas e instrumentos de recopilación de datos	69
Tabla N° 08. Formato plan de estudios de la FINESI 2008-2012.	70
Tabla N° 09. Formato plan de estudios de la FINESI 2013-2018	71
Tabla N° 10. Historial de notas finales de los estudiantes.	72
Tabla N° 11. Plan de estudio homogenizado.....	73
Tabla N° 12. Datos para Regresión y Redes Neuronales.....	73
Tabla N° 13. Variables independientes considerados para los modelos	81
Tabla N° 14. Correlación entre todos los variables.....	82
Tabla N° 15. Matriz de significancia valor $p < 0.05$	83
Tabla N° 16. Resultados del ajuste del modelo de la asignatura 010-05.....	85
Tabla N° 17. Resultados del ajuste del modelo de la asignatura 009-05.....	86
Tabla N° 18. Predicción de las asignaturas 010-05 y 009-05	89
Tabla N° 19. MSE de las asignaturas 010-05 y 009-05	89
Tabla N° 20. Resultado del modelo de la asignatura de 010-05.....	95
Tabla N° 21. Resultado del modelo de la asignatura de 009-05.....	95
Tabla N° 22. Resultado de la predicción de Redes neuronales.....	96
Tabla N° 23. MSE de las asignaturas 010-05 y 009-05	96
Tabla N° 24. Error el modelo y de la predicción de dos cursos.	97
Tabla N° 25. Promedios de 2 cursos.	97

ÍNDICE DE GRÁFICOS

Gráfico N° 01: Características básicas de la neurona biológica	31
Gráfico N° 02: Modelo de Neurona Artificial Simple	32
Gráfico N° 03: Modelo de Neurona Artificial Estándar.....	33
Gráfico N° 04: Entrada y salida de una neurona <i>Uj</i>	35
Gráfico N° 05: Funciones de activación de una neurona artificial	40
Gráfico N° 06: Estructura jerárquica de un sistema basado en RNAs.....	42
Gráfico N° 07: Arquitectura simple de las RNAs.	45
Gráfico N° 08: Modelo de un perceptrón	49
Gráfico N° 09: Modelo de un perceptrón multicapa.....	50
Gráfico N° 10: Arquitectura Backpropagation.....	52
Gráfico N° 11: Promedio ponderado de acuerdo a las los promedios finales por periodo académico.....	74
Gráfico N° 12: Promedio ponderado acumulado hasta el semestre previo.	75
Gráfico N° 13: Efectividad de aprobación de acuerdo a la calificaciones del semestre previo.....	76
Gráfico N° 14: Promedio de efectividad de aprobación de acuerdo al rendimiento académico por periodo.....	76
Gráfico N° 15: Grado de dificultad de aprobación de acuerdo a la calificación obtenida en una asignatura en el semestre previo.....	77
Gráfico N° 16: Grado de dificultad de aprobación de acuerdo a la calificación obtenida en tres asignaturas.	77
Gráfico N° 17: Sumatoria de promedio de grado de dificultad de acuerdo a la calificación obtenida	78
Gráfico N° 18: Efectividad de aprobación de acuerdo a los créditos.....	79

Gráfico N° 19: Promedio de efectividad de aprobación de acuerdo a los créditos aprobados hasta el semestre previo.	79
Gráfico N° 20: Promedio Grado de dificultad de aprobación de acuerdo a los créditos de una asignatura en el semestre previo.	80
Gráfico N° 21: Promedio del grado de dificultad de aprobación de acuerdo a los créditos por semestre hasta el semestre previo	80
Gráfico N° 22: Normalidad de los residuos de la asignatura 010-05.	87
Gráfico N° 23: Normalidad de los residuos de la asignatura 009-05	88
Gráfico N° 24: Valores ajustados vs. Residuos estandarizados.....	88
Gráfico N° 25: Arquitectura para las asignaturas 009-05 y 010-05	93

RESUMEN

La presente investigación se realizó en la Facultad de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano de Puno, la cual tuvo como objetivo determinar la mejor técnica de predicción en el rendimiento académico utilizando regresión y redes neuronales en estudiantes de la Facultad mencionada. Para ello se utilizó una población que estuvo conformada por estudiantes matriculados durante los años 2009 al 2015; haciendo un total de 696 estudiantes. Se consideró muestreo intencional de cohorte entre los años 2009-2015, conteniendo 19334 registros de promedios finales de asignaturas. Se consideró 23 variables predictoras; de ellas 17 variables fueron seleccionados por el método stepwise para la asignatura 009-05 con un $R^2= 0.72$, 0.11 de error para los modelos, 0.37 de error para la predicción y 16 variables para la asignatura 010-05 con de $R^2= 0.92$, 0.96 de error para los modelos, 0.0032 de error para la predicción. Mientras que las RNA's Perceptrón multicapa, algoritmo backpropagation, con arquitectura de 3 capas en función de las mismas variables que fueron seleccionadas en regresión múltiple; en donde de ambos asignaturas mencionadas anteriormente obtuvieron promedios de 0.0558 de error para los modelos y 0.00081 de error para las predicciones. Finalmente se midieron los promedios los errores obteniendo que las RNA's es la mejor técnica en predicción; puesto que tienen una diferencia de 0.534 error en modelo y 0.1307 error en predicción respecto a la regresión.

Palabras clave: Predicción de Rendimiento Académico, Redes neuronales artificiales, Backpropagation, Regresión múltiple, Mínimos cuadrados.

ABSTRACT

The present research was carried out in the Faculty of Statistics and Computer Engineering of the National University of the Altiplano of Puno, which had as objective to determine the best prediction technique in the academic performance using regression and neural networks in students of the aforementioned Faculty. For this, a population that was formed by students enrolled during the years 2009 to 2015 was used; making a total of 696 students. Intentional cohort sampling was considered between the years 2009-2015, containing 19334 records of final averages of subjects. It was considered 23 predictor variables; Of these, 17 variables were selected by the stepwise method for the subject 009-05 with an $R^2 = 0.72$, 0.11 error for the models, 0.37 error for the prediction and 16 variables for the subject 010-05 with $R^2 = 0.92$, error 0.96 for the models, error 0.0032 for the prediction. While the Multilayer Perceptron RNAs, backpropagation algorithm, with 3-layer architecture based on the same variables that were selected in multiple regression; where of both subjects mentioned above they obtained averages of 0.0558 error for the models and 0.00081 error for the predictions. Finally, the averages were measured, obtaining that RNAs is the best prediction technique; since they have a difference of 0.534 error in model and 0.1307 error in prediction with respect to regression.

Keywords: Prediction of Academic Performance, Artificial Neural Networks, Backpropagation, Multiple Regression, Least squares.

INTRODUCCIÓN

La educación superior universitaria pública y privada peruana, actualmente enfrenta problemas en la calidad de la educación, reflejados en el rendimiento académico, la presente investigación se centró en la predicción de rendimiento académico mediante técnicas de regresión y redes neuronales, la predicción de eventos futuros es una fascinación del ser humano, desde su existencia a la actualidad existen técnicas sofisticados y se amplió su uso en diferentes áreas, en tanto el rendimiento académico universitario es un indicador de las capacidades del estudiante, que expresa lo que el estudiante ha aprendido a lo largo del proceso formativo. Por ejemplo el rendimiento académico de un estudiante están relacionados con la dificultad propia de algunas asignaturas, efectividad de aprobación de las asignaturas, el rendimiento académico previo, historial de los promedios finales de las asignaturas, efectividad de créditos académicos aprobados, con el fin de proponer modelos de predicción del rendimiento académico para identificar y mitigar a estudiantes con bajo rendimiento, se convierten en un factor clave de éxito para la gestión de las universidades con el propósito de preservar la buena reputación y mejorar en el rango entre Universidades.

Este trabajo se consideró de diseño cuasi-experimental, con un muestreo poblacional de una cohorte entre los años 2009 al 2015, 19334 registros de promedios finales de las asignaturas de un total de 696 estudiantes matriculados en la FINESI de la Universidad Nacional del Altiplano-Puno. Las dos técnicas se procesaron independientemente para la predicción del Rendimiento Académico. Por lo tanto, el objetivo es determinar la mejor técnica de predicción en el rendimiento académico mediante regresión y redes neuronales en los estudiantes de la FINESI de la Universidad Nacional del Altiplano. Para dar lugar a un mejor

aporte del servicio educativo con herramientas inteligentes. La estructura del presente trabajo se consideró de la siguiente manera:

En el capítulo I, se detalló el planteamiento del problema de investigación formando parte de ello la definición y formulación, objetivos, hipótesis, justificación y delimitación de la investigación.

En el capítulo II, se desarrolló el marco teórico que contiene los antecedentes de la investigación, la base teórica, la definición de términos básicos y la operacionalización de variables.

En el capítulo III, se estableció los materiales y método de la investigación, tomando en consideración los siguientes puntos: tipo y método de investigación, diseño de estudio, población y muestra, los métodos, técnicas e instrumentos de recopilación de datos y los métodos de análisis de datos.

En el capítulo IV, se describieron los resultados de las técnicas de predicción mediante regresión múltiple, redes neuronales, el análisis, la interpretación de los resultados obtenidos en las técnicas, los modelos se ejecutan usando la herramienta Rstudio, finalmente las conclusiones, recomendaciones y sugerencias.

CAPÍTULO I

PLAN DE INVESTIGACIÓN

1.1 PLANTEAMIENTO DEL PROBLEMA

1.1.1 Definición del problema

Conforme se han ido dando, los cambios de tipo tecnológico, social y legal, el bajo rendimiento académico universitario ha sido un problema de interés latinoamericano. En la actualidad la Educación Superior Universitaria Peruano se ha modificado con la Ley Universitaria N° 30220, que tiene como fin mejorar permanentemente la calidad educativa universitaria que la sociedad peruana necesita.

El alto porcentaje de 71% de desaprobados con más de una asignatura en la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano – Puno-2014. Tal es el caso que del total de alumnos matriculados en el año 2014, el 29% aprobó en condición de invicto (ha disminuido en 1% en comparación al año 2013), el 17% desaprobó con 1 curso (ha disminuido 4% en comparación al año anterior), el 14% desaprobó con 2 asignaturas (aumento en 1% en comparación al año 2013), el 34% desaprobó con 3 ó más asignaturas (aumento en 4% en comparación al año precedente),

y el 1% de reservados (1% más que el año anterior). (Oficina de Estadística OGPD-UNA/P, 2013)

La FINESI no cuenta con información como es la predicción de rendimiento académico de los estudiantes para anticipar el riesgo del bajo rendimiento académico de los estudiantes, que facilite la toma de decisiones y controlar el riesgo del bajo rendimiento académico. Por lo tanto predecir el rendimiento académico, identificar y mitigar a los estudiantes con bajos rendimientos se convierte en un factor clave de éxito con el propósito de gestionar, preservar la buena reputación y mejore en el rango entre Universidades.

Con el fin de proponer modelos de predicción del rendimiento académico con técnica de predicción, que se ajuste a las necesidades de cada estudiante, docente, administrativo. A la actualidad existen técnicas, métodos estadísticos clásicos y nuevos sofisticados técnicas tal es el caso de las Redes Neuronales que garantizan la existencia de una solución a los problemas que se adaptan como una buena opción en la educación Superior Universitaria con costos y recursos eficientes.

1.1.2 Formulación del Problema

Problema General

¿Cuál es la mejor técnica de predicción en el rendimiento académico mediante regresión y redes neuronales en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano - Puno 2015?

Problemas específicos

1. ¿Cuál es la predicción del rendimiento académico mediante regresión en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano - Puno 2015?
2. ¿Cuál es la predicción del Rendimiento académico mediante las redes neuronales en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano - Puno 2015?

1.2 OBJETIVOS

1.2.1 Objetivo General

Determinar cuál es la mejor técnica de predicción en el rendimiento académico mediante regresión y redes neuronales en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano - Puno 2015.

1.2.2 Objetivos específicos

1. Predecir el rendimiento académico mediante la técnica de regresión en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano - Puno 2015
2. Predecir el rendimiento académico mediante la técnica de redes neuronales en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano - Puno 2015

1.3 HIPÓTESIS

1.3.1 Hipótesis general

La mejor técnica de predicción en el rendimiento académico en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano - Puno 2015, son las redes neuronales frente a la regresión lineal múltiple.

1.4 JUSTIFICACIÓN Y DELIMITACIÓN DE LA INVESTIGACIÓN

1.4.1 Justificación de la Investigación

Con la nueva Ley universitaria N° 30220, las universidades Peruanas están en la necesidad de mejorar la calidad de formación de los estudiantes universitarios.

En ese contexto este trabajo se dio como una alternativa poco explorado en Perú, la existencia de indicadores de bajo rendimiento académico en los estudiantes de la FINESI, inexistencia alguna de técnica de predicción del rendimiento académico universitario en la FINESI, se evaluó las técnicas de regresión y redes neuronales, se proporcionó los mejores modelos de predicción para las asignaturas del área de estadística e informática, permitió dar una solución a la necesidad de disponer de la mejor técnica de predicción del rendimiento académico de los estudiantes, proporcionando una información adecuada para la toma de decisiones, mejorando los procesos de aprendizaje de los estudiantes en el reforzamiento del algún asignatura en riesgo, en tanto para los docentes como apoyo para la tutoría, todo esto para mejorar la calidad y la imagen de la institución.

1.4.2 Limitaciones de la Investigación

La disponibilidad de la información es inaccesible debido a las Normas, reglas de la universidad por lo que dificulta el proceso de recolección de datos.

Este trabajo está enmarcado en un cohorte de estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano – Puno, que cursaron entre los años 2009 -2015, los datos son las los promedios finales obtenidas por los estudiantes en las áreas de estadística e informática.

Para la implementación de la red neuronal y la regresión múltiple se desarrolló con las herramientas de programación Visual Basic para Aplicaciones Excel y R. Con estos lenguajes de programación se realizó las distintas fases de este presente trabajo.

CAPÍTULO II

MARCO TEÓRICO

2.1 ANTECEDENTES DE LA INVESTIGACIÓN

Mencionamos algunos trabajos que son enfocados como antecedentes de la presente investigación:

2.1.1 Antecedentes a nivel internacional

Arsad (2012) utilizó las Redes Neuronales Artificiales (ANN) perceptron multicapa, Backpropagation, el estudio se realizó sobre la ingesta de estudiantes desde el primer nivel, desarrolló un modelo para predecir el rendimiento académico en función de su promedio acumulado de calificaciones (CGPA) de los estudiantes ingeniería en la Facultad de Ingeniería Eléctrica, Universidad Tecnológica de MARA (UITM), Malasia. La investigación llegó a las siguientes conclusiones:

- Afirman con seguridad la existencia de una correlación directa entre la rendimiento académico general final con respecto a las materias básicas del primer nivel de los estudiantes.

- También sugirió una intervención estratégica para ayudar durante el periodo de estudio a los estudiantes de bajo rendimiento, con el fin de mejorar los resultados académicos a los estudiantes en general.

2.1.2 Antecedentes a nivel nacional

De acuerdo a la investigación realizado por Acosta y Pizarro (2010) utilizaron técnicas de minería de datos y técnicas estadísticas para la predecir el rendimiento académico de un estudiante universitario en una asignatura que desea inscribirse. Utilizando la base de datos académica de los universitarios previamente preparado de las 7 asignaturas llegando a la siguiente conclusión:

- Con respecto a la predicción de la nota de una asignatura con técnicas de redes neuronales de retropropagación y regresión múltiple, obtuvieron promedios de Raíz del Error Cuadrático Medio similares de 0,1495 y 0,1430 para los modelos, y de 0,1397 y de 0,1380 para los pronósticos respectivamente.

2.1.3 Antecedentes a nivel local

Esteba (2011), se plantea un objetivo de predecir el ingreso de extranjeros al Perú por el Aeropuerto Internacional Jorge Chávez, utilizando Redes Neuronales Artificiales, se experimentó y se observó el desempeño del Algoritmo de Aprendizaje retropropagación, encontrándose experimentalmente una serie estimada con la Red Neuronal, para entrenamiento se utilizó 108 datos históricos, llegando a la conclusión:

- Ha demostrado que el potencial de las Redes Neuronales Artificiales como herramienta para el cálculo de previsiones de ingreso de extranjeros por el aeropuerto internacional Jorge Chávez. Gracias a su capacidad de aprender a partir de los datos que se proporcionó, sin hacer suposiciones sobre los modelos y relaciones que subyacen en la serie, pueden ser aplicadas directamente, lo que facilita considerablemente el proceso de cálculo de previsiones.
- Aplicando las técnicas de Redes Neuronales Artificiales como es el modelo de Backpropagation, tiene la cualidad de aprender los patrones de series históricas en forma vectorial.

2.2 RENDIMIENTO ACADÉMICO

En la literatura revisada, se sigue buscando su compleja definición del rendimiento académico, las definiciones se adaptan de acuerdo al objetivo del estudio.

2.2.1 Definición de Rendimiento académico

El Diccionario de la Real Academia Española (2014) define rendimiento como "Producto o utilidad que rinde o da alguien o algo", académico, ca como "Perteneiente o relativo a centros oficiales de enseñanza, especialmente a los superiores. Curso, expediente, título académico".

Para esta investigación la definiciones que mejor resaltan el rendimiento académico: es un "resultado del aprendizaje, suscitado por la actividad educativa del profesor, y producido en el alumno, aunque es claro que no todo aprendizaje producto de la acción del docente" (Tourón, 1984), también se

define como "producto que rinde o da el alumnado en el ámbito de los centros oficiales de enseñanza, y que normalmente se expresa a través de las calificaciones escolares" (Martínez, 2007 citado por lamas, 2015), se definió un modelo teórico de desempeño académico de un alumno refiriéndose que Rendimiento General es el "resultado de los rendimientos parciales alcanzados tanto en sus actividades académicas: la regularización y la aprobación de las asignaturas correspondientes a la carrera en la secuencia temporal prevista por el Plan de Estudio como respecto del nivel proporcional de logro cognitivo alcanzado en cada materia aprobada" (Luque y Sequi, 2002).

Las calificaciones en las universitarias peruanas se hacen mediante una medición cuantitativa y cualitativa. Para el estudiante, las los promedios finales evidencia que el contenido de un curso ha sido asimilado satisfactoriamente y apertura otros cursos u otros estudios posteriores. Para un docente, la calificación es evidencia de que el contenido de un curso ha sido asimilado por el estudiante.

Las calificaciones que la Universidad Nacional Del Altiplano (Directiva académica UNAP, 2017) definen los siguientes formulas:

- Promedios parciales:

$$PP = \frac{EC(\text{Ponderado})+ED(\text{Ponderado})+EP(\text{Ponderado})}{\text{Sumatoria de los Ponderados}} \quad (1)$$

Donde:

PP: Promedio Parcial

ED: Evidencia de desempeño

EC: Evidencia de conocimiento

EP: Evidencia de producto

•El Promedio Final (PF) del logro de aprendizaje de la competencia prevista de la asignatura o componente curricular, según el número de promedios parciales:

Para dos promedios parciales:

$$PF = \frac{IPP + IIPP}{2}$$

Para tres promedios parciales:

$$PF = \frac{IPP + IIPP + IIIPP}{3} \quad (2)$$

Donde:

PF = Promedio final

IPP = Primer promedio parcial

IIPP = Segundo promedio parcial

IIIPP = Tercer promedio parcial

Las evidencias de conocimiento, desempeño y de producto se evalúan en una escala vigesimal de 0 a 20 puntos. La nota mínima para aprobar es 11 o en su defecto, 10,5 que son equivalentes al promediar. Se establece la siguiente escala cuantitativa – cualitativa para determinar el logro de las competencias:

Tabla N° 01. Escala de rendimiento académico

Calificación cuantitativa	Apreciación cualitativa	Nivel de logro de competencia
17-20	Alto	Logra eficazmente la competencia
14-16	Bueno	Logra la competencia en forma aceptable
11-13	Regular	Logro de la competencia en proceso
00-10	Deficiente	Deficiente No logra la competencia

Fuente: *Directiva académica UNAP 2017*

Concluyendo, rendimiento académico es un indicador, calificación final del conocimiento adquirido por un estudiante en las aulas universitarias en un determinado asignatura durante un periodo académico.

2.2.2 Factores del Rendimiento Académico Universitario

Los trabajos de investigación sobre predicción del rendimiento académico suelen asociar a diversos factores como institucional, psicológicos, sociales, pedagógicos, académicos, demográficos, etc. Estos factores determinantes son considerados como las variables independientes que influyen sobre la variable dependiente.

En esta investigación se enfocó a los factores académicos para la predicción del rendimiento académico, en ese sentido Rodríguez y Coello (2008), determinaron que el rendimiento futuro depende del rendimiento previo, es decir, ambas variables se ven afectas por el rendimiento anterior de los estudiantes, del mismo modo Tejedor (2003) asegura que “se predice mejor el historial académico de un alumno en base a su historial académico previo en la Universidad (más cercano en el tiempo) que en base a su trayectoria académica en secundaria (más lejana en el tiempo)”, Valle (1998) describió las variables dependientes (endógenas): Rendimiento académico y las variables independientes (exógenas): Rendimiento previo, de los mencionados anteriormente Tejedor y otros (1998) confirman que el rendimiento académico previo es el mejor predictor del rendimiento académico universitario.

Acosta y Pizarro (2010) determinaron 4 categorías:

- 1) Rendimiento global del estudiante (promedio ponderado acumulado al semestre previo, antigüedad en años desde el año de ingreso a la universidad hasta el año del semestre previo)
- 2) Rendimiento del estudiante relacionado al curso (nota pre-requisito 1 y 2)
- 3) Grado de dificultad de aprobación de un curso (promedio del grado de dificultad 1 de aprobación por semestre hasta el semestre previo)
- 4) Influencia de los otros cursos que se quiere llevar en el semestre en estudio (numero de créditos totales que se quiere llevar en el semestre en estudio, sumatoria del promedio del grado de dificultad (por semestre hasta el semestre previo), evaluado para todos los cursos que llevaran en el semestre en estudio).

También “Encontraron que si el estudiante disminuía el número de créditos en el que estaba matriculado su rendimiento general (promedio) se incrementaba” (Girón y González ,2005 citado por Ocaña ,2011).

Por otro lado Tejedor y otros (1995, 1998) establecieron cinco categorías:

- 1) Variables de identificación (género, edad)
- 2) Variables psicológicas (aptitudes intelectuales, personalidad, motivación, hábitos de estudios, etc.)
- 3) Variables académicas (tipos de estudios cursados, curso, opción en que se estudia una carrera, rendimiento previo, etc.)

- 4) Variables pedagógicas (método de enseñanza, estrategias de evaluación)
- 5) Variables socio familiares (estudios de los padres, situación laboral de los padres, lugar de residencia familiar, lugar de estudio, etc.).

Del mismo modo, Randall y Bulent (1997) encontraron que el promedio ponderado en matemáticas tenía un aporte positivo al rendimiento académico en la asignatura de Estadística para Negocios y Economía.

Para la predicción de rendimiento académico de los estudiantes universitarios obliga evaluar, seleccionar, procesar y analizar la información disponible en las Unidades Académicas para determinar las variables, parámetros e indicadores que objetivarán a la convergencia de las variables predictoras.

2.3 REDES NEURONALES ARTIFICIALES

Las RNA's son el resultado de los intentos por reproducir mediante computadoras el funcionamiento del cerebro humano. Esta investigación considera importante describir el funcionamiento de las redes neuronales biológicas, para luego describir el comportamiento de las redes neuronales artificiales.

2.3.1 Definición de Redes Neuronales Artificiales

Existen múltiples definiciones de Redes Neuronales Artificiales (RNAs) entre las que resultan interesantes:

Según Flórez y Fernández (2008) Las RNAs es la emulación del sistema nervioso central biológico a través de procesadores artificiales, modelos

computacionales que resultan como un intento de conseguir formalizaciones matemáticas acerca de la estructura del cerebro, con la misma definición (Martín y Sanz, 2001) Las RNAs imitan la estructura física del sistema nervioso, con la intención de construir sistemas de procesamiento de la información en paralelos, distribuidos y adaptativos, que puedan presentar un cierto comportamiento inteligente. De acuerdo a Haykin (1994) "una red neuronal es un procesador distribuido paralelamente de manera masiva que tiene una tendencia natural para almacenar conocimiento experimental y hacerlo disponible para su uso".

Se define también como: "Redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico". (Kohonen, 1988 Citado por Lahoz, 2010), de igual manera es "Un sistema de computación hecho por un gran número de elementos simples, elementos de proceso muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas" (Hecht-Nielsen, 1988), también "Una nueva forma de computación, inspirada en modelos biológicos", "Un modelo matemático compuesto por un gran número de elementos procesales organizados en niveles". (Hilera y Martínez, 1995).

Para obtener una definición de red se usa el concepto matemático grafo. A través de este término, se puede definir una red neuronal de la siguiente forma:

Las neuronas que reciben los datos iniciales conforman lo que se conoce como: capa de entrada mientras que las que devuelven el último valor sin que este lo recoja ninguna otra neurona conforman la capa de salida. Entre ambas capas puede haber otras más, llamadas capas ocultas.

Estos conceptos pueden ser definidos de una manera mucho más rigurosa desde un punto de vista matemático. A continuación se da la definición de (Müller y Reinhardt, 1990):

Una red neuronal es un grafo dirigido, con las siguientes propiedades:

- A cada nodo i se asocia una variable de estado X_i
- A cada conexión (i,j) de los nodos i y j se asocia un peso $W_{ij} \in \mathbb{R}$
- A cada nodo i se le asocia un umbral Θ_i
- Para cada nodo i se define una función $F_i(x_j, w_{ij}, \Theta_i)$, que depende de los pesos de sus conexiones, del umbral y de los estados de los nodos j conectados a él. Esta función proporciona el nuevo estado del nodo.

Donde los nodos son las neuronas y las conexiones son las sinapsis en la terminología más común, y según la definición anterior:

- Neurona de entrada: neurona sin sinapsis entrantes.
- Neurona de salida: neurona sin sinapsis salientes
- Neurona oculta: toda neurona que no es de entrada ni de salida.

2.3.1.1 Neurona Biológica

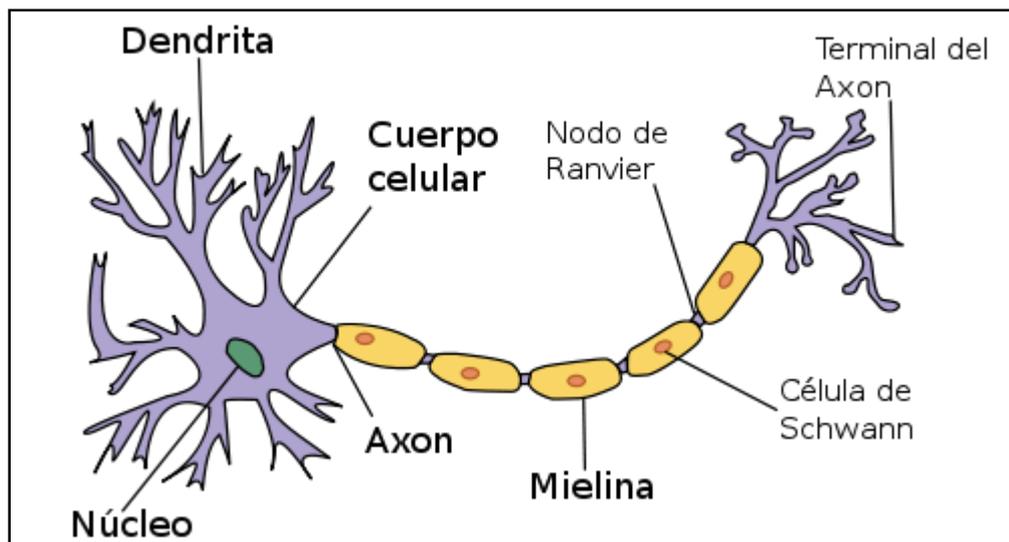
Ramón y Cajal (1888) fue quien descubrió la estructura celular (neurona) del sistema nervioso. También defendió la teoría de que las neuronas se interconectaban entre sí de forma paralela, y no formando un circuito cerrado como el sistema sanguíneo. La neurona es considerada como unidad independiente, estructural y funcional del sistema nervioso, cuya principal característica es la recepción de estímulos y la transmisión unidireccional del impulso nervioso entre neuronas.

2.3.1.1.1 Estructura de la neurona biológica

Hilera y Martínez (1995) describe que la teoría y modelado de las redes neuronales artificiales están inspirada en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es elemento fundamental. Una de las características que diferencia a las neuronas del resto de las células vivas, es su capacidad de comunicarse.

La comunicación entre neuronas, que implica un proceso electroquímico, implica que, una vez que una neurona es excitada a partir de cierto umbral, ésta se despolariza transmitiendo a través de su axón una señal que excita a neuronas aledañas, y así sucesivamente.

En términos generales, las dendritas y el cuerpo celular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida.

Gráfico N° 01: Características básicas de la neurona biológica

Fuente: Flórez y Fernández (2008)

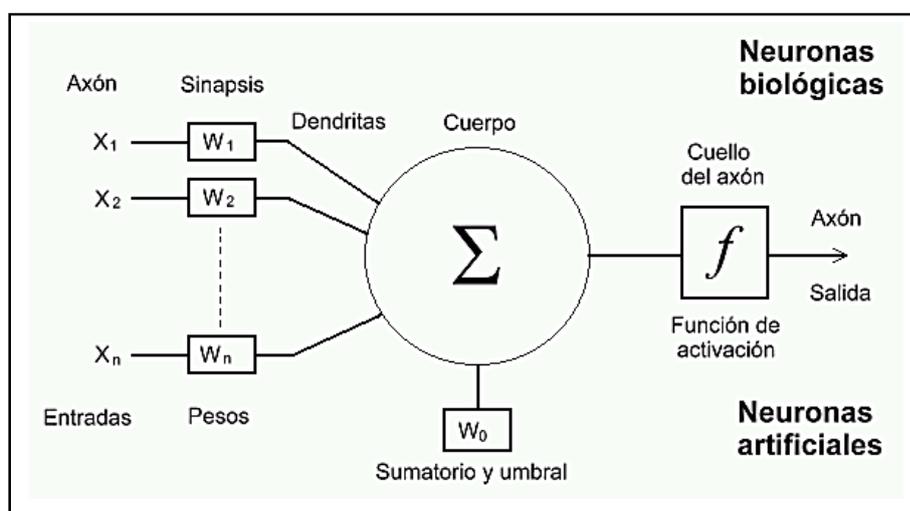
La Gráfico 1 muestra el esquema general de una neurona biológica, y donde podemos reconocer diferentes partes:

- El cuerpo central, llamado soma, que contiene el núcleo.
- Una prolongación del soma, el axón es un tubo largo y delgado que se ramifica en su extremo en pequeños bulbos finales que casi tocan las dendritas de las células vecinas.
- Una ramificación terminal, las dendritas forman una estructura de filamentos muy fina que rodean el cuerpo de la neurona.
- Una zona de conexión entre una neurona y otra, conocida como sinapsis, en las cuales se produce una transformación de los impulsos eléctricos en un mensaje neuroquímico, mediante la liberación de unas sustancias llamadas neurotransmisores.

2.3.1.2 Neurona Artificial Simple

McCulloch y Pitts (1943) demostraron en un análisis matemático del funcionamiento del cerebro la cual fue el primer modelamiento de una neurona simple al que llamaron Perceptrón, construido con circuitos electrónicos.

Gráfico N° 02: Modelo de Neurona Artificial Simple



Fuente: Modelo de McCulloch Pitts.

La grafica 2 muestra un modelo neuronal con n entradas, que consta de:

- Un conjunto de entradas X_1, \dots, x_n .
- Los pesos sinápticos w_1, \dots, w_n , correspondientes a cada entrada.
- Una función de agregación, Σ .
- Una función de activación, f .
- Una salida, Y .

Una neurona es un procesador elemental, los vectores entrada que son el estímulo procedente del exterior o de otras neuronas, proporciona una única

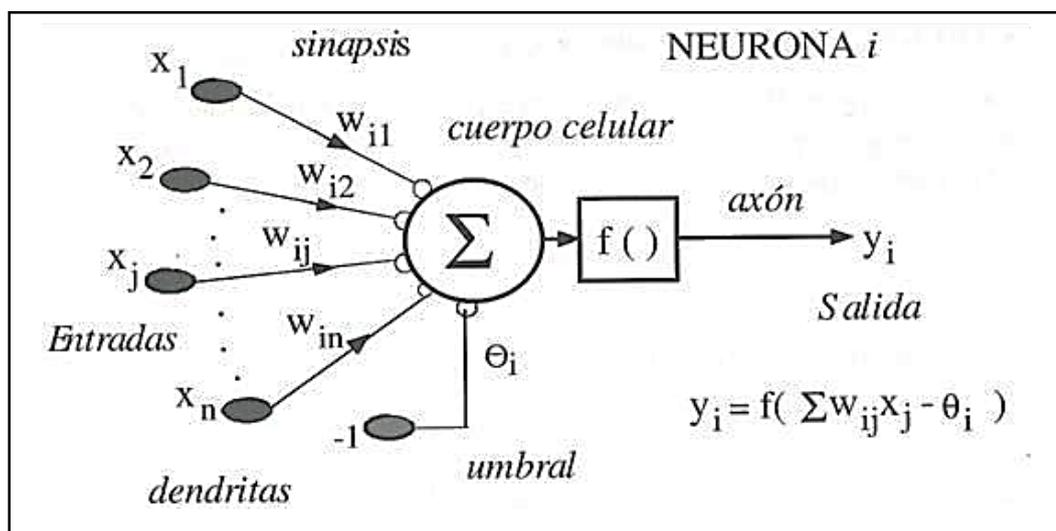
respuesta o salida a tal estímulo. La neurona puede adaptarse al medio circundante y aprender de él modificando el valor de sus pesos sinápticos, y por ello son conocidos como los parámetros libres del modelo, ya que pueden ser modificados y adaptados para realizar una tarea determinada.

2.3.1.2.1 Modelo Estándar de Neurona Artificial

Martín y Sanz (2007) consideró que la regla de propagación consiste en la sumatoria de las entradas ponderadas y que la función de salida es la identidad, la neurona estándar consiste en:

- Conjunto de entradas $x_j(t)$.
- Pesos sinápticos w_{ij} asociados a las entradas
- Regla de propagación $h_j(t) = \sigma(\sum w_{ij}, x_j(t))$ ó $h_i(t) = \sum w_{ij} x_j(t)$ es la más común.
- Una función de activación $h_j(t) = f_j(h_j(t))$ que representa simultáneamente la salida de la neurona y su estado de activación.

Gráfico N° 03: Modelo de Neurona Artificial Estándar.



Fuente: Grafica de Martín y Sanz.

Con frecuencia se añade al conjunto de pesos de la neurona un parámetro adicional θ_i que denominaremos umbral, que se resta del potencial post sináptico, por lo que el argumento de la función de activación queda:

$$\sum_j w_{ij} x_j - \theta_i$$

En conclusión, el modelo de esta neurona queda definido como:

$$y_i(t) = f_i(\sum_{j=0}^n w_{ij} x_j - \theta_i) \quad (3)$$

De forma equivalente, si hacemos que los índices i y j comiencen en 0 y definiendo $w_{ij} = \theta_i$ y $x_0 = -1$ (constante), con lo que la potencia post sináptico se obtiene realizando la suma desde $i = 0$ la neurona a través de $y_i(t) = f_i(\sum_{j=0}^n w_{ij} x_j)$.

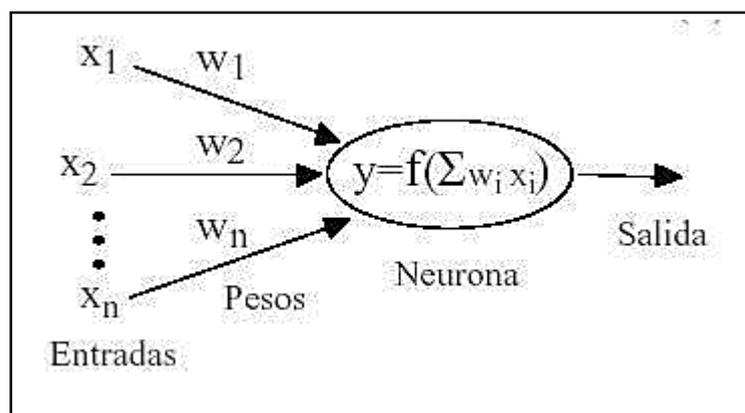
2.3.2 Elementos de una red neuronal artificial

La neurona artificial pretende minimizar las características más importantes de las neuronas biológicas. Cada neurona i -ésima está caracterizada en cualquier instante por un valor numérico denominado valor o estado de activación $a_i(t)$; asociado a cada unidad, existe una función de salida, f_i , que transforma el estado actual de activación en una señal de salida. Dicha señal es enviada a través de los canales de comunicación unidireccionales a otras unidades de la red; estos canales la señal se modifica de acuerdo con la sinapsis (el peso, w_{ji}) asociada a cada uno de ellos según determinada regla. Las señales moduladas que han llegado a la unidad j -ésima se combinan entre ellas, generando así la entrada total Net_j .

$$Net_j = \sum_i y_i w_{ji} \quad (8)$$

Una función de activación, f , determina el nuevo estado de activación $a_j(t + 1)$ de la neurona, teniendo en cuenta la entrada total calculada y el anterior estado de activación $a_j(t)$.

Gráfico N° 04: Entrada y salida de una neurona U_j .



Fuente: Grafica de Martín y Sanz.

La dinámica que rige la actualización de los estados de las unidades puede ser de dos tipos: asíncrono y modo síncrono. En el primer caso, las neuronas evalúan su estado continuamente según les va llegando información, y lo hacen de forma independiente, En el segundo caso, la información llega de forma continua, pero los cambios se realizan simultáneamente, como si existiera un reloj interno que decidiera cuando cambiar su estado. Los sistemas biológicos quedan probablemente entre ambas posibilidades.

2.3.2.1 Unidades de proceso: La neurona artificial

Si se tienen N unidades (neuronas), podemos ordenarlas arbitrariamente y designar la j -ésima unidad como U_j .

En cualquier sistema que se esté modelando, es útil caracterizar tres tipos de unidades: entradas, ocultas y salida.

- Las unidades de entrada reciben señales del entorno, éstas pueden ser provenientes de sensores o de otros sectores del sistema.
- Las unidades ocultas son aquellas cuyas entradas y salidas se encuentran dentro del sistema; es decir no tienen contacto con el exterior.
- Las unidades de salida envían la señal fuera del sistema; éstas pueden controlar directamente potencias u otros sistemas.

Se conoce como capa o nivel a un conjunto de neuronas cuyas entradas provienen de la misma fuente y cuyas salidas se dirigen al mismo destino.

2.3.2.2 Estado de Activación

Junto al conjunto de unidades, la representación necesita los estados del sistema en un tiempo t . Esto se especifica en un vector de N números reales $A(t)$, que representa el estado de activación del conjunto de unidades de procesamiento. Cada elemento del vector representa la activación de una unidad en el tiempo t . La activación de una unidad U_j en el tiempo t se designa por $a_i(t)$ es decir:

$$A(t) = (a_1(t), a_2(t), \dots, a_n(t)) \quad (9)$$

Todas las neuronas que componen la red se encuentran en dos posibles estados, reposo y excitado, se le asigna valores de activación pueden ser continuos o discretos. Además pueden ser limitados o ilimitados.

Si son discretos, en notación binaria. El estado activo se indicaría por un 1, y se caracteriza por la emisión de un impulso por parte de la neurona (potencial de acción), el estado pasivo se indicaría por un 0.

En otros modelos se considera un conjunto continuo de estados de activación, en cuyo caso se asigna un valor entre $[0,1]$ o en el intervalo $[-1,1]$, generalmente siguiendo una función sigmoïdal.

Los criterios o reglas que siguen las neuronas para alcanzar tales estados activación en principio dependen de dos factores:

- Puesto que las propiedades macroscópicas de las redes neuronales son producto del conjunto como un todo, es necesario tener idea del mecanismo de interacción entre las neuronas. Este estado de activación estará fuertemente influenciado por tales interacciones, ya que el efecto que producirá una neurona sobre otra será proporcional a la fuerza, peso o magnitud de la conexión entre ambas,
- La señal que envía cada una de las neuronas a sus vecinas dependerá de su propio estado de activación.

2.3.2.3 Función de salida o transferencia

Asociada a cada unidad U_j (neurona) hay una función de salida $f_j(a_i(t))$, que transforma el estado actual de activación en una señal de salida:

$$y_i(t)=f_j(a_i(t)) \quad (4)$$

El vector que contiene las salidas de todas las neuronas en un instante t es:

$$Y(t) = (f_1(a_1(t)) f_2(a_2(t)), \dots, f_i(a_i(t)), \dots, f_N(a_N(t)))$$

En algunos modelos, esta salida es igual al nivel de activación de la unidad, en cuyo caso la función f_j es la función identidad, $f_j(a_i(t)) = a_i(t)$. A menudo, f_j es de tipo sigmoïdal, y suele ser la misma para todas las unidades.

Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas:

- Función escalón -
- Sigmoïdal
- Función lineal y mixta -
- Función gaussiana

La función escalón o umbral: Únicamente se utiliza cuando las salidas de la red son binarias. La salida de una neurona se activa sólo cuando el estado de activación es mayor o igual que cierto valor umbral.

Las funciones mixtas y sigmoïdal: Son las más apropiadas cuando queremos como salida información analógica.

La función lineal o identidad: Equivale a no aplicar función de salida. Se usa muy poco.

2.3.2.4 Conexiones entre neuronas

Las conexiones que unen las neuronas que forman una RNA tienen asociado un peso que es el que hace que la red adquiera conocimiento. Consideremos y_i como el valor de salida de una neurona i en un instante dado. Una neurona recibe un conjunto de señales que le dan información del estado de activación

de todas las neuronas con las que se encuentra conectada. Cada conexión (sinápsis) entre la neurona i y la j está ponderada por un peso w_{ji} . Normalmente, como simplificación, se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona Net_j , es la suma de cada señal individual por el valor de la sinapsis que conecta ambas neuronas:

$$Net_j = \sum_i w_{ji} y_i$$

Esta regla muestra el procedimiento a seguir para combinar los valores de entrada a una unidad con los pesos de conexiones que llegan a esa unidad y es conocida como regla de propagación.

2.3.2.5 Función o regla de activación

Así como es necesario una regla que combine las entradas de una neurona con los pesos de las conexiones, también se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función f produce un nuevo estado de activación en una neurona a partir del estado a_i que existía y la combinación de las entradas con los pesos de las conexiones (Net_i).

Dado el estado de activación $a_i(t)$ de la unidad U_j y la entrada total que llega, Net_i , el estado de activación siguiente, $a_i(t+1)$, se obtiene aplicando una función F , llamada función de activación.

$$a_i(t+1) = F(a_i(t), Net_i)$$

En la mayoría de los casos la función f es la función identidad, por lo que el estado de activación de la neurona en $t+1$ coincidirá con el Net de la misma t . En este caso, el parámetro que se le pasa a la función de salida f , de la neurona será directamente el Net. Es estado de activación anterior no se tiene en cuenta. Según esto, la salida de una neurona $i(y_i)$ quedará según la expresión:

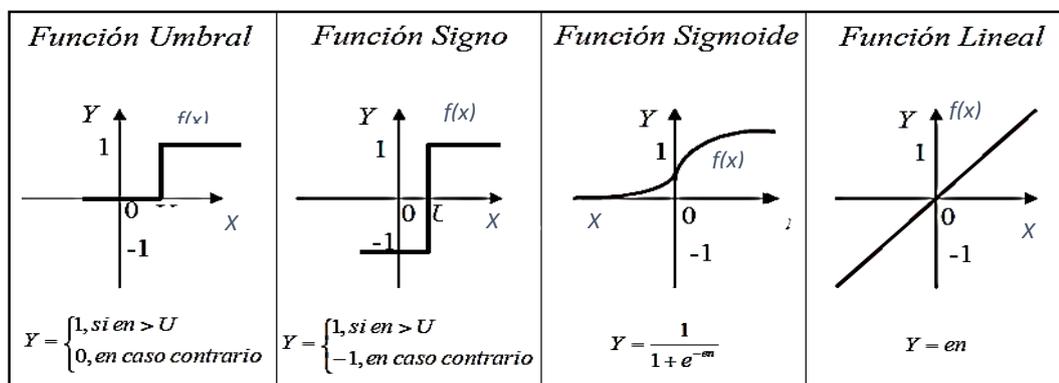
$$y_i(t + 1) = f(Net_j) = f\left(\sum_{j=1}^N w_{ji} y_j(t)\right)$$

Por tanto, y en lo sucesivo, consideraremos únicamente la función f , que denominaremos de transferencia o de activación. Además, la misma no está centrada en el origen del eje que representa el valor de entrada neta sino que existe cierto desplazamiento debido a las características internas de la neurona y que no es igual en todas ellas. Este valor se denota como θ_i y representa el umbral de activación de la neurona i .

$$y_i(t + 1) = f(Net_i - \theta_i) = f\left(\sum_{j=1}^N w_{ji} y_j(t) - \theta_i\right)$$

La salida se obtiene en una neurona para las diferentes funciones f serán:

Gráfico Nº 05: Funciones de activación de una neurona artificial



Fuente: Flórez y Fernández (2008)

2.3.2.6 Regla de aprendizaje

Existen muchas definiciones del concepto aprendizaje, una de ellas podría ser: La modificación del comportamiento inducido por la interacción del entorno y como resultado de las experiencias conducen al establecimiento de nuevos modelos de respuesta a estímulos externos.

Biológicamente, se suele aceptar que la información memorizada en el cerebro está más relacionada con los valores sinápticos de las conexiones entre las neuronas que con ellas mismas. En el caso de las RNA, se puede considerar que el conocimiento se encuentra representado en los pesos de las conexiones entre neuronas. Todo proceso de aprendizaje implica cierto número de cambios en estas conexiones. Puede decirse que se aprende modificando los valores de los pesos de la red.

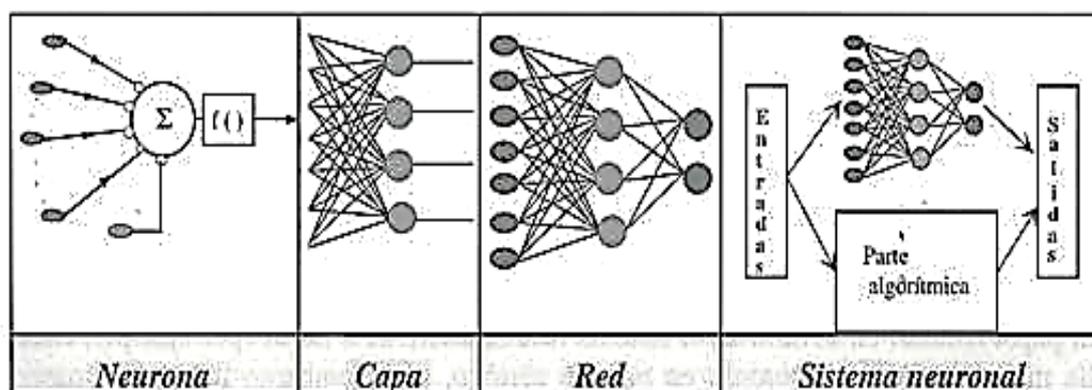
2.3.3 Estructura de una red neuronal artificial

A partir de los tres conceptos claves a emular de los sistemas nerviosos son: paralelismo de cálculo, memoria distribuida, y adaptabilidad al entorno (Del Brío & Sanz, 2005), un sistema neuronal artificial puede establecerse una estructura jerárquica similar. El elemento esencial de partida será la neurona artificial, que se organizará en capas; varias capas constituirán una red neuronal, y por último, una red neuronal (o conjunto de ellas), junto con las interfaces de entrada y salida, más los módulos convencionales adicionales necesarios, constituirán el sistema global de proceso.

En un sistema neuronal artificial puede establecerse una estructura jerárquica similar a las redes neuronales biológicas, de forma que una RNA pueda

concebirse como una colección de procesadores elementales (neuronas artificiales), conectadas a otras neuronas o bien a entradas externas y con una salida que permite propagar las señales por múltiples caminos.

Gráfico N° 06: Estructura jerárquica de un sistema basado en RNAs.



Fuente: Adaptado de Martín y Sanz por Flórez y Fernández (2008)

La distribución de neuronas dentro de la red se realiza formando niveles o capas de un número determinado cada una. Se pueden distinguir tres tipos de capas:

- De Entrada: es la capa que recibe directamente la información proveniente de las fuentes externas de la red.
- Ocultas: son internas a la red, no tiene contacto directo con el exterior. El número de niveles ocultos puede ser de cero a un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina junto a su número, las distintas topologías.
- De Salida: transfieren información de la red hacia el exterior.

2.3.4 Ventajas de las redes neuronales artificiales

Las RNA's presentan muchas ventajas debido a que gran número de características están basados en el sistema nervioso, semejantes a la del cerebro. Esto hace que tengan numerosas ventajas, según Hilera y Martínez (1995) estas son:

- Operación entiempro real: la estructura de una RNA es paralela, es implementado con computadoras o dispositivos electrónicos especiales, resulta esencial en cada una de ellas trabajando simultáneamente para poder realizar procesos con gran cantidad cálculos en un intervalo de tiempo reducido.se puede obtener respuesta en tiempo real.
- Tolerancia a fallas: Otro concepto importante que aparece en el cerebro es el de memoria distribuida, las RNA son los primeros métodos computacionales con la capacidad inherente de tolerancia a fallos comparados con los sistemas tradicionales que pierden su funcionalidad cuando sufren un pequeño error de memoria, en las redes neuronales, si se produce un fallo en un número pequeño de neuronas no sufre una caída repentina.
- Aprendizaje adaptativo: Las RNA tienen la capacidad de adaptarse fácilmente al entorno modificando sus pesos sinápticos, aprendiendo de las experiencias, consiguiendo generalizar conceptos a partir de casos particulares, permitiéndole encontrar una solución aceptable al problema mediante un entrenamiento con ejemplos ilustrativos.

- Auto organización: una red neuronal puede crear su propia representación de la información en su interior que recibe mediante una etapa de aprendizaje.
- Fácil operación e inserción entre la tecnología existente: se pueden obtener circuitos integrados especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Esto facilitará la integración modular en los sistemas existentes.
- No lineal: Las RNAs permiten realizar a través de sus funciones de activación transformaciones no lineales de los datos, lo cual supone una ventaja frente a los métodos tradicionales de regresión y análisis discriminante múltiple.

Algunas de las desventajas de las redes neuronales artificiales son:

- Las redes neuronales artificiales deben de entrenar para cada problema. Además es necesario realizar múltiples pruebas para determinar la arquitectura adecuada.
- El entrenamiento es largo y puede consumir bastante tiempo de procesamiento de datos en la computadora. Debido a que las redes se entrenan en lugar de programarlas, estas necesitan muchos datos.

2.3.5 Clasificación de las RNA

Las RNA se pueden clasificar según en (Hilera y Martínez, 1995), (Charytoniuk, 2000):

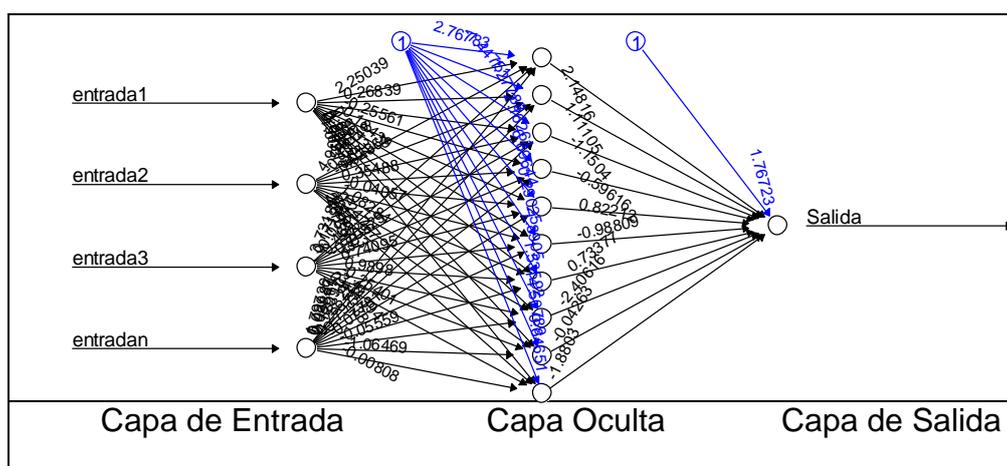
2.3.5.1 Según su arquitectura

La topología o arquitectura de las redes neuronales consta de la organización y disposición de las neuronas en la red formando por una capa de entrada, una o más capas ocultas y salida que están unidas entre sí por conexiones llamadas peso (sinapsis).

Cada nodo de la capa de entrada está conectado a un nodo desde la capa oculta y cada nodo de la capa oculta está conectado a un nodo en la capa de salida.

Gráfico N° 07:

Arquitectura simple de las RNAs.



Fuente: Grafico generado por software R studio.

La capa de entrada representa la información bruta que se alimenta a la red. Esta parte de la red nunca cambia sus valores. Cada entrada a la red se duplica y se envía a los nodos en la capa oculta.

La capa oculta acepta datos de la capa de entrada y los modifica usando algún valor de peso, este nuevo valor es que se envía a la capa de salida, pero también se modificará por algún peso de la conexión entre la capa oculta

y la de salida que es procesada por la función de activación. Dependiendo del sentido de sus conexiones se clasifican en recurrentes y no recurrentes.

a) Con conexiones hacia adelante (No Recurrentes o Feedforward). Son aquellas cuyas conexiones son hacia adelante y unidireccionales, Según el número de capas que posean pueden ser:

- **Redes neuronales monocapa.**

Sólo tienen una capa de neuronas que proyectan las entradas a una capa de neuronas de salida, se establecen conexiones laterales entre todas las neuronas que pertenecen a la única capa de la red. Donde se realizan típicamente en tareas de auto asociación; por ejemplo para regenerar informaciones de entrada que se presentan de forma incompleta o distorsionada. Las arquitecturas más conocidas son: Monolayer Perceptron y el ADALINE.

- **Redes neuronales multicapa.**

Es una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la Salida. Las arquitecturas más conocidas están: Multylayer Perceptron y el MADALINE.

b) Con conexiones hacia atrás (Recurrentes o Feedback). son aquellas en las que la información circula tanto hacia delante como hacia atrás. se caracterizan por la existencia conexiones de retorno entre neuronas de una determinada capa con otras de capas anteriores, conexiones entre neuronas una misma capa o conexiones de una neurona consigo

misma. Las arquitecturas más conocidas están las SOM de Kohonen, Hopfield y las redes ART.

2.3.5.2 Según su aprendizaje

- **Aprendizaje supervisado (con maestro).** Una RNA realiza un aprendizaje supervisado cuando tiene un supervisor en el entrenamiento de la red, significa que existe un parámetro de referencia ya conocido (maestro), el cual es comparado con las salidas de la red, el aprendizaje supervisado se caracteriza por un entrenamiento controlado por una agente externo que determina la respuesta que debería generar la red a partir de una entrada determinada.

El supervisor comprueba la salida de la red y en el caso de que ésta no coincida con la deseada, procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada. Un aprendizaje supervisado requiere disponer de un conjunto de patrones de los cuales se conoce su clase cierta. A este conjunto se le denomina conjunto de entrenamiento. Este tipo de entrenamiento se denomina entrenamiento supervisado y los clasificadores así obtenidos son clasificadores supervisados.

- **Aprendizaje no supervisado (Sin Maestro).** Estos tipos de redes no tienen una referencia de comparación por lo cual contemplan el auto organización y el auto asociación, como procesos de obtención de la salida de la red. Se caracteriza por que la salida no requiere ser contrastada con algo específico ya conocido (maestro).

El aprendizaje no supervisado es conocido también como auto supervisado no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas, por ello, suele decirse que estas redes son capaces de auto organizarse.

2.3.5.3 Según su aplicación

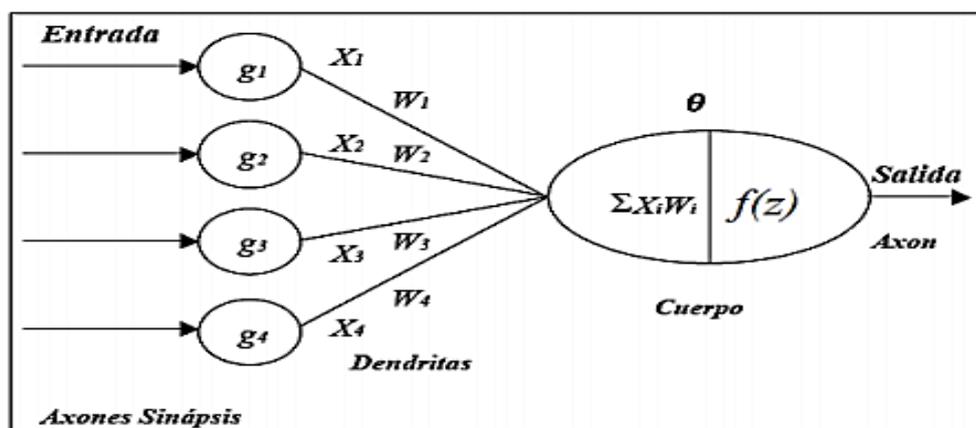
- **Redes de reconocimiento de patrones**, son del tipo no recurrente y con aprendizaje supervisado.
- **Redes de clasificación**, hacen uso del aprendizaje no supervisado para obtener características de clasificación a base de las entradas del problema.
- **Redes de predicción**, tienen como objetivo modelar una función no lineal.

Otros tipos de redes son, redes de memoria asociativa, de Mapeo de Características, de optimización.

2.3.6 Perceptrón Multicapa

Según Anderson (1995) el Perceptrón intenta modelar el comportamiento de la neurona biológica, trabaja con funciones de activación, el cuerpo de la neurona es representado como un sumador lineal de estímulos Z_j , seguida por una función no lineal $f(Z_j)$ que es la función de activación, esta utiliza la suma de estímulos para determinar la salida de la neurona. En el Perceptrón cada entrada es multiplicada por un factor de peso W correspondiente, los resultados son sumados y luego evaluados contra el valor de umbral Θ , si el valor es mayor al máximo el Perceptrón se activa.

Gráfico N° 08: Modelo de un perceptrón



Fuente: Grafica de Martín y Sanz.

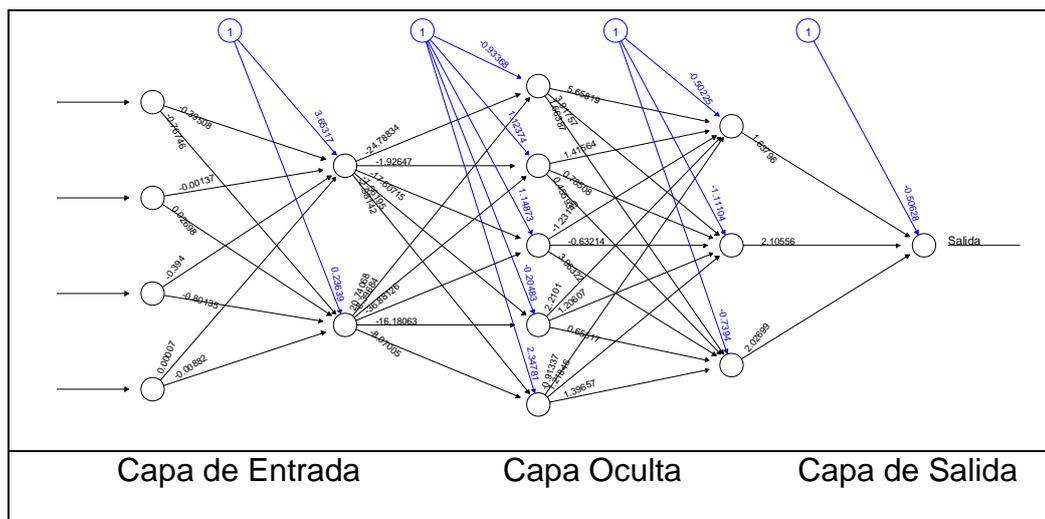
La primera capa actúa como un grupo de sensores que detectan una señal específica con la importancia correspondiente. La segunda capa toma salidas de los detectores y clasifica el patrón de entrada dado.

El aprendizaje empieza ajustando la fuerza en las conexiones (pesos W_i) y el valor de umbral Θ . La función g_i es fija y esta predeterminada.

El entrenamiento de un Perceptrón se hace utilizando una función de aprendizaje. Si la respuesta dada por el Perceptrón es incorrecta, se modifican todos los pesos de las conexiones de acuerdo a la función

$$\Delta W_i = n t_i x_i$$

Donde n es la ratio de aprendizaje, t_i es la salida deseada y x es la entrada del Perceptrón. La arquitectura típica de una RNA Perceptrón Multicapa está constituida por varias capas de nodos con interconexión completa entre ellos. El caso más sencillo en este tipo de red consiste en sólo 2 capas de neuronas, las de entrada y las de salida. De esta manera podemos obtener un modelo adecuado para problemas lineales del tipo de la regresión lineal múltiple.

Gráfico N° 09: Modelo de un perceptrón multicapa.

Fuente: Gráfico generado por software R studio..

En este tipo de red, una neurona recibe distintas entradas y activa la función de red (o regla de propagación) con unos pesos de entrada asociados. La computación de estos pesos se sigue de la aplicación de la función de activación que determina el nivel de activación de salida de la neurona.

2.3.7 Algoritmo Backpropagation.

Básicamente el algoritmo de back-propagation Rumelhart (1986) citado por Hilera y Martínez (1995) consiste en transmitir el error hacia atrás en la red partiendo de la capa de salida. Este proceso se transmite al resto de las capas, permitiendo actualizar los pesos de acuerdo con las contribuciones de cada nodo. Con esta actualización se vuelve a aplicar la red a los datos disponibles y se vuelve a medir el error, poniéndose en marcha nuevamente el mecanismo hacia atrás. El proceso continuará hasta que el error sea menor que un cierto umbral previamente fijado o bien porque se haya llegado al máximo de iteraciones.

La técnica que se utiliza en la aplicación de este algoritmo es la del gradiente descendente. Retomando el grafico 7 que se ha puesto para describir la arquitectura simple de una red, la descripción matemática de esta técnica.

El error de toda la red viene dado por:

$$E = \frac{1}{2} \sum_{i=1}^T (y - O_i)^2 \quad (5)$$

Donde T es el número de elementos de la muestra.

Recordamos que la red sólo tenía un nodo en la capa de salida y se llamaba O al resultado obtenido Y al resultado deseado.

- Primeramente se actualizan los pesos de las conexiones de la capa oculta a la capa output. Se necesita para ello el vector gradiente del error respecto de los v_j

$$\frac{dE}{dV_i} = - \sum (Y_i - O_t) \frac{\partial O_i}{\partial V_i} = - \sum (Y_i - O_t) O_i (1 - O_i) H_{ij}$$

El valor de los pesos v_j se actualiza con una tasa negativa, por lo que el nuevo valor vendría dado por

$$v_j^* = V_i + (-\eta) \frac{dE}{dV_i} \quad (6)$$

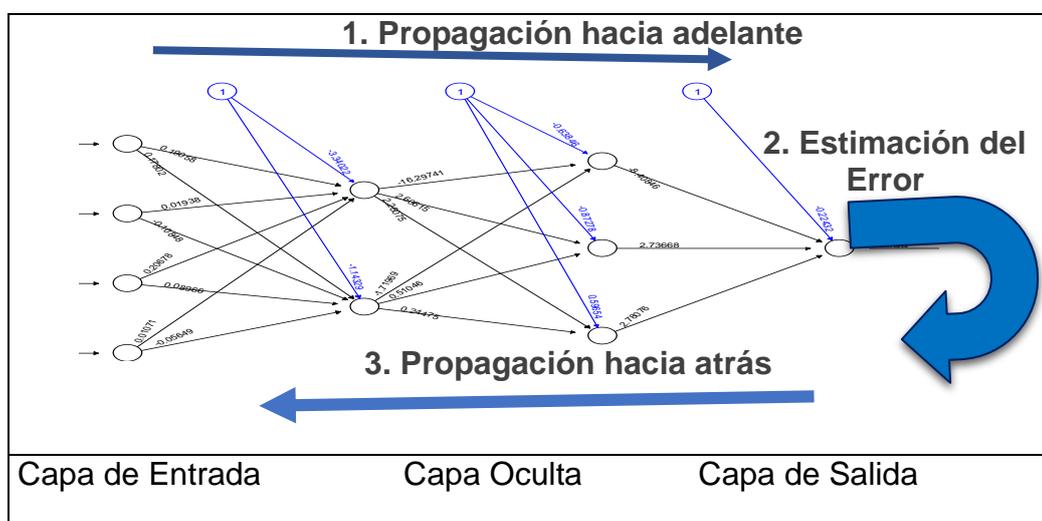
- En segundo lugar, se actualizan los pesos de las conexiones de la capa input a la capa oculta, teniendo en cuenta la expresión

$$\frac{dE}{dV_i} = - \sum (Y_i - O_i) O_i (1 - O_i) V_i H_{ij} (1 - H_{ij}) X_{ij} \quad (7)$$

Para que el proceso de aprendizaje se realice más rápidamente, y a la vez reducir las posibilidades de convergencia a un mínimo local, se puede añadir un término de momento, que recuerda el cambio realizado en el paso anterior (Curram y Mingers, 1994).

El hecho de repetir este proceso durante muchas épocas puede dar a lugar a sobreaprendizaje. Para evitarlo, se suele dividir el conjunto de datos muestrales en dos subconjuntos, uno destinado a entrenamiento y otro a validación (Curram y Mingers, 1994). Con los datos de entrenamiento (al menos el 60% del total) se actualizan los pesos, siguiendo el algoritmo backpropagation ya descrito. La red obtenida con los pesos actualizados cada época se pasa sobre los datos del conjunto de validación y medimos el error cometido. Si este error aumenta a lo largo de las épocas debemos parar el entrenamiento para evitar el sobreaprendizaje. En general, se suele considerar también un tercer subconjunto de datos de test, destinado a contrastar el poder de generalización de la red asociada a las ponderaciones finales.

Gráfico Nº 10: Arquitectura Backpropagation



Fuente: Gráfico generado por software R studio

2.3.8 Metodología de diseño de redes neuronales

La metodología para el diseño de las redes neuronales es ampliamente desarrollada en pronóstico de series de tiempo, en esta ocasión se adaptó para la predicción de rendimiento académico de los estudiantes que a continuación se describe los pasos (Hill,1996 citado por Sanchez 2010):

- Paso 1: Selección de variables
- Paso 2: Recolección de datos
- Paso 3: Preparación de datos
- Paso 4: Entrenamiento, validación
- Paso 5: Selección De la configuración interna
 - Número de capas ocultas
 - Número de neuronas ocultas
 - Número de neuronas de salida
- Paso 6: Criterio de evaluación
- Paso 7: Entrenamiento de la Red neuronal
- Paso 8: Uso del Modelo

2.4 REGRESIÓN LINEAL MÚLTIPLE

Aplicando el modelo de regresión lineal múltiple se hacen las siguientes consideraciones sobre los datos:

- Linealidad: Los valores de la variable dependiente están generados por el siguiente modelo lineal

$$Y = X \cdot B + \varepsilon$$

- Homocedasticidad: Todas las observaciones tienen la misma varianza

$$V (u_i) = \sigma^2$$

- Independencia: Las observaciones aleatorias son independientes entre sí

$$\varepsilon (u_i, u_j) = 0$$

- Normalidad: La distribución de la observación aleatoria tiene distribución normal

$$Y \approx N (0, \sigma^2)$$

- Multicolinealidad: No existen relaciones lineales entre las variables explicativas X_k se obtienen sin errores de media.

Si admitimos que los datos presentan estas hipótesis entonces el teorema de Gauss-Markov establece que el método de estimación de mínimos cuadrados va a demostrar el cumplimiento al producir estimadores óptimos, en el sentido que los parámetros estimados van a estar centrados y van a ser de mínima varianza (Rojo, 2007).

El modelo de regresión lineal múltiple implica 3 procesos según Levin & Rubin (1998) a partir de la descripción de la ecuación de regresión múltiple.

2.4.1 Modelo de Regresión Múltiple

El modelo de regresión múltiple utiliza para predecir el comportamiento de una determinada variable dependiente en función de otras variables independientes de la siguiente ecuación de regresión múltiple.

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k + \varepsilon \quad (8)$$

Donde:

y = función lineal de X_1, X_2, \dots, X_k (variables explicativas predictoras)

β = parámetros del modelo

ε = Representa el error aleatorio.

Se usa el término lineal por que la ecuación es una función lineal de los parámetros desconocidos $\beta_0 + \beta_1 + \dots + \beta_k$ los parámetros $\beta_j, j= 0, 1, \dots, k$ se llaman coeficientes de regresión.

El parámetro β_j representa el cambio esperado en la respuesta y por cambio unitario en X_j cuando todas las demás variables predictoras $X_i (i \neq j)$ se mantienen constantes.

Para determinar los parámetros β , se usará el método de mínimos cuadrados, dado que es el método más sencillo y el más utilizados para la estimación.

2.4.1.1 Estimación de parámetro por el método mínimos cuadrados

El uso de este método determina el valor de la pendiente de la línea de estimación y el valor de la intersección en Y , así se obtendrá el valor de estos factores para la ecuación de regresión lineal.

El criterio del método de los mínimos cuadrados es el siguiente:

$$\text{Min } \Sigma (y_k - \hat{y}_i)^2 \quad (9)$$

Donde:

y = valor observado de la variable dependiente del valor i

\hat{y} = valor estimado de la variable dependiente del valor i

Los valores estimados de la variable dependiente se calculan empleando la ecuación de regresión múltiple estimada, así:

$$\hat{y}_i = b_0 + b_1X_1 + \dots + b_kX_k \quad (10)$$

Los valores de b_k se pueden determinar mediante la siguiente ecuación:

$$b_k = \frac{\sum (x_i - \bar{x}) (y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \quad (11)$$

$$b_0 = \bar{y} - b_kX_k$$

Donde:

x_i = valor de la variable independiente en la observación i

y_i = valor de la variable dependiente en la observación i

\bar{x} = media de la variable independiente

\bar{y} = media de la variable dependiente

2.4.1.2 El error estándar de la estimación de la regresión múltiple

Puesto que se ha determinado la ecuación que relaciona a nuestras variables, se necesita una medida de dispersión para el plano de regresión lineal múltiple. Para medir esta variación, se usa la medida conocida como error estándar de la estimación que viene dada por la siguiente fórmula.

$$S_e = \sqrt{\frac{\sum (y_i - \bar{y})^2}{n-k-1}} \quad (12)$$

Donde:

Y = valores muestrales de la variable dependiente

\bar{Y} = valores correspondientes estimados con la ecuación de regresión

n = número de puntos de la muestra

k = número de variables independientes

El resultado que se obtendrá a partir de la ecuación anterior también se le conoce como error cuadrático medio.

2.4.1.3 El coeficiente de determinación múltiple (R^2)

El coeficiente de determinación múltiple viene dado por los siguientes cálculos:

$$STC = SCR + SCE \quad (13)$$

Donde:

$STC = (y_i - \bar{y})^2$, Suma total de cuadrados

$SCR = (\hat{y}_i - \bar{y})^2$, Suma de cuadrados debido a la regresión

$SCE = (y_i - \hat{y}_i)^2$, Suma de cuadrados debido al error

Siendo: y_i = medias calculadas

\bar{y} = media muestral

\hat{y}_i = media observada

Cada una de estas sumas de cuadrados tiene un número asociado de grados de libertad.

SCT tiene $n - 1$ grados de libertad (n observaciones menos un grado de libertad).

SCR tiene k grados de libertad, porque existen k variables independientes que se utilizaron para explicar y finalmente,

SCE tiene $n - k - 1$ grados de libertad, porque utilizamos nuestras n observaciones para estimar $k + 1$ constantes, a, b_1, b_2, \dots, b_k .

El término coeficiente de determinación múltiple indica que mide la bondad de ajuste de la ecuación de regresión múltiple estimada. El coeficiente de determinación múltiple, que se denota R^2 y se calcula como:

$$R^2 = \frac{SCR}{STC} \quad (14)$$

El coeficiente de determinación múltiple puede interpretarse como la proporción de la variabilidad explicada por la ecuación de regresión estimada. Por lo tanto, el producto de este coeficiente por 100, se interpreta como el porcentaje de la variabilidad en y que es explicada por la ecuación de regresión estimada.

Muchos analistas prefieren ajustar R^2 al número de variables independientes para evitar sobreestimar el efecto que tiene agregar una variable independiente sobre la cantidad de la variabilidad explicada por la ecuación de regresión estimada. Siendo n el número de observaciones y k el número de variables independientes, el coeficiente de determinación ajustado se calcula como:

$$R_a^2 = 1 - (1 - R^2) \cdot \frac{n-1}{n-k-1} \quad (15)$$

El estadístico F contrasta la hipótesis nula de que el valor poblacional de R^2 es cero y, por tanto, nos permite decidir si existe relación lineal significativa entre la variable dependiente y el conjunto de variables independiente. El valor del $\text{Sig} = 0.05$ se acepta la hipótesis nula, valores inferiores se rechaza la hipótesis nula. Se pueden clasificar los valores de R^2 de la siguiente manera:

Tabla Nº 02. Clasificación de los valores de R^2

Menor de 0.3	0.3 a 0.4	0.4 a 0.5	0.5 a 0.85	Mayor de 0.85
Muy malo	Malo	Regular	Bueno	Muy Bueno

Fuente: Rojo, 2007

El estadístico F se calcula así:

$$F = \frac{SCT/K}{SCR/n-k-1} \quad (16)$$

Donde:

SCT = Suma de cuadrados del modelo

K = Grados de libertad del modelo

SCR = Suma de cuadrados de los residuos

2.4.2 Validación de los resultados

2.4.2.1 Multicolinealidad

Es la asociación, medida como correlación entre tres o más variables explicativas. Se trata de reducir el poder explicativo de cualquier variable explicativa individual en la medida en que está correlacionada con las otras variables explicativas presentes en el modelo.

Si las variables explicativas se pueden expresar como una combinación lineal así $a_1X_1 + a_2X_2 + \dots + a_kX_k + a_0 = 0$; se dice que tenemos un problema de multicolinealidad.

Para la detección de la multicolinealidad usaremos el factor de inflación de varianza (VIF).

$$VIF_j = 1 / (1 - R_j^2)$$

2.4.2.2 Método para la selección de las variables

Las variables independientes que se crearon a partir del método de análisis de componentes principales serán seleccionadas de tres diferentes maneras para su posterior comparación, esto se lo realizará para que aquellas variables

seleccionadas proporcionen una mayor explicación a la variable independiente y el modelo no sea redundante, a su vez evalúan estadísticos F que controlan la entrada y salida de variables, además de las correlaciones parciales de la variable dependiente con cada regresor. Los métodos seleccionados serán los siguientes:

Método Stepwise: Combina los métodos forward y backward definiendo un procedimiento en el que las variables independientes entran o salen del modelo dependiendo de su significación (valores F-entrar y F-salir) (Fuente, 2011).

2.4.2.3 Análisis de los residuos

Es la diferencia entre los valores observados y pronosticados del modelo del análisis de regresión lineal múltiple:

$$(Y_i - \hat{Y}_i) \quad (17)$$

Los residuos son variables aleatorias que siguen una distribución normal. Los residuos tienen unidades de medida y, por tanto no se puede determinar si es grande o pequeño a simple vista.

A su vez, los residuos verifican que se cumplan las hipótesis sobre las que se estima el modelo y se realiza la inferencia. Para verificar los residuos se realiza los contrastes de hipótesis siguientes:

a) Normalidad: Se debe realizar la gráfica de histograma de los residuos y para su contraste el test de Kolmogorov – Smirnov o Shapiro–Wilk, ya que para un número de datos <50 el test de Shapiro–Wilk es más efectivo; y un

número de datos >50 es mejor utilizar el test de Kolmogorov – Smirnov. (Frías, 2011).

b) Homocedasticidad: La hipótesis de homocedasticidad establece que la variabilidad de los residuos es independiente de las variables explicativas, es decir solo se deberá examinar el gráfico de valores pronosticados vs residuos al cuadrado. El contraste de esta hipótesis se debe realizar un conjunto de transformaciones que se debe realizar sobre la variable dependiente para conseguir la hipótesis (Frías, 2011).

Existen diferentes autores que enumeran a la normalidad y homocedasticidad como las principales hipótesis, pero existe otra hipótesis que es la siguiente:

c) No auto correlación: Hace referencia a los efectos de la inercia de una observación a otra que pueda indicar la no independencia entre los residuos. Se trata de buscar modelos o pautas en los gráficos residuales frente al número de caso (incluso con cada variable independiente). El contraste Durbin – Watson indica cuando la hipótesis H_0 : no hay autocorrelación, entonces:

Tabla N° 03. Coeficiente Durbin - Watson

Coeficiente Durbin-Watson(d)	Hipótesis
$d < 1.18$	Rechazar
$d > 1.4$	Aceptar
Si $1.18 < d < 1.4$	No es concluyente

Fuente: Pérez, 2001

En el caso que exista autocorrelación se deberían adicionar más variables al análisis de regresión múltiple.

2.5 VALIDACIÓN DE LOS MODELOS DE PREDICCIÓN

2.5.1 Validación cruzada

La validación cruzada o cross-validation es una técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes particiones. Se utiliza en entornos donde el objetivo principal es la predicción y se quiere estimar cómo de preciso es un modelo que se llevará a cabo a la práctica.

Es una técnica muy utilizada en proyectos de inteligencia artificial para validar modelos generados. El estadístico que se utilizó para evaluar la eficiencia de la predicción es el error medio cuadrático.

2.5.2 Error cuadrático medio MSE

Los criterios para seleccionar el mejor modelo están relacionado con el error de predicción. El MSE es un estimador que mide el promedio de los errores al cuadrado, es decir, se utiliza en las estadísticas para dar un valor numérico a la diferencia entre los valores de una estimación y el valor real. El MSE es una función de riesgo, correspondiente al valor esperado de la pérdida del error al cuadrado o pérdida cuadrática. La diferencia se produce debido a la aleatoriedad o porque el estimador no tiene en cuenta la información que podría producir una estimación más precisa.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \gamma_i)^2 \quad (18)$$

Dónde:

Y = Valor predicho

γ = El valor verdadero y cuando menor sea el valor del MSE indican que modelo es mejor.

El MSE es el segundo momento del error, por lo tanto incorpora la varianza del estimador y su sesgo. Para un estimador insesgado, el MSE es la varianza del estimador, al igual que la varianza, el MSE tiene las mismas unidades de medida que el cuadrado de la cantidad que se estima. En una analogía con la desviación estándar, tomando la raíz cuadrada del MSE produce el error de la raíz cuadrada de la media o la desviación de la raíz cuadrada media (RMSE o RMSD), que tienen las mismas unidades que la cantidad que se estima; para un estimador insesgado, el RMSE es la raíz cuadrada de la varianza, conocida como la desviación estándar. (Lehmann et.al., 1998)

2.6 DEFINICIÓN DE TÉRMINOS BÁSICOS

Aprendizaje No Supervisado: Este término se refiere a la colección de técnicas donde se definen agrupaciones de los datos sin el uso de una variable dependiente.

Aprendizaje Supervisado: La colección de técnicas donde el análisis usa una variable dependiente conocida. Se dirige a todas las técnicas la regresión y clasificación.

Asignatura en estudio: Asignatura matriculado que desea realizar la predicción.

Asignatura pre-requisito: Asignatura que apertura la siguiente asignatura del semestre en estudio en el plan de estudio en un periodo académico.

Datos: Los valores coleccionados a través del registro ya sean guardados, observados, o medidos, típicamente organizados para análisis o fabricación de decisiones. Más simplemente, los datos son hechos, transacciones y Gráficos.

Efectividad de aprobación de acuerdo a la calificación: Relación entre el número de asignaturas aprobadas y el número de asignaturas matriculados de un estudiante

Efectividad de aprobación de número de créditos: es la relación entre el número de créditos aprobados y el número de créditos matriculados de un estudiante

FINESI: Facultad de Ingeniería Estadística E Informática

Dificultad de aprobación de la calificación de una asignatura por periodo académico: es la diferencia de veinte menos el promedio de los promedios finales del curso de un periodo académico o semestre.

Dificultad de aprobación de las asignaturas desaprobados: es la relación del número de estudiantes desaprobados entre el número de estudiantes matriculados

Modelo: Un modelo puede ser descriptivo o predictivo. Un modelo descriptivo entiende procesos o conductas subyacentes. Un modelo predictivo es una ecuación o grupo de reglas que hacen posible predecir un valor desconocido (variables dependiente o salida), de otros valores conocidos (variables independientes o entradas).

Nodo: Un punto en una red neuronal que combina entradas de otros nodos y produce salidas a través de la aplicación de una función de activación.

Periodo académico: Es la unidad de tiempo semestral que se establece en un programa académico de formación, destinada al desarrollo de un conjunto de asignaturas y demás actividades académicas.

Predecir: Anunciar por revelación, ciencia o conjetura algo que ha de suceder.

Prueba de Datos (Test Data): Un grupo de datos independiente de los datos de entrenamiento, usados para comparar el comportamiento del modelo

Prueba de Error (Test Error): La estimación de error se basa en la diferencia entre las predicciones de un modelo con un grupo de datos prueba y los valores observados en los datos de la prueba cuando el grupo de datos de prueba no se usó en el entrenamiento del modelo.

Regresión: es la tendencia de una medición extrema a presentarse más cercana a la media en una segunda medición.

Validación: El proceso de comprobación los modelos con un grupo de datos diferente del grupo de datos de entrenamiento.

2.7 OPERACIONALIZACIÓN DE VARIABLES

Tabla Nº 04. Operacionalización de variables

TIPO	VARIABLES	DIMENSIÓN	INDICADOR	ESCALA
DEPENDIENTE	Rendimiento Académico	Área Informática	Calificativo obtenido en una asignatura.	0 – 20
		Área matemática		
INDEPENDIENTE	Nota prerequisite (X1).	Área informática, matemática	Calificativo previo de una asignatura.	0 – 20
	Promedio ponderado del alumno en el semestre previo/20 (X2).	Razones, proporciones de Rendimiento académico	Indicadores de rendimiento académico	0-1
	Promedio ponderado del alumno en el semestre previo acumulado /20 (X3).			
	Promedio ponderado del alumno al semestre previo (X4).	Área informática, matemática	Calificativo previo de una asignatura.	0 – 20
	Promedio ponderado acumulado del alumno al semestre previo(X5).	Razones, proporciones, índices de Rendimiento académico	Indicadores de rendimiento académico	0-1
	Efectividad de aprobación de una asignatura de del alumno de acuerdo a la calificación al semestre previo(X6).			
	Promedio de efectividad de aprobación acumulado del alumno de acuerdo a la calificación hasta el semestre previo(X7).			
	Efectividad de aprobación de una asignatura del alumno de acuerdo a los créditos al semestre previo(x8).			
	Promedio de efectividad de aprobación acumulado del alumno de acuerdo a los créditos hasta el semestre previo(X9).			
	Grado de dificultad de aprobación del alumno de acuerdo a la calificación en una asignatura al semestre previo(X10).			
	Promedio del grado de dificultad acumulada de aprobación del alumno de acuerdo a la calificación de una asignatura al semestre previo(X11).			
	Dificultad de aprobación del alumno de acuerdo a los créditos de una asignatura al semestre previo(X12).			
	Promedio de dificultad de aprobación acumulado del alumno de acuerdo a los créditos hasta el semestre previo(X13).			
	Antigüedad en años desde el año de ingreso a la universidad hasta el año del semestre previo(X14)			
	Promedio ponderado de la asignatura al semestre previo(x15).	Área informática, matemática	Calificativo previo de una asignatura.	0 – 20
	Promedio ponderado acumulado de la asignatura al semestre previo(X16).			
	Dificultad de aprobación de la asignatura al semestre previo(X17).	Razones, proporciones, índices de Rendimiento académico	Indicadores de rendimiento académico	0-1
	Promedio ponderado acumulado de una asignatura de acuerdo al crédito al semestre previo (X18)			
	Grado de dificultad de aprobación una asignatura de acuerdo al crédito matriculado al semestre previo(X19)			
	Dificultad de aprobación de una asignatura acumulada de acuerdo al crédito matriculados(X20)			
Dificultad del curso de acuerdo al crédito desaprobado(X21)				
Número de créditos totales por periodo (X22)	Número de Créditos	Cantidad de Créditos	0- 260	
Sumatoria del promedio del grado de dificultad de acuerdo a la calificación obtenida (X23)	Suman de Promedios	Suma de promedios	0-350	

Fuente: *Elaboración propia.*

CAPÍTULO III

MÉTODOS Y MATERIALES

3.1 TIPO Y MÉTODO DE ESTUDIO

El presente estudio, se consideró de tipo aplicada con el método inductivo - deductivo por que permitió ofrecer la mejor técnica de predicción práctica y concreta para los estudiantes, docentes, administrativos.

3.2 DISEÑO DE ESTUDIO

Dado el tipo de datos que han sido recolectados, se consideró el diseño cuasi-experimental con estrategia transversal, los datos son de una cohorte entre los años 2009 - 2015 todos los registros de los estudiantes de la FINESI de la Universidad Nacional del Altiplano Puno.

3.3 POBLACIÓN Y MUESTRA

Población: La población objetiva para el presente estudio, fue compuesta por todos los estudiantes matriculados durante los años 2009 al 2015, haciendo un total de 696 estudiantes en la FINESI de la Universidad Nacional del Altiplano Puno.

Muestra: Se consideró muestreo intencional de cohorte entre los años 2009-2015, compuesto por 19334 registros de promedios finales de los 696 estudiantes matriculados en la FINESI de la Universidad Nacional del Altiplano Puno

Tabla N° 05. Número de estudiantes ingresantes matriculados por años

AÑO DE INGRESO	ESTUDIANTES MATRICULADOS	AÑO DE INGRESO	ESTUDIANTES MATRICULADOS
<2000	30	2008	35
2001	15	2009	78
2002	13	2010	59
2003	22	2011	21
2004	35	2012	59
2005	66	2013	74
2006	50	2014	51
2007	57	2015	31
TOTAL	288	TOTAL	408

Fuente: Coordinación académica de la FINESI

Tabla N° 06. Número de registros por semestre y periodo académico

SEMESTRE	2009		2010		2011		2012		2013		2014		2015	
	1	2	1	2	1	2	1	2	1	2	1	2	1	2
1	272	236	267	196	99	96	211	172	299	172	193	159	104	135
2	144	186	186	246	211	146	98	186	163	290	185	216	124	137
3	112	117	170	267	179	142	135	137	139	144	201	165	155	217
4	95	92	68	196	156	147	150	87	123	64	116	166	215	156
5	173	110	87	95	111	150	150	133	104	120	118	100	155	141
6	137	142	104	92	94	116	162	174	141	139	160	139	136	127
7	132	165	119	103	101	88	93	115	145	129	106	125	127	106
8	148	155	176	103	71	89	143	124	147	179	129	134	128	178
9	169	127	130	165	110	77	71	51	117	130	162	127	150	128
10	118	121	101	138	123	113	48		63	70	82	72	76	87
Total	1500	1451	1408	1601	1255	1164	1261	1179	1441	1437	1452	1403	1370	1412

Fuente: Coordinación académica de la FINESI.

3.4 MÉTODOS, TÉCNICAS E INSTRUMENTOS DE RECOPIACIÓN DE DATOS

3.4.1 Técnicas de Recolección de datos

Las principales técnicas que se utilizaron para recolectar datos involucrados necesarios en la investigación son:

Tabla N° 07. Técnicas e instrumentos de recopilación de datos

Técnica	Instrumento	Objetivos
-Análisis documental	-Guía de análisis documental -Registros -Actas -Material informático	Ellos lo conforman para la extracción de los promedios finales, plan de estudio de los estudiantes que conforman la muestra.
-Fichaje. -Material virtual.	Fichas de resumen, libros, revistas, páginas web	Para contemplar el marco teórico de la investigación.
-Redes Neuronales Artificiales -Regresión Lineal Múltiple	R studio	-Entrenamiento, Predicción. -Relacionar la variable respuesta con un conjunto de variables predictoras.

Fuente: *Elaboración propia.*

3.4.2 Método de Recolección de datos

Fuente de los datos: para esta investigación fueron proporcionados en archivos de Excel y en fichas en la oficina de coordinación académica de la FINESI de la Universidad Nacional del Altiplano de Puno.

3.4.3 Método de Análisis de Datos

Una vez obtenido los datos a través de los instrumentos de investigación se procede al análisis de datos.

Preparación de datos.

Los datos son procesados, transformados tanto para los entrenamientos como para la validación, con los siguientes programas: MS-Excel 2010 y R.

Tratamiento de datos.

Se utilizó la técnica de regresión lineal para el procesamiento y Análisis de Datos.

Descripción de los datos de entrada.

Para realizar la predicción, se recolecto una cantidad importante de datos para este estudio las cuales son:

El historial académico de promedios finales registrados en la base de datos de la universidad entré los años 2009 y 2015 en la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano Puno en Tabla N° 7. Plan de estudio de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano Puno (anexo2):

Tabla N° 08. Formato plan de estudios de la FINESI 2008-2012.

NOMBRE DE CURSOS	CODIGO CURSO	CRE DITO	PLAN DE ESTUDIO	T	P	TH	SEMES TRE	REQUISITO
MATEMÁTICA SUPERIOR	001-04	3	FLEXIBLE 04	2	2	4	1	NINGUNO
GEOMETRIA VECTORIAL	002-04	3	FLEXIBLE 04	2	2	4	1	NINGUNO
EXPRESION ORAL Y ESCRITA	003-04	3	FLEXIBLE 04	2	2	4	1	NINGUNO
ESTADISTICA INFORMATICA	004-04	5	FLEXIBLE 04	4	2	6	1	NINGUNO
TÉCNICAS DE PROGRAMACIÓN	005-04	4	FLEXIBLE 04	2	4	6	1	NINGUNO
METODOS COMPUTACIONALES	006-04	4	FLEXIBLE 04	2	4	6	1	NINGUNO
CALCULO DIFERENCIAL	007-04	5	FLEXIBLE 04	4	2	6	2	001-04

Fuente: Oficina de coordinación académica de la FINESI

Descripción de los datos del plan de estudios 2008-2012:

- asignaturas obligatorias 199 créditos.
- asignaturas electivas 15 créditos.

Tabla N° 09. Formato plan de estudios de la FINESI 2013-2018

NOMBRE DE CURSOS	CODIGO CURSO	CRE DITO	PLAN DE ESTUDIO	T	P	TH	SEMESTRE	REQUISITO
ESTRATEGIAS DE APRENDIZAJE	005-05	2	FLEXIBLE 05	4	2	6	1	NINGUNO
GESTION Y LIDERAZGO	006-05	2	FLEXIBLE 05	4	2	6	1	NINGUNO
ESTADISTICA MULTIVARIABLE	007-05	5	FLEXIBLE 05	4	2	6	2	001-05
DEMOGRAFIA	008-05	3	FLEXIBLE 05	2	2	4	2	NINGUNO
FUNDAMENTOS DE PROGRAMACION	009-05	4	FLEXIBLE 05	3	2	5	2	002-05
ANALISIS DE SISTEMAS DE INFORMACION	010-05	4	FLEXIBLE 05	3	2	5	2	NINGUNO
ARQUITECTURA DE COMPUTADORAS	011-05	4	FLEXIBLE 05	3	2	5	2	NINGUNO
CALCULO DIFERENCIAL	012-05	4	FLEXIBLE 05	3	2	5	2	004-05

Fuente: Oficina de coordinación académica de la FINESI

Descripción de los datos del plan de estudios 2013-2018:

- 7 asignaturas electivas 21 créditos.
- 61 asignaturas obligatorias 229 créditos.

Selección de datos:

La selección de las asignaturas con sus pre-requisitos del plan de estudio, puesto que en esta investigación se elaboró con los datos históricos del Rendimiento Académico, durante los años 2009 a 2015 hubo dos cambios en el currículo. Los datos de la base histórica académica de los promedios finales de los estudiantes de la FINESI de la Universidad Nacional del Altiplano Puno. Es proporcionado por el coordinador académico del sistema que maneja la OTI (oficina tecnológica informática). Extraído en formato Excel y consolidado queda de esta manera en la siguiente tabla.

Tabla Nº 10. Historial de notas finales de los estudiantes.

Cod_Estudiante	Nota	Plan-Código	Semestre
42754	11	049-04	8
40454	11	049-04	8
33038	11	049-04	8
52683	11	049-04	8
42762	12	049-04	8
42757	12	049-04	8
62000	12	049-04	8
40445	12	049-04	8
40444	12	049-04	8
40443	12	049-04	8

Fuente: Oficina de coordinación académica de la FINESI

Descripción de la base histórica de los promedios finales:

Código de estudiante (COD_EST)

Modalidad de matrícula (MOD_MAT)

Nota de la asignatura (NOTA)

Semestre (SEM)

Periodo Académico (PER_ACAD), la hoja consolidada extraída del sistema académico tiene un total de 22586 registros que son un total de 696 estudiantes de la FINESI.

Limpieza de datos:

Los campos que tienen ambigüedad, para esta investigación son: En modalidad de matrícula: se tiene regular, dirigido, vacacional, para el estudio solo se toma en cuenta regular. Quedando un total de (19334 registros). Las vacacionales son un corto periodo y diferente lineamiento. Nota "0": corresponden a los estudiantes que abandonaron por motivos personales sin realizar ningún tipo de trámite para el retiro.

En el caso de las currículos el código de la asignatura se cambió de nombre, en otras se reemplaza para homogenizar los antiguos código por los códigos

nuevos, estos datos mencionados no serán considerados para la investigación. Eliminado estos datos nos queda 19334 registros y 696 estudiantes nombramos este último archivo

Tabla Nº 11. Plan de estudio homogenizado

CAMPOS	INDICADORES
Código de estudiante (COD_EST).	696 estudiantes.
Modalidad de matrícula (MOD_MAT).	Regular, segunda matrícula, tercera matrícula, cuarta matrícula, quinta matrícula.
Créditos (CRED).	Valores de 3, 4, 5.
Nota de la asignatura (NOTA).	0 a 20
Semestre (SEM).	1 a 10
Nombre del docente (NOM_DOC).	Nombres y apellidos
Periodo Académico PER_ACAD).	2009 – 2015

Fuente: *Elaboración propia.*

Generación de datos para las variables.

Los valores para cada variable se generaron utilizando VBA Excel, de las cuales el siguiente cuadro muestra para dos asignaturas para esta investigación.

Tabla Nº 12. Datos para Regresión y Redes Neuronales

Regresión Lineal Múltiple			
Código de la asignatura	Nº de registros	Aplicación	Prueba
010-05	421	401	20
009-05	479	458	21
Redes Neuronales			
Código de la asignatura	Nº de registros	Aplicación	Prueba
010-05	421	401	20
009-05	479	458	21

Fuente: *Elaboración propia.*

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN DE LA INVESTIGACIÓN

4.1 LAS VARIABLES PREDICTORAS DEL RENDIMIENTO ACADÉMICO

Se procedió a desarrollar las siguientes metodologías para la predicción del rendimiento académico mediante regresión y redes neuronales.

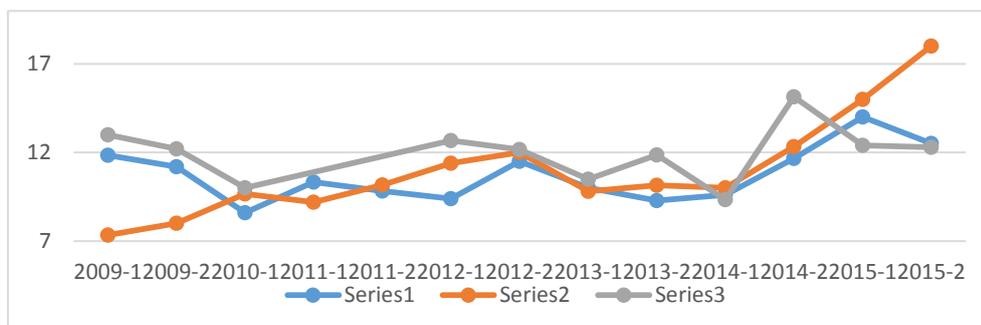
4.1.1 Discusión de las variables.

a) Variables relacionados al rendimiento académico del estudiante.

Promedio ponderado del alumno en el semestre previo acumulado /20 (X3):

Esta variable toma el promedio ponderado de los promedios finales de las asignaturas previas del estudiante.

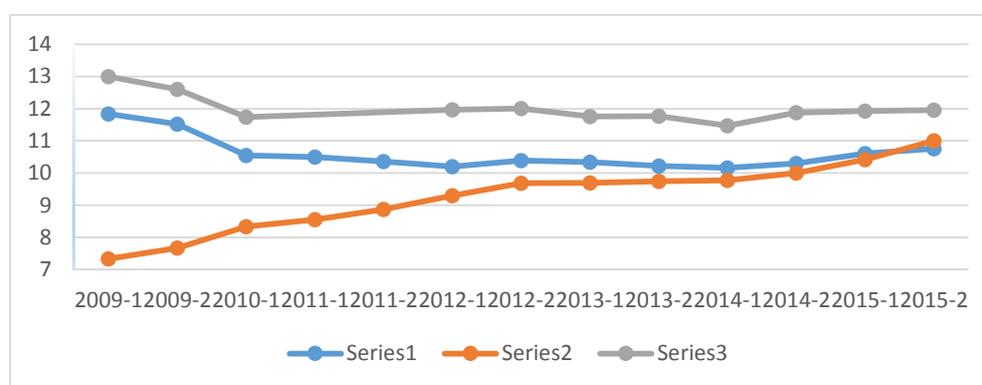
Gráfico N° 11: Promedio ponderado de acuerdo a las los promedios finales por periodo académico.



En la Gráfico anterior se muestra tres estudiantes con promedios irregulares de periodo a periodo.

Promedio ponderado acumulado del alumno al semestre previo (X5): Promedio ponderado de todos los promedios finales obtenidos por el estudiante hasta el semestre previo a matricularse.

Gráfico N° 12: Promedio ponderado acumulado hasta el semestre previo.

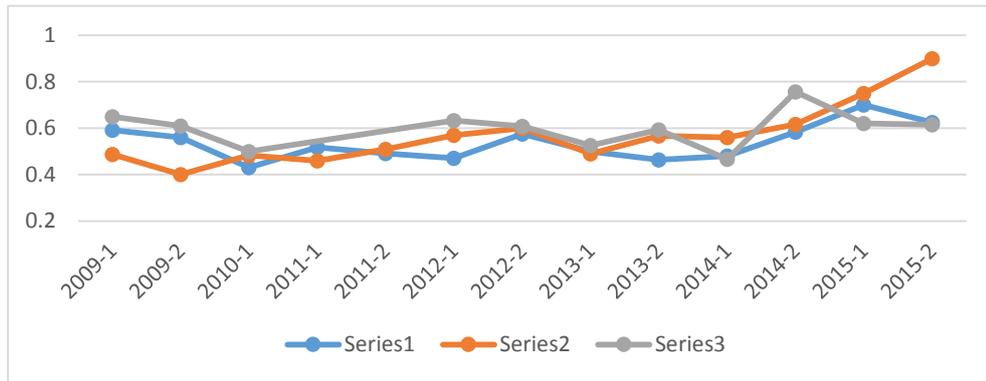


Se puede apreciar que existe una regularidad entre los periodos académico. Esto podría interpretarse que a mayor linealidad mayor probabilidad de predicción. Por tanto seleccionamos esta variable.

Efectividad de aprobación de una asignatura de acuerdo a la calificación al semestre previo (X6): Esta variable se entiende como la proporción de asignaturas aprobadas entre el total de asignaturas matriculadas se establece a través de la siguiente fórmula:

$$\frac{\text{Número de asignaturas aprobadas}}{\text{Número total de asignaturas matriculadas}}$$

Gráfico N° 13: Efectividad de aprobación de acuerdo a la calificaciones del semestre previo.

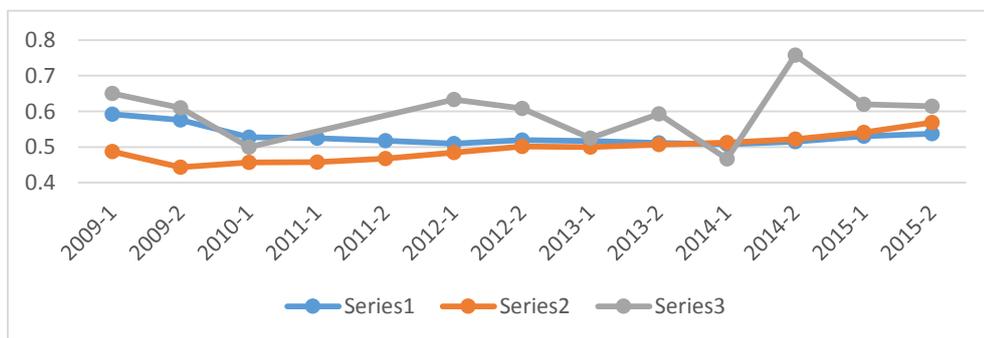


Se observa el comportamiento es cambiante en cada periodo.

Promedio de efectividad acumulado de aprobación de una asignatura de acuerdo a la calificación por semestre hasta el semestre previo(X7): Esta variable se calcula promediando los índices de Efectividad de aprobación de acuerdo a la calificación del semestre previo.

$$PEASP = \frac{\text{SUMA DE EASP}}{\text{NÚMERO TOTAL DE EASP}}$$

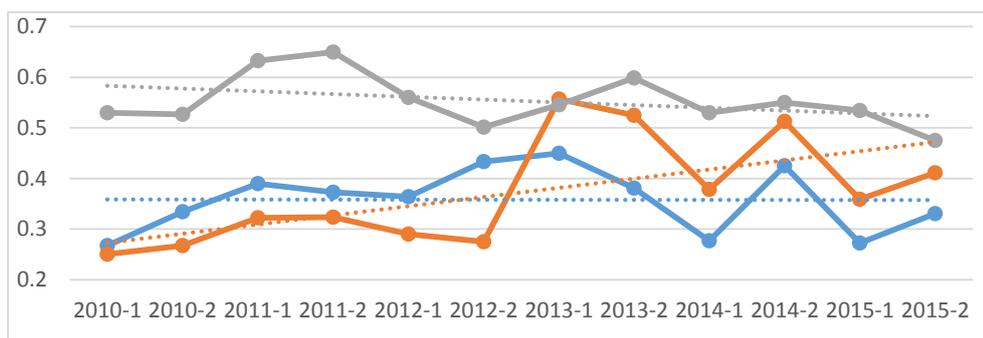
Gráfico N° 14: Promedio de efectividad de aprobación de acuerdo al rendimiento académico por periodo.



En la Gráfico 14 se ve el comportamiento de tres estudiantes, uno de ellos tiene cambio regular por lo que nos indica que esta variable tiene influencia.

Grado de dificultad de aprobación de acuerdo a la calificación de una asignatura(X10): El grado de dificultad de aprobación depende de cada curso, complejidad del curso, llegada del docente al estudiante, rendimiento grupal de los estudiantes, periodo académico.

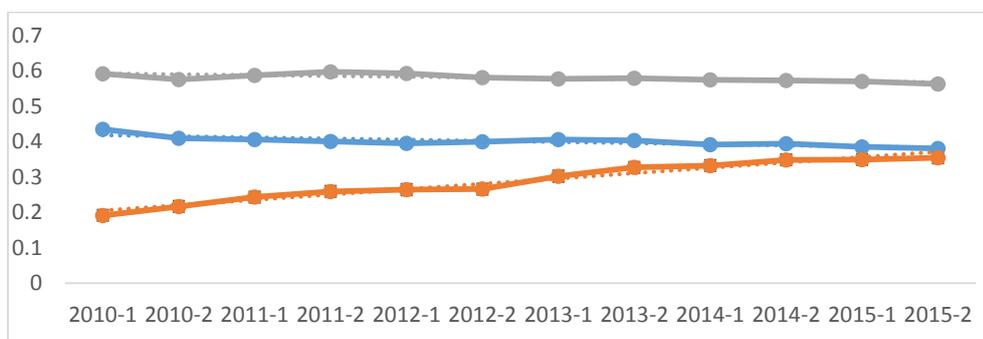
Gráfico N° 15: Grado de dificultad de aprobación de acuerdo a la calificación obtenida en una asignatura en el semestre previo.



De la gráfica 15 se tiene a tres asignaturas que demuestran que son muy cambiantes periodo a periodo por lo que esta variable no influiría.

Promedio del grado de dificultad de aprobación de acuerdo a la calificación por semestre (X11): Esta variable toma el promedio de todo los semestres cursados hasta el último semestre previo a matriculares.

Gráfico N° 16: Grado de dificultad de aprobación de acuerdo a la calificación obtenida en tres asignaturas.



En esta Gráfico N° 16 se muestran tres asignaturas con sus valores que son muy regulares de periodo a periodo por lo se escogeria también esta variable.

Antigüedad en años desde el año de ingreso a la universidad hasta el año del semestre previo(X14): Esta variable número de año curando la carrera, se concluye que cuanto mayor es esta variable, es menor el rendimiento del estudiante.

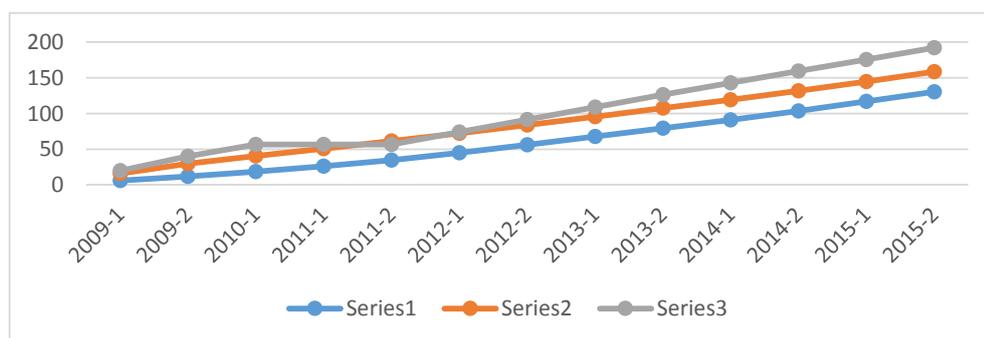
b) Variable relacionados con diseño curricular por competencias.

Las siguientes variables mencionadas se obtuvieron a partir del plan curricular.

Número de créditos totales por periodo(X22): La cantidad de crédito que llevó para matricularse hasta el semestre previo.

Sumatoria del promedio del grado de dificultad de acuerdo a la calificación obtenida (X23):

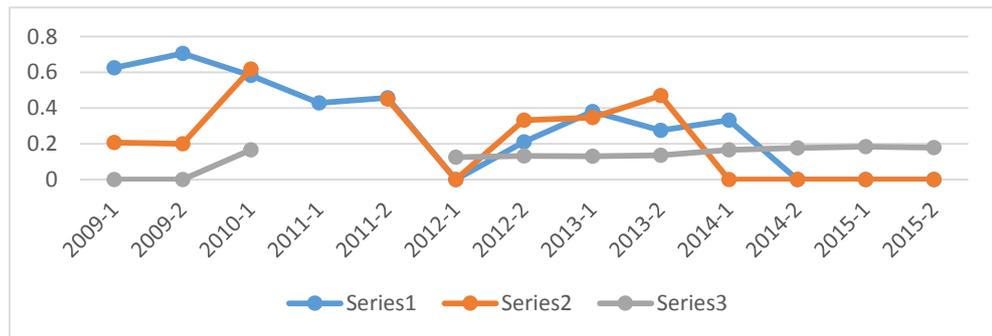
Gráfico N° 17: Sumatoria de promedio de grado de dificultad de acuerdo a la calificación obtenida



En esta grafica 17 se muestran tres estudiantes con valores regulares de periodo a periodo por lo que escogemos también esta variable.

Efectividad de aprobación de acuerdo a los créditos del semestre previo(X8).

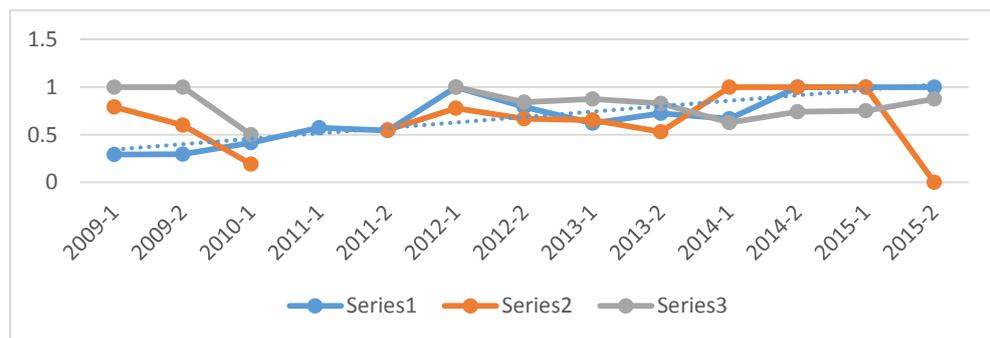
Gráfico N° 18: Efectividad de aprobación de acuerdo a los créditos



Dos de los estudiantes tiene discontinuidad en los periodos académicos como se muestra en la Gráfico 18 tienen tendencia a cambiar por lo que nos indica no se seleccionaría esta variable.

Promedio de efectividad de aprobación de acuerdo a los créditos por semestre hasta el semestre previo(X9).

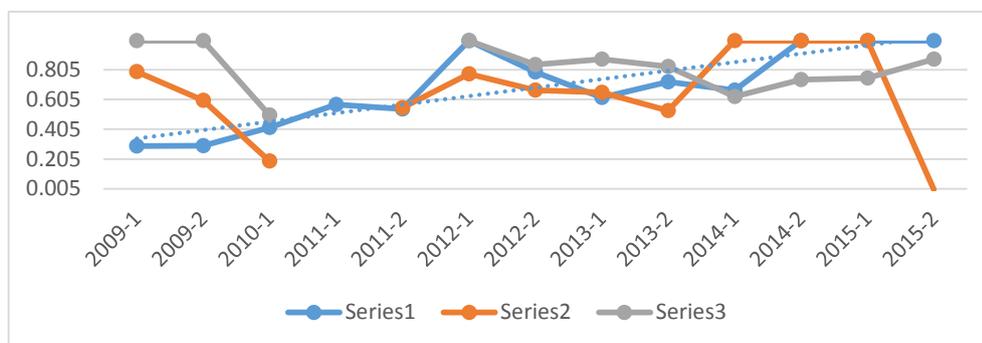
Gráfico N° 19: Promedio de efectividad de aprobación de acuerdo a los créditos aprobados hasta el semestre previo.



Dos de los estudiantes tienen discontinuidad en los periodos académicos debido a que no se matricularon en estos periodos por lo que tienen irregularidades en los periodos.

Grado de dificultad de aprobación de acuerdo a los créditos de una asignatura en el semestre previo (X17).

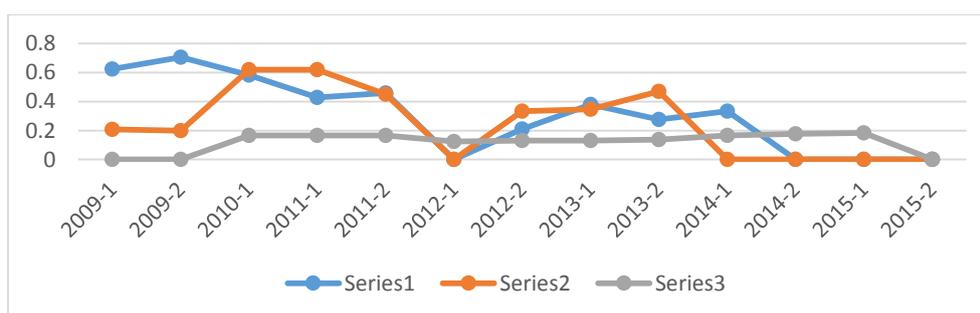
Gráfico N° 20: Promedio Grado de dificultad de aprobación de acuerdo a los créditos de una asignatura en el semestre previo.



Dos de los estudiantes tiene discontinuidad en los periodos académicos como se muestra esto debido a que no se matricularon en estos periodos.

Promedio del grado de dificultad de aprobación de acuerdo a los créditos por semestre hasta el semestre previo (X19):

Gráfico N° 21: Promedio del grado de dificultad de aprobación de acuerdo a los créditos por semestre hasta el semestre previo



En la Gráfico N° 14 se muestran datos irregulares por tanto descartamos esta variable.

Nota prerequisite(x1): a mayor la calificación del prerequisite mayor será la probabilidad de aprobar el curso.

4.1.2 Descripción de variables

Las variables mencionadas a continuación son:

- Variables dependientes: Rendimiento académico (Y).
- Variables independientes (X): A continuación se describe las variables más resaltantes en la Tabla N° 13:

Tabla N° 13. Variables independientes considerados para los modelos

VARIABLES PARA REGRESIÓN Y REDES NEURONALES	
Nota pre-requisito (X1).	Promedio de dificultad de aprobación acumulado del alumno de acuerdo a los créditos hasta el semestre previo(X13).
Promedio ponderado del alumno en el semestre previo/20 (X2).	Antigüedad en años desde el año de ingreso a la universidad hasta el año del semestre previo(X14)
Promedio ponderado del alumno en el semestre previo acumulado /20 (X3).	Promedio ponderado de la asignatura al semestre previo(x15).
Promedio ponderado del alumno al semestre previo (X4).	Promedio ponderado acumulado de la asignatura al semestre previo(X16).
Promedio ponderado acumulado del alumno al semestre previo(X5).	Dificultad de aprobación de la asignatura al semestre previo(X17).
Efectividad de aprobación de una asignatura de del alumno de acuerdo a la calificación al semestre previo(X6).	Promedio ponderado acumulado de una asignatura de acuerdo al crédito al semestre previo (X18)
Promedio de efectividad de aprobación acumulado del alumno de acuerdo a la calificación hasta el semestre previo(X7).	Grado de dificultad de aprobación una asignatura de acuerdo al crédito matriculado al semestre previo(X19)
Efectividad de aprobación de una asignatura del alumno de acuerdo a los créditos al semestre previo(x8).	Dificultad de aprobación de una asignatura acumulada de acuerdo al crédito matriculados(X20)
Promedio de efectividad de aprobación acumulado del alumno de acuerdo a los créditos hasta el semestre previo(X9).	Dificultad del curso de acuerdo al crédito desaprobado(X21)
Grado de dificultad de aprobación del alumno de acuerdo a la calificación en una asignatura al semestre previo(X10).	Número de créditos totales por periodo (X22)
Promedio del grado de dificultad acumulada de aprobación del alumno de acuerdo a la calificación de una asignatura al semestre previo(X11).	Sumatoria del promedio del grado de dificultad de acuerdo a la calificación obtenida (X23)
Dificultad de aprobación del alumno de acuerdo a los créditos de una asignatura al semestre previo(X12).	

Fuente: *Elaboración propia*

4.1.3 Matriz de correlaciones de las variables

En un primer momento en el estudio de un modelo de regresión lineal múltiple al realizar la matriz de correlación para definir existencia de relación lineal o de otro tipo entre todas las variables mediante método Pearson se obtuvo los siguientes resultados.

Tabla N° 14. Correlación entre todos los variables.

	RA	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20	X21	X22	X23
RA	1	0.849	-0.03	0.734	0.799	0.687	0.792	0.68	-0.69	-0.25	-0.02	0.057	0.089	-0.1	-0.04	-0	0.037	-0.04	-0	-0.91	0.786	-0.81	0.651	0.797
X1	0.849	1	-0.07	0.848	0.932	0.802	0.927	0.796	-0.8	-0.29	-0.07	0.175	0.189	-0.18	-0.14	0.04	0.096	-0.05	-0.01	-0.75	0.916	-0.65	0.669	0.894
X2	-0.03	-0.07	1	-0.12	-0.07	-0.16	-0.06	-0.14	0.141	0.31	0.427	-0.58	-0.58	0.48	0.599	-0.69	6E-04	0.085	-0.11	-0.05	-0.04	-0.14	-0.15	-0.12
X3	0.734	0.848	-0.12	1	0.767	0.943	0.762	0.941	-0.94	-0.23	-0.05	0.119	0.148	-0.13	-0.09	0.021	0.071	-0.04	0.007	-0.71	0.759	-0.6	0.698	0.874
X4	0.799	0.932	-0.07	0.767	1	0.807	0.997	0.801	-0.8	-0.21	-0.06	0.15	0.147	-0.12	-0.11	0.037	0.082	-0.04	0.015	-0.69	0.99	-0.64	0.623	0.825
X5	0.687	0.802	-0.16	0.943	0.807	1	0.802	0.996	-0.99	-0.15	-0.02	0.112	0.114	-0.08	-0.06	0.036	0.03	0.006	0.078	-0.64	0.797	-0.58	0.678	0.826
X6	0.792	0.927	-0.06	0.762	0.997	0.802	1	0.8	-0.8	-0.2	-0.06	0.15	0.145	-0.12	-0.11	0.023	0.092	-0.05	0.007	-0.69	0.993	-0.63	0.617	0.818
X7	0.68	0.796	-0.14	0.941	0.801	0.996	0.8	1	-0.99	-0.15	-0.02	0.112	0.11	-0.08	-0.06	0.012	0.049	-0	0.063	-0.64	0.796	-0.58	0.673	0.822
X8	-0.69	-0.8	0.141	-0.94	-0.8	-0.99	-0.8	-0.99	1	0.147	0.028	-0.11	-0.11	0.084	0.06	-0	-0.06	0.009	-0.05	0.639	-0.8	0.582	-0.68	-0.82
X9	-0.25	-0.29	0.31	-0.23	-0.21	-0.15	-0.2	-0.15	0.147	1	0.389	-0.51	-0.6	0.619	0.544	-0.23	-0.32	0.305	0.294	0.288	-0.2	0.027	-0.12	-0.23
X10	-0.02	-0.07	0.427	-0.05	-0.06	-0.02	-0.06	-0.02	0.028	0.389	1	-0.74	-0.88	0.882	0.81	-0.43	-0.46	0.828	0.458	-0.03	-0.06	-0.14	0.021	-0.05
X11	0.057	0.175	-0.58	0.119	0.15	0.112	0.15	0.112	-0.11	-0.51	-0.74	1	0.895	-0.79	-0.96	0.421	0.612	-0.46	-0.38	0.016	0.146	0.122	0.046	0.141
X12	0.089	0.189	-0.58	0.148	0.147	0.114	0.145	0.11	-0.11	-0.6	-0.88	0.895	1	-0.96	-0.93	0.562	0.407	-0.62	-0.3	-0.01	0.14	0.132	0.033	0.138
X13	-0.1	-0.18	0.48	-0.13	-0.12	-0.08	-0.12	-0.08	0.084	0.619	0.882	-0.79	-0.96	1	0.878	-0.48	-0.36	0.669	0.346	0.024	-0.11	-0.11	-0.04	-0.13
X14	-0.04	-0.14	0.599	-0.09	-0.11	-0.06	-0.11	-0.06	0.06	0.544	0.81	-0.96	-0.93	0.878	1	-0.53	-0.54	0.519	0.45	-0.03	-0.1	-0.14	-0.04	-0.12
X15	-0	0.04	-0.69	0.021	0.037	0.036	0.023	0.012	-0	-0.23	-0.43	0.421	0.562	-0.48	-0.53	1	-0.32	-0.05	0.287	0.122	0.013	0.188	-0.07	9E-04
X16	0.037	0.096	6E-04	0.071	0.082	0.03	0.092	0.049	-0.06	-0.32	-0.46	0.612	0.407	-0.36	-0.54	-0.32	1	-0.57	-0.86	-0.08	0.1	-0.02	0.103	0.126
X17	-0.04	-0.05	0.085	-0.04	-0.04	0.006	-0.05	-0	0.009	0.305	0.828	-0.46	-0.62	0.669	0.519	-0.05	-0.57	1	0.611	0.04	-0.05	-0.05	0.006	-0.03
X18	-0.91	-0.75	-0.05	-0.71	-0.69	-0.64	-0.69	-0.64	0.639	0.288	-0.03	0.016	-0.01	0.024	-0.03	0.122	-0.08	0.04	0.063	1	-0.68	0.874	-0.56	-0.73
X20	-0.91	-0.75	-0.05	-0.71	-0.69	-0.64	-0.69	-0.64	0.639	0.288	-0.03	0.016	-0.01	0.024	-0.03	0.122	-0.08	0.04	0.063	1	-0.68	0.874	-0.56	-0.73
X20	0.786	0.916	-0.04	0.759	0.99	0.797	0.993	0.796	-0.8	-0.2	-0.06	0.146	0.14	-0.11	-0.1	0.013	0.1	-0.05	-0	-0.68	1	-0.63	0.606	0.81
X21	-0.81	-0.65	-0.14	-0.6	-0.64	-0.58	-0.63	-0.58	0.582	0.027	-0.14	0.122	0.132	-0.11	-0.14	0.188	-0.02	-0.05	0.023	0.874	-0.63	1	-0.52	-0.64
X22	0.651	0.669	-0.15	0.698	0.623	0.678	0.617	0.673	-0.68	-0.12	0.021	0.046	0.033	-0.04	-0.04	-0.07	0.103	0.006	-0.09	-0.56	0.606	-0.52	1	0.885
X23	0.797	0.894	-0.12	0.874	0.825	0.826	0.818	0.822	-0.82	-0.23	-0.05	0.141	0.138	-0.13	-0.12	9E-04	0.126	-0.03	-0.07	-0.73	0.81	-0.64	0.885	1

Se utilizó el coeficiente de correlación de Pearson para examinar la fuerza y la dirección de la relación lineal entre dos variables continuas.

INTERPRETACIÓN: Como se observa en la tabla 12, la variable independiente que mejor correlación tiene con variable dependiente es X1 con valor de 0.85 y X4, X23, con 0.80, mientras que las mejores correlaciones negativas con el variable dependiente son X18, X20 con -0.91.

Se observó que las variables independientes que obtuvieron correlación lineal positivamente mayores al 0.70 fueron X1, X3, X4, X6, X20, X23 y negativamente mayores al 0.70 fueron X18, X20, X21.

Las variables X5, X7, X8, X22 tuvieron una correlación moderado entre 0.30 y 0.70 de coeficiente de correlación con variable dependiente. Las variables X2, X9, X10, X11, X12, X13, X14, X15, X16, X17 resaltaron con una correlación bajo menores a ± 0.30 .

4.1.4 Selección de variables predictoras

Para seleccionar las variables predictoras del rendimiento académico, se realizó la prueba de significancia para determinar la relación existente. La Tabla N° 14 muestra los resultados que nos ayudara a comprobar si la correlación es significativa.

Tabla N° 15. Matriz de significancia valor $p < 0.05$

	RA	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20	X21	X22	X23	
RA	0.00	0.00	0.57	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.66	0.25	0.07	0.05	0.37	1.00	0.47	0.38	0.96	0.00	0.00	0.00	0.00	0.00	
X1	0.00	0.00	0.17	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.16	0.00	0.00	0.00	0.00	0.42	0.06	0.27	0.91	0.00	0.00	0.00	0.00	0.00	
X2	0.57	0.17	0.00	0.02	0.17	0.00	0.24	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.99	0.09	0.03	0.29	0.37	0.00	0.00	0.00	0.01	
X3	0.00	0.00	0.02	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.29	0.02	0.00	0.01	0.09	0.67	0.16	0.37	0.89	0.00	0.00	0.00	0.00	0.00	
X4	0.00	0.00	0.17	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.25	0.00	0.00	0.02	0.03	0.47	0.10	0.41	0.77	0.00	0.00	0.00	0.00	0.00	
X5	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.66	0.03	0.02	0.10	0.23	0.47	0.54	0.91	0.12	0.00	0.00	0.00	0.00	0.00	
X6	0.00	0.00	0.24	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.22	0.00	0.00	0.02	0.03	0.65	0.07	0.32	0.89	0.00	0.00	0.00	0.00	0.00	
X7	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.64	0.03	0.03	0.12	0.26	0.81	0.32	0.97	0.21	0.00	0.00	0.00	0.00	0.00	
X8	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.57	0.02	0.02	0.09	0.23	0.94	0.25	0.86	0.29	0.00	0.00	0.00	0.00	0.00	
X9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.59	0.01	0.00	
X10	0.66	0.16	0.00	0.29	0.25	0.66	0.22	0.64	0.57	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.50	0.24	0.01	0.67	0.33
X11	0.25	0.00	0.00	0.02	0.00	0.03	0.00	0.03	0.02	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.76	0.00	0.02	0.35	0.00	
X12	0.07	0.00	0.00	0.00	0.00	0.02	0.00	0.03	0.02	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.91	0.00	0.01	0.51	0.01	
X13	0.05	0.00	0.00	0.01	0.02	0.10	0.02	0.12	0.09	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.63	0.02	0.03	0.48	0.01	
X14	0.37	0.00	0.00	0.09	0.03	0.23	0.03	0.26	0.23	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.49	0.04	0.01	0.47	0.02	
X15	1.00	0.42	0.00	0.67	0.47	0.47	0.65	0.81	0.94	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.29	0.00	0.01	0.80	0.00	0.16	0.99	
X16	0.47	0.06	0.99	0.16	0.10	0.54	0.07	0.32	0.25	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.09	0.05	0.63	0.04	0.01	
X17	0.38	0.27	0.09	0.37	0.41	0.91	0.32	0.97	0.86	0.00	0.00	0.00	0.00	0.00	0.00	0.29	0.00	0.00	0.00	0.42	0.30	0.35	0.90	0.49	
X18	0.96	0.91	0.03	0.89	0.77	0.12	0.89	0.21	0.29	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.21	0.99	0.64	0.07	0.19	
X19	0.00	0.00	0.29	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.50	0.76	0.91	0.63	0.49	0.01	0.09	0.42	0.21	0.00	0.00	0.00	0.00	0.00	
X20	0.00	0.00	0.37	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.24	0.00	0.00	0.02	0.04	0.80	0.05	0.30	0.99	0.00	0.00	0.00	0.00	0.00	
X21	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.59	0.01	0.02	0.01	0.03	0.01	0.00	0.63	0.35	0.64	0.00	0.00	0.00	0.00	0.00	
X22	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.67	0.35	0.51	0.48	0.47	0.16	0.04	0.90	0.07	0.00	0.00	0.00	0.00	0.00	
X23	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.33	0.00	0.01	0.01	0.02	0.99	0.01	0.49	0.19	0.00	0.00	0.00	0.00	0.00	

INTERPRETACIÓN: En la Tabla N° 15 podemos observar que existen correlaciones significativas en la mayoría de las variables independientes, siendo X9 con mayor número de variables de correlacione significativa, también se consiguió que las variables predictoras presentan correlacion no significativa $p > 0.05$ son 5 que tienen poca importancia, las variables son X2, X10, X14, X15, X16, X17, X18. Concluyendo se utilizará las 23 variables para

las predicciones con el fin de comparar las técnica de regresión lineal múltiple con las redes neuronales.

4.2 MODELO DE REGRESIÓN LINEAL MÚLTIPLE APLICADO A LA PREDICCIÓN DEL RENDIMIENTO ACADÉMICO

A partir de la descripción de las variables se procede a realizar los modelos iniciando con el método de análisis de regresión múltiple. Se procederá a formar los 2 modelos para los dos cursos.

4.2.1 Análisis de regresión lineal múltiple en R

4.2.1.1 Ajuste del modelo

A partir de los análisis realizados previamente se optó por realizar un modelo lineal múltiple, se seleccionó las variables con el método Método Stepwise obteniendo $k = 16$ para la asignatura 010-05. Ajustando el modelo se obtuvo el siguiente resumen en R estudió:

MODELO FINAL ESTIMADO

El modelo regresión final para asignatura 010-05 queda de esta manera:

$$\hat{Y} = 16.2867 + 11.54 * X1 - 3.9125 * X3 + 6.1236 * X4 - 6.0202 * X6 - 4.5814 * X7 - 5.6646 * X8 + 1.5 * X9 + 1.9827 * X10 - 1.4488 * X13 + 0.80 * X15 - 1.0649 * X16 - 0.6898 * X17 - 1.64 * X19 - 9.62 * X21 + 6.726 * X22 - 7.75 * X23$$

Donde:

\hat{Y} : Rendimiento académico

$X1, X3, \dots, X23$: Variables predictoras

Tabla N° 16. Resultados del ajuste del modelo de la asignatura 010-05.

Residuals:					
	Min	1Q	Median	3Q	Max
	-4.0829	-0.5432	0.112	0.5963	2.877
Coefficients:					
	Estimate	Std.	Error	t valor	Pr(> t)
(Intercept)	16.287	1.9266	8.454	5.99E-16	***
X1	11.542	1.3087	8.819	2.00E-16	***
X3	-3.9125	1.443	-2.711	0.007	**
X4	6.1236	2.4372	2.513	0.0124	*
X6	-6.0202	2.3505	-2.561	0.01081	*
X7	-4.5814	1.8732	-2.446	0.0149	*
X8	-5.6646	1.7704	-3.2	0.00149	**
X9	1.5992	0.4053	3.945	9.48E-05	***
X10	1.9827	1.015	1.954	0.05149	.
X13	-1.4488	0.6562	-2.208	0.02784	*
X15	0.8047	0.3636	2.213	0.02748	*
X16	-1.0649	0.4868	-2.187	0.02932	*
X17	-0.6898	0.3902	-1.768	0.07792	.
X19	-1.6437	0.71	-2.315	0.02114	*
X21	-9.6216	0.3329	-28.9	2.00E-16	***
X22	6.7267	0.8092	8.312	1.65E-15	***
X23	-7.7583	1.2182	-6.369	5.46E-10	***
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1					
Residual standard error: 0.9612 on 383 degrees of freedom					
Múltiple R-squared: 0.9238			Ajuste R-squared: 0.9206		
F-statistic: 290.2 on 16 and 383 DF			p-value: < 2.2e-16		

INTERPRETACIÓN: Se obtuvo un gran modelo que fue capaz de explicar con $R^2=0.92$ donde todas las variables son significativas, el error del modelo es de 0.9612, el valor de p es muy pequeño $2.2e-16$ se observó que los datos son influyentes.

Para la asignatura 009-05, también se optó por un modelo lineal múltiple, seleccionando con el método Método Stepwise se obtuvo $k = 16$ variables ajustando el modelo se obtuvo el siguiente resumen en R estudió:

Tabla N° 17. Resultados del ajuste del modelo de la asignatura 009-05.

Residuals:					
Min	1Q	Median	3Q	Max	Max
-4.0829	-0.5432	0.112	0.5963	2.877	2.877
Coefficients:					
	Estimate	Std.	Error	t valor	Pr(> t)
(Intercept)	-8.76389	1.95	-4.495	9E-06	***
X1	0.68916	0.111	6.206	1E-09	***
X2	0.19346	0.034	5.642	3E-08	***
X3	0.26897	0.141	1.911	0.057	.
X4	-0.54254	0.237	-2.288	0.023	*
X5	-0.57109	0.161	-3.553	4E-04	***
X6	0.50723	0.223	2.279	0.023	*
X9	-0.31472	0.143	-2.197	0.029	*
X10	0.29069	0.085	3.438	6E-04	***
X11	16.50897	4.645	3.554	4E-04	***
X13	0.60257	0.195	3.087	0.002	**
X14	15.02119	4.485	3.349	9E-04	***
X15	0.35945	0.138	2.598	0.01	**
X16	-7.76481	2.822	-2.751	0.006	**
X17	-0.56769	0.131	-4.341	2E-05	***
X18	-6.66311	2.746	-2.427	0.016	*
X19	0.40522	0.137	2.957	0.003	**
X21	-0.15662	0.021	-7.499	4E-13	***
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1					
Residual standard error: 0.1092 on 440 degrees of freedom					
Múltiple R-squared: 0.729			Ajuste R-squared: 0.7186		
F-statistic: 69.64 on 17 and 440 DF			p-value: < 2.2e-16		

INTERPRETACIÓN: El modelo explicó con $R^2=0.72$ donde todas las variables son significativas, el error del modelo es de 0.1092, p es menor a 2.2e-16.

MODELO FINAL ESTIMADO: El modelo regresión final de la asignatura 009-05 queda de esta manera:

$$\hat{Y} = -8.76389 + 0.68916 * X1 + 0.19346 * X2 + 0.26897 * X3 - 0.54254 * X4 - \\ -0.57109 * X5 + 0.50723 * X6 - 0.31472 * X9 - 0.29069 * X10 + 16.50897 * X11 + \\ 0.60257 * X13 + 15.02119 * X14 - 0.35945 * X15 - 7.76481 * X16 - 0.56769 * X17 - \\ 6.6631 * X18 + 0.4052 * X19 - 0.15662 * X21$$

Donde:

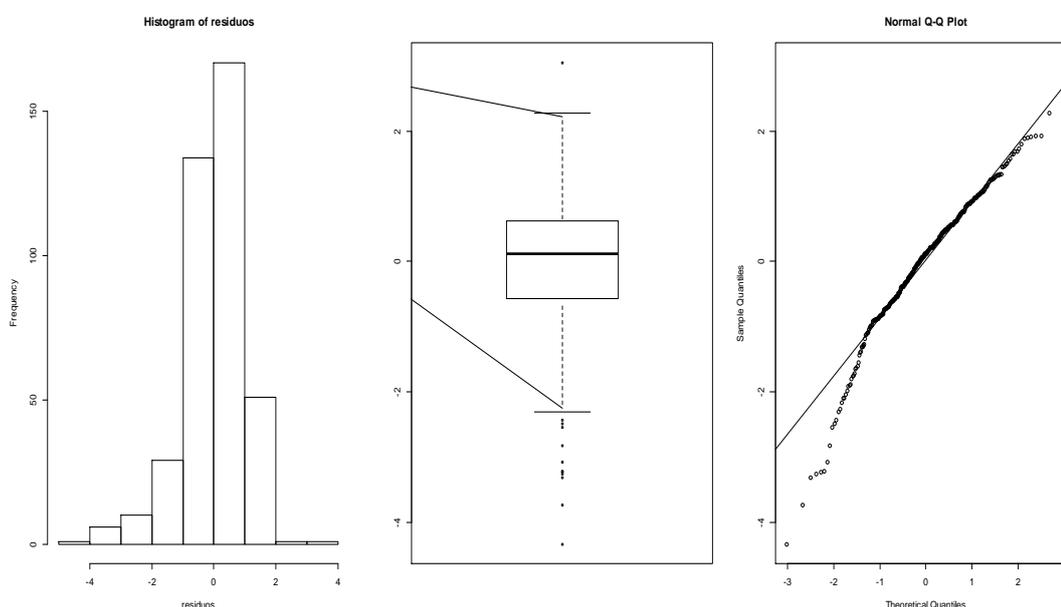
\hat{Y} : Rendimiento académico

X_1, X_2, \dots, X_{21} : Variables predictoras

4.2.1.2 Análisis de residuos

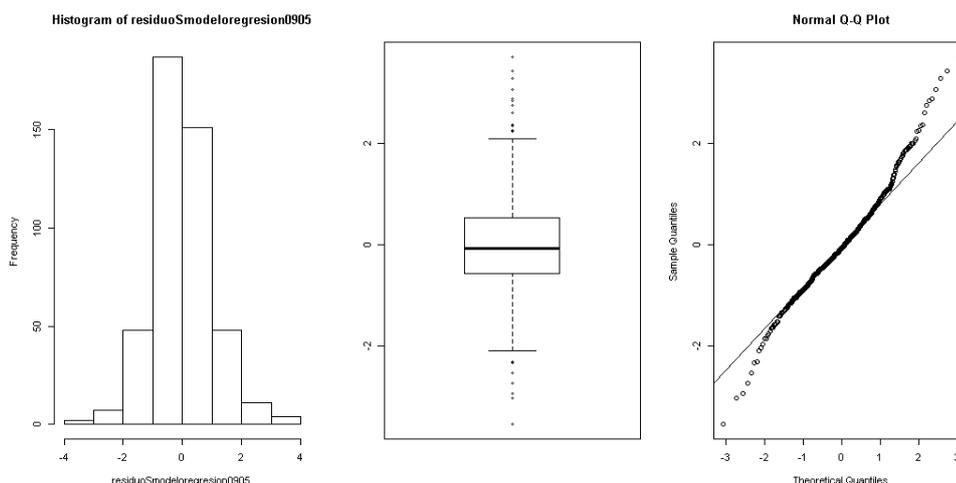
Se realizó el análisis de residuos estándares del modelo ajustado se obtuvo la siguiente gráfica.

Gráfico N° 22: Normalidad de los residuos de la asignatura 010-05.



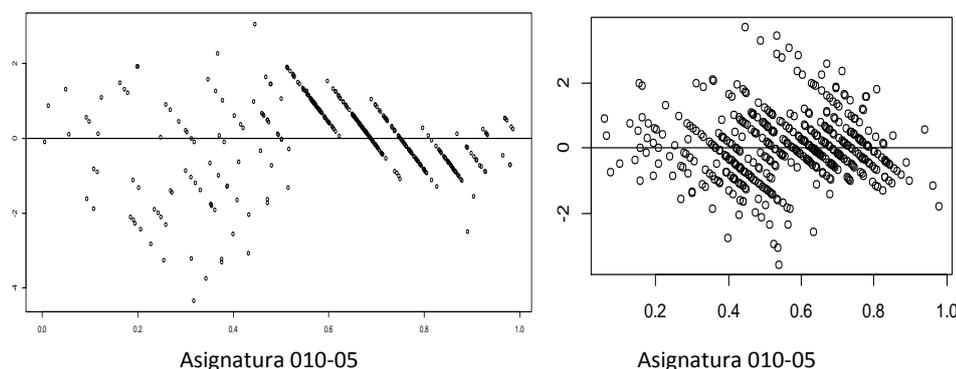
INTERPRETACIÓN: El histograma de los residuos estandarizados revela un patrón ligero simétrico que no es perfecto con forma de campana, lo que indica que los residuos no son asimétricos existe normalidad tanto en diagrama de cajas como en el gráfico de cuantiles de los residuos estandarizados. Esto nos está indicando que la distribución de los residuos es normal. El test de normalidad de Shapiro-Wilks, así como el de Kolmogorov-Smirnov para normalidad, la distribución es normal p -valor= $7.632e-09$ y p -valor= 0.1204 , respectivamente.

Gráfico N° 23: Normalidad de los residuos de la asignatura 009-05



INTERPRETACIÓN: El histograma de los residuos estandarizados revela un patrón asimétrico con forma de campana, existe normalidad tanto en diagrama de cajas, tenemos que la mayoría de puntos se encuentran cercanos a la recta (todos salvo algunos extremos). Esto nos está indicando que la distribución de los residuos es normal. El test de normalidad de Shapiro-Wilks, así como el de Kolmogorov-Smirnov para normalidad, la distribución es normal $p\text{-valor} = 9.054e-06$ y $p\text{-valor} = 0.1883$, respectivamente.

Gráfico N° 24: Valores ajustados vs. Residuos estandarizados.



INTERPRETACIÓN: La varianza de los errores son constantes entre los valores ajustados y los residuos estandarizados para las dos asignaturas.

4.2.1.3 Predicciones de los modelos

Después de obtener los modelos de regresión se pasa a predecir los promedios finales de cada una de las asignaturas.

Tabla Nº 18. Predicción de las asignaturas 010-05 y 009-05

	010-05			009-05		
	Predicción	Real	Residual	Predicción	Real	Residual
1	0.795754	0.625	0.171	0.619318	0.578947	0.040371
2	0.785003	0.625	0.16	0.452011	0.526316	-0.07431
3	0.66623	0.625	0.041	0.472496	0.526316	-0.05382
4	0.774748	0.625	0.15	0.493209	0.526316	-0.03311
5	0.703176	0.5625	0.141	0.51916	0.526316	-0.00716
6	0.5376	0.5	0.038	0.708705	0.736842	-0.02814
7	0.558639	0.5	0.059	0.632899	0.631579	0.00132
8	0.709147	0.5	0.209	0.512717	0.578947	-0.06623
9	0.594869	0.4375	0.157	0.718234	0.736842	-0.01861
10	0.375546	0.4375	-0.06	0.665573	0.684211	-0.01864
11	0.620964	0.4375	0.183	0.576982	0.631579	-0.0546
12	0.568579	0.4375	0.131	0.617888	0.631579	-0.01369
13	0.578818	0.4375	0.141	0.582343	0.631579	-0.04924
14	0.694214	0.4375	0.257	0.629433	0.631579	-0.00215
15	0.540935	0.4375	0.103	0.538435	0.578947	-0.04051
16	0.651331	0.375	0.276	0.474564	0.526316	-0.05175
17	0.40982	0.3125	0.097	0.546604	0.526316	0.020289
18	0.509062	0.3125	0.197	0.600093	0.526316	0.073777
19	0.169796	0.1875	-0.02	0.53777	0.526316	0.011454
20	0.328989	0.125	0.204	0.590253	0.526316	0.063937
21	0.253985	0.125	0.129			

Tabla Nº 19. MSE de las asignaturas 010-05 y 009-05

010-05	009-05
MSE = 0.00321637217	MSE = 0.3729119

INTERPRETACIÓN: El mejor Error Cuadrático Medio (MSE) que se obtuvo fue la asignatura 010-05, los resultados del cuadro anterior, nos permite inferir que la predicción de la asignatura 010-05 es superior a 009-05.

4.3 MODELO DE REDES NEURONALES APLICADO A LA PREDICCIÓN DEL RENDIMIENTO ACADÉMICO

Para la implementación de un modelo de redes neuronales en la predicción de rendimiento académico de los estudiantes se utilizó lenguaje de programación R.

4.3.1 Selección de variables.

Se eligió variables de las investigaciones antecedentes relacionadas al rendimiento académico, se creó variables a partir de otras variables e índices, algunas proporcionaron con más precisión a los modelo como se muestra en la Tabla N° 13 variables independientes considerados para los modelos, las cuales se seleccionaron mediante el método stepwise en la sección 4.2.1.1 obteniendo 17 variables para la asignatura 009-05 y 16 variables para 010-05.

4.3.2 Recolección de datos.

En esta etapa de la recolección de datos válidos, confiables es vital para diseñar y construir el modelo, los datos fueron proporcionados por la oficina de Coordinación académica de la FINESI desde diferentes repositorios y registros de datos de los estudiantes desde 2009 a 2015 que se acopió para este trabajo, los que se detallan en la Tabla N° 10 Campos de la base histórica de los promedios finales de los estudiantes en la sección 3.4.3 Método de Análisis de Datos.

4.3.3 Preparación de datos

Para dar consistencia en los datos y mejorar la eficiencia del modelo de predicción la preparación de datos va generar un conjunto más pequeño que el original. Esto se logra a través de la selección relevante de los datos (eliminación de registros repetidos, anomalías) y la reducción de los mismos (selección de características y variables a utilizar, eliminación de información irrelevante para el estudio).

En los casos se utilizaron los primeros registros para el conjunto de entrenamiento de 90%, para la validación 10% de los registros que se reservaron para estimar el error de cada método que se muestra en la Tabla N° 12.

Limpieza adicional de datos obtenidos para las variables

Para estructurar el modelo de predicción con las variables clasificados en grupos se consolidaron los datos de los periodos académicos 2009-I hasta 2015-II para el entrenamiento y para la validación.

Normalización

La transformación de los datos para las variables (normalización) para mejorar el trabajo de las funciones de transferencia y la habilidad de la red para generalizar, los valores de las variables se normalizan con la función

Min-Max: Transformación lineal que lleva el rango original de las variables al intervalo $(-1, 1)$.

$$X' = \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right)$$

Donde:

X' = Valor de la Variable después de la normalización

X = Valor de la variable

X_{min} = Valor mínimo de la variable

X_{max} = Valor máximo de la variable

4.3.4 Conjunto de entrenamiento, validación y prueba

Para el conjunto de entrenamiento, validación se trabajó con los datos de los periodos académicos 2009-I hasta 2015-II, se dividieron en 2 sub muestras por asignatura en dividiendo en 90% para entrenamiento y 10% validación.

4.3.5 Selección de la configuración interna

No existe una metodología suficientemente clara y rigurosa a la hora de aplicar esta técnica, según Coakley y Brown (2000) asignar el número de capas ocultas y el número de neuronas en cada capa forma todavía parte del arte del uso de las redes neuronales. Para la implementación de las RNAs en este trabajo se consideró lo siguiente:

Número de capas

La red seleccionada contiene en general tres capas 1 capa de entrada, 1 capa oculta y 1 capa de salida.

Número de neuronas

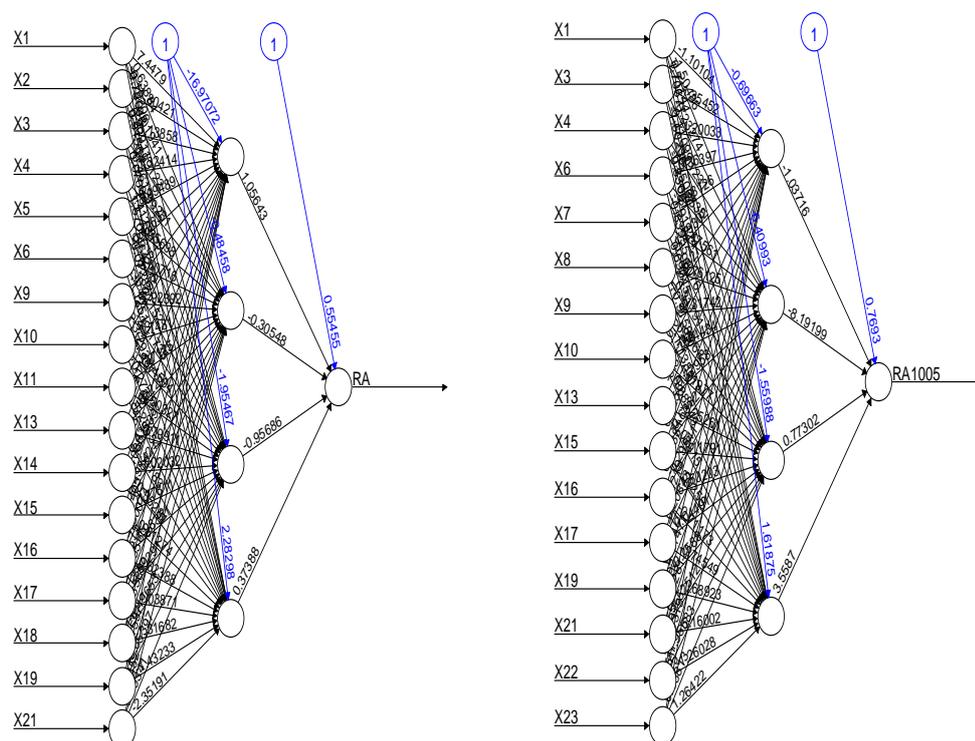
- El número de neuronas en la capa de entrada: son todas las variables independientes que se describe en la Tabla N° 13 en la sección 4.1.1.
- El número de neuronas en la capa oculta: es importante para el eficiente aprendizaje y su generalización. un número pequeño de neuronas en la

capa oculta hace que la red no puede aprender adecuadamente las relaciones existentes en los datos, mientras que un gran número hace que la red memorice los datos con una pobre generalización y una poca utilidad para la predicción.

Se consideró 4 neuronas en la capa oculta.

- El número de neuronas en la capa oculta: 1 neurona de salida.
- Funciones de transferencia (activación) se consideró la función de activación sigmoidea.

Gráfico N° 25: Arquitectura para las asinaturas 009-05 y 010-05



4.3.6 Criterio de evaluación

El criterio de evaluación se basa en la habilidad de aprendizaje de las arquitecturas específicas de un dominio con la complejidad de la topología generada. Se utilizó las funciones de iteración simple, radial e iteraciones complicadas.

4.3.7 Entrenamiento de la red neuronal

El entrenamiento de una red neuronal es un problema de optimización no lineal sin restricciones en el cual los pesos de la red son iterativamente modificados con el fin de minimizar el error entre la salida deseada y la obtenida, en la búsqueda de un mínimo global. Las técnicas clásicas de gradiente descendiente también llamado Backpropagation o la Regla Delta Generalizada, el algoritmo más comúnmente usado. (Hagan, 1996 citado por Sanchez, 2010).

Para el entrenamiento se utilizó lenguaje de programación R con el procedimiento de algoritmo backpropagation, con el paquete neuralnet, función de activación sigmoide.

El entrenamiento consiste en la presentación repetida de un conjunto datos de entrenamiento formado por las entradas (variables independientes) y los valores correspondientes de las variables a predecir(variables dependiente), hasta conseguir que los pesos internos (interacciones entre nodos) conduzcan a resultados óptimos en la capa de salida, acercándose lo más posible a los resultados esperados.

En un primer momento se entrenó para la asignatura con código 010-05 el mejor resultado obtenido ejecutados con el paquete neuralnet de R studio son los son los siguientes:

Tabla N° 20. Resultado del modelo de la asignatura de 010-05

Hidden:4	Thresh: 0.01	rep:1 / 1	steps:36104
Error: 0.0538		Time:59.12secs	

INTERPRETACIÓN: Los resultados del Tabla N° 20, nos permite un error de 0.054 para el modelo con 4 neuronas en la capa oculta, el umbral de activación de la neurona s es de 0.01 en un tiempo de 59.12 segundos en 36104 pasos.

También se entrenó para la asignatura con código 009-05 el mejor resultado obtenido en proceso de entrenamiento y validación de modelos de redes neuronales aplicados con el paquete neuralnet de R studio son los siguientes:

Tabla N° 21. Resultado del modelo de la asignatura de 009-05

Hidden:4	Thresh: 0.01	rep:1 / 1	steps: 7284
Error: 0.02947		15.75 secs	

INTERPRETACIÓN: Los resultados del Tabla N° 21, nos permite un error de 0.029 para el modelo, con 4 neuronas en la capa oculta, el umbral de activación de la neurona s de 0.01 en un tiempo de 15.75 segundos, 7284 pasos.

4.3.8 Uso y análisis de redes predicción de rendimiento académico

Después de entrenar las redes neuronales y validar los modelos que ya generalizan seguidamente en la tabla Tabla N° 22 se muestra la predicción de los promedios finales que se obtuvo de los 20 alumnos la asignatura 010-05

y 21 alumnos en 009-05, también se muestra la Tabla N° 23 con el error media cuadrática de las asignaturas.

Tabla N° 22. Resultado de la predicción de Redes neuronales

010-05			009-05		
Real	Predicho	Residuo	Real	Predicho	Residuo
0.5789	0.582	0.0031	0.625	0.64	-0.015
0.5263	0.4893	-0.037	0.625	0.6211	0.0039
0.5263	0.4893	-0.037	0.625	0.5983	0.0267
0.5263	0.4879	-0.038	0.625	0.6199	0.0051
0.5263	0.4888	-0.038	0.5625	0.5269	0.0356
0.7368	0.7243	-0.013	0.5	0.5616	-0.062
0.6316	0.6583	0.0267	0.5	0.4572	0.0428
0.5789	0.5897	0.0107	0.5	0.4903	0.0097
0.7368	0.7276	-0.009	0.4375	0.4728	-0.035
0.6842	0.6956	0.0114	0.4375	0.5227	-0.085
0.6316	0.6455	0.0139	0.4375	0.4817	-0.044
0.6316	0.6464	0.0148	0.4375	0.548	-0.11
0.6316	0.6457	0.0142	0.4375	0.4784	-0.041
0.6316	0.6466	0.0151	0.4375	0.4653	-0.028
0.5789	0.5754	-0.004	0.4375	0.4984	-0.061
0.5263	0.4794	-0.047	0.375	0.4399	-0.065
0.5263	0.4841	-0.042	0.3125	0.3849	-0.072
0.5263	0.4872	-0.039	0.3125	0.4086	-0.096
0.5263	0.4847	-0.042	0.1875	0.1979	-0.01
0.5263	0.4866	-0.04	0.125	0.2179	-0.093
			0.125	0.1828	-0.058

Tabla N° 23. MSE de las asignaturas 010-05 y 009-05

010-05	009-05
MSE = 0.00079890	MSE = 0.00082519176

INTERPRETACIÓN: Error Cuadrático Medio (MSE) para 010-05 es 0.00079 y 0.00083 para 009-05 se obtuvo valores aceptables más bajos para el error de predicción.

4.4 ANÁLISIS DE LOS RESULTADOS DE LAS TÉCNICAS DE PREDICCIÓN

La finalidad era saber cuál de las técnicas obtendría el menor error cuadrático medio y de esta manera probar la hipótesis planteada, a partir de los resultados anteriormente realizados en este capítulo a continuación se presentan los resultados obtenidos luego de realizar predicciones de cada técnica:

Tabla N° 24. Error del modelo y de la predicción de dos asignaturas.

Error del Modelo y Error de Predicción				
Técnicas de predicción	010-05		009-05	
	Error del modelo	MSE(error de predicción)	Error del modelo	MSE(error de predicción)
Redes neuronales	0.0538	0.00079890	0.02947	0.000825192
Regresión múltiple	0.9612	0.00321637	0,109236	0.3729119

INTERPRETACIÓN: La RNA's tiene un mejor rendimiento una diferencia de 0.9 de error del modelo en la asignatura 010-05 y 0.8 de error de modelo en la asignatura 009-05. La RNA's tiene un mejor rendimiento a 0.0024 menor en error de predicción en la asignatura 01005 y 0.3721 menor en error de predicción en la asignatura 00905.

Tabla N° 25. Promedios de 2 cursos.

Promedios		
Técnicas de Predicción	Error del Modelo	MSE(error de predicción)
Redes Neuronales	0.041635	0.0008120
Regresión múltiple	0.535218	0.1880641
Diferencia	0.493583	0.1872520

INTERPRETACIÓN: Los resultados del en la tabla 25, nos permitió diferenciar los promedios de regresión con las predicciones de redes neuronales a 0.49

en el error del modelo y 0.18 de error en predicción. De esta manera se concluye que la técnica de las redes neuronales artificiales alcanzó el menor error respecto a la técnica de regresión múltiple.

4.5 DISCUSIÓN DE LOS RESULTADOS

En primer lugar analizamos los resultados de las técnicas de predicción que obtuvieron Acosta y Pizarro (2010), aplicaron backpropagacion y regresión múltiple para predecir el rendimiento académico, obtuvieron como resultados de 7 cursos promedios de raíz de errores medios cuadráticos similares de 0,1495 y 0,1430 para los modelos, y de 0,1397 y 0,1380 para los pronósticos respectivamente, a diferencia frente a los resultado que se obtuvo en esta investigación de 2 asignaturas con promedios de MSE similares a 0.0416 y 0.5352 para los modelos, y de 0.0002 y 0.1880 para las predicciones.

Segundo en lo que respecta el efecto de las variables predictoras del historial de los promedios finales de los estudiantes de la FINESI tuvieron un alto grado de influencia sobre los modelos que fueron capaz de explicar superior a 92% de la variabilidad sobre los promedios finales, se reafirma respecto a la afirmación de Rodríguez y Coello (2008), Tejedor y otros (1998) que el mejor predictor del rendimiento académico universitario futuro es el rendimiento académico previo (Variables académicas), también Randall y Bulent (1997) afirmaron que el promedio ponderado es un buen predictor, esta investigación coincidió con lo afirmado.

En la presente investigación se obtuvo coeficientes de correlación con un buen nivel de asociación mayor a 0.70 que incide considerablemente en la

variable dependiente las cuales son; X1, X3, X4, X6, X20, X23, estas variables predictoras coincidieron con los propuestos por Acosta y Pizarro (2010),

De igual modo se reafirma las conclusiones de Arsad (2012) sobre la existencia de correlación directa entre el rendimiento académico final general y los resultados obtenidos en las materias básicas del primer nivel ya las variables predictoras de esta investigación fueron generados a partir de las asignaturas previas para predecir el rendimiento académico de las asignaturas 00905, 01005.

Se reafirma lo mencionado por Tejedor (2003) que se predice mejor en base al historial académico reciente en tiempo, se hizo usó de los datos de las asignaturas previo de los estudiantes registrados en la base de datos de la universidad.

En esta investigación la predicción del rendimiento académico esta netamente en función del rendimiento previo, diferentes tasas e índices académicos de esta manera se coincidió con las afirmaciones de Rodríguez y Coello (2008), Valle (1998).

Se reafirma la conclusión de Esteba (2011), Acosta y Pizarro (2010), Arsad (2012) de que las RNA's son mejores técnicas de predicción en el análisis de datos.

CONCLUSIONES

- Los resultados de la técnica de redes neuronales tiene menor grado de error frente a la técnica de regresión, se obtuvo que los modelos de RNAs mostraron mejor desempeño con promedios de 0.041635 de error en el modelo y 0.0008120 error en predicción frente a los modelos de regresión con 0.535218 error de modelo y 0.1880641 de error para las predicciones, de acuerdo al objetivo general de este trabajo de investigación se afirmó las RNA's es la mejor técnica en predicción; puesto que tienen una diferencia de 0.534 error en modelo y 0.1307 error en predicción respecto a la regresión en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano - Puno 2015.
- Los resultados que se obtuvo con los modelos de regresión en las asignaturas: 009-05 con un comportamiento de $R^2= 0.72$, error de modelo 0,1092 de variabilidad, 0.3729119 de error para las predicciones y para la asignatura 010-05 con un comportamiento de $R^2= 0.92$, error de modelo 0.9612 de variabilidad, 0.00321637217 de error para las predicciones.
- Los resultados que se obtuvo con los modelos de las RNAs en las asignaturas: 009-05 con un error de modelo 0.02947 de variabilidad, 0.00082519 de error para las predicciones y para la asignatura 010-05 con error de modelo 0.0538 de variabilidad, 0.00079890 de error para las predicciones.

RECOMENDACIONES Y SUGERENCIAS

- Se recomienda tener en cuenta al momento identificar y seleccionar el grupo apropiado de variables, tener buena calidad en la recogida, procesamiento de datos, tener un tamaño de base de datos considerable y limpio.
- Se recomienda las futuras investigaciones a considerar otras variables como son factores socioeconómicos, demográficos, institucionales para la predicción del rendimiento académico, considerar en aplicar en otras áreas del análisis de datos.
- Se sugiere a la FINESI elaborar un plan estratégico para la toma de decisión en cuanto a la mejora continua y la calidad de la formación, haciendo uso de los modelos de RNAs e identificar a estudiantes con riesgo a bajo rendimiento en las asignaturas de los semestres posteriores.
- Se recomienda el uso de las redes neuronales como una gran alternativa para el análisis de datos y con el uso de software libre el caso de R studio que posee gran gama de librerías para todo tipo de análisis estadístico en un proyecto de investigación.
- Se afirma que las redes neuronales a diferencia de regresión no necesita análisis de correlación, multicolenidad de las variables, las RNA's generalizan a partir del entrenamiento. Para esta investigación se hizo uso del método stepwise para seleccionar variables para un óptimo resultado.

BIBLIOGRAFIA

- Acosta, R. y Pizarro, A. (2010). *Predicación del rendimiento académico en la educación superior usando minería de datos y su comparación con técnicas estadísticas*. Tesis de Maestría, Universidad Nacional de Ingeniería, Lima, Peru.
- Anderson, J (1995). *An Introduction to Neural Networks*. USA: MIT Press.
- Arsad, P., Buniyamin, N. y Manan, J. (2012). Neural network model to predict electrical students' academic performance. 2012 *4th International Congress on Engineering Educatio,2012*, pp. 1-5. doi:10.1109/ICEED.2012.6779270.
- Charytoniuk, W., Box,E., Lee, W., Chen, M., Kotas, P. y Van Olinda, P. (1999) Neural network based demand forecasting in a deregulated environment. *1999 IEEE Industrial and Commercial Power Systems Technical Conference,1999*, pp.7-. doi:10.1109/ICPS.1999.787232
- Coakley, J. R. y Brown, C. E. (2000): Artificial Neural Networks in Accounting and Finance: Modeling Issues. *International Journal of Intelligent Systems in Accounting Finance and Management*, 9(2), pp.119-144. doi:10.1002 / 1099-1174 (200006)
- Curram, P. y Mingers, J. (1994). Neural networks, decision tree induction and discriminant analysis: an empirical comparison. *Journal of the Operational Research Society,45(4),pp.440-450*.doi:10.1057/jor.1994.62
- Fuente, Santiago (2011). *Regresión Múltiple*. Facultad de Ciencias Económicas y Empresariales, Universidad Autónoma de Madrid, España.
- Flórez, L. R. Y Fernández, F., J.M. (2008). *Las Redes Neuronales Artificiales, Fundamentos teóricos y aplicaciones prácticas*. España: Netbiblo.
- Haykin, S. S. (1994). *Neural Networks: a Comprehensive Foundation*. New York. Macmillan.
- Hilera, J. y Martínez, V. (1995). *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones*. Madrid: RA-MA.
- Lahoz, B. (2010). *Bioinformática: Simulación, vida artificial e inteligencia artificial*. Madrid: Diaz de Santos.

- Lamas, H. (2015). *Sobre el rendimiento escolar Propósitos y Representaciones*.
Extraída el 20 Octubre 2016 desde.
<http://dx.doi.org/10.20511/pyr2015.v3n1.74>.
- Lehmann, E. y Casella G. (1998). *Theory of Point Estimation*. Nueva York: Springer.
- Levin, R. y Rubin, D. (1998). *Statistics for management*. New York: Prentice Hall.
- Luque, E. y Sequi, J. (2002). *Modelo Teórico para la Determinación del Rendimiento Académico General del Alumno, en la Enseñanza Superior*. Argentina.
Extraída el 16 Junio 2015 at:
<http://www.editorial.unca.edu.ar/Publicacione%20on%20line/CD%20INTE RACTIVOS/NOA2002/Modelo%20Rendimiento%20Academico.pdf>.
- Martín, B. B., y Sanz, M. A.(2001). *Redes neuronales y Sistemas difusos*. Madrid: RA-MA.
- Martín, B. B., y Sanz, M. A.(2007). *Redes neuronales y Sistemas difusos*. España: Alfaomega Edición.
- McCulloch, W.S. y Pitts, W. (1943) *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics <http://cns-classes.bu.edu/cn550/Readings/mcculloch-pitts-43.pdf>
- McCullagh, P. (1983). *Generalized Linear Models*, London, Chapman and Hall.
- Molera, L (2001). *Predicción del éxito en estudios universitarios mediante redes neuronales*. España:Universidad de Murcia.
- Müller, B., Reinhardt, J. (1990). *Neural Networks. An Introduction*. Springer-Verlag.
- Netter, J. & Wasserman, W.(1990). *Applied Linear Statistical Models*. (3ª ed.). Boston: Richard D. Irwin.
- Ocaña Fernández, Y. (2011). *VARIABLES académicas que influyen en el rendimiento académico de los estudiantes universitarios*. Extraída el 16 Junio 2015 at:
http://sisbib.unmsm.edu.pe/bibvirtual/publicaciones/inv_educativa/2011_n27/a11v15n27.pdf.
- Rabunal, J. y Dorrado, J. (2005). *Neural networks: algorithms, applications, and programming techniques*. Idea Group Reference.
- Real Academia Española. (2014). *Diccionario de la lengua española (23.ª ed.)*. Consultado en <http://www.rae.es/rae.html>
- Rodríguez, A, & Ruiz, P. (2010). *Indicadores de rendimiento de estudiantes universitarios: calificaciones versus créditos acumulados*. Revista de

- Educación, Extraída el 18 Junio 2016 desde http://www.revistaeducacion.educacion.es/re355/re355_20.pdf
- Sanchez, P. (2010). *Selección del método de pronóstico La selección de la técnica para la predicción, se define en base al análisis de los factores que intervienen en la selección del modelo, en esta investigación.* universidad nacional de colombia. Extraída el 16 Junio 2015 desde. <http://www.bdigital.unal.edu.co/28798/1/26654-93565-1-PB.pdf>
- Tejedor, F. y García, A. (2007). *Causas del bajo rendimiento del estudiante universitario (en opinión de los profesores y alumnos). Propuestas de mejora en el marco del EEES.* Extraída el 20 Junio 2015 desde. http://www.revistaeducacion.mec.es/re342/re342_21.pdf
- Tejedor, F. (2003). *Poder explicativo de algunos determinantes del rendimiento en los estudios universitarios. Revista Española de Pedagogía,* Extraída el 18 Julio 2015 desde. <http://reunir.unir.net/bitstream/handle/123456789/4164/PoderExplicativoDeAlgunosDeterminantes.pdf?sequence=1&isAllowed=y>
- Tourón, J. (1984). *Factores del rendimiento académico en la universidad.* España: Ediciones Universidad de Navarra, S.A.
- Tourón, J. (1985). *La predicción del rendimiento académico: Procedimientos, resultados e implicaciones.* Revista Española de Pedagogía, 169/170. Extraída el 18 Julio 2015 desde. <http://dadun.unav.edu/handle/10171/18774>
- Trujillano, J. (2004). *Aproximación metodológica al uso de Redes Neuronales Artificiales para la predicción de resultados en medicina.* Extraída el 20 Junio 2015 desde. <http://web.udl.es/Biomath/Group/Treballs/2004MedClin.pdf>
- Valle Arias, Antonio (1998). *Variables cognitivo-motivacionales, enfoques de aprendizaje y Rendimiento Académico.* Extraída el 25 Junio 2015 desde. <http://www.redalyc.org/html/727/72710213/>
- Universidad Nacional del Altiplano (2017). *Directiva académica 2017.* Extraída el 1 Junio 2017 desde. <http://www.unap.edu.pe/web/documentos/2017/directiva-academica-2017.pdf>

ANEXOS

ANEXO 1.- HERRAMIENTAS

VENTANA DE LIMPIEZA Y CONSOLIDACION DE DATOS

UserForm2

Consolido de base para limpiar datos

CODIGO CURSO

NUMERO DE MATRICULA

NOMBRE DEL CURSO

SEMESTRE

DOCENTE

PERIODO ACADEMICO

copiar

pegar

pegar Hojas

Siguiete

pegar

Buscar

Limpiar

VENTANA PARA GENERAR LAS VARIABLES PREDICTORAS

UserForm4

CONSOLIDADO DE VARIABLES

PROMEDIO PONDERADO ACUM

NOTA PRE-REQUISITO

GRADO DE DIFICULTAD

EFECTIVIDAD DE APROBACION

CODIGO ALUMNO

CODIGO CURSO

CODIGO CURSO

NRO DE CREDITOS

Salir

Limpiar

SPGDC

NUMERO DE CCREDITOS

PRUEBA

**ANEXO 2: PLAN DE ESTUDIO 2008- 2015 Y BASE HISTORICAS DE
TODAS LAS VARIABLES**

PLAN DE ESTUDIOS FINESI 2008- 2015

ID	NOMBRE DE CURSOS	CODIGO CURSO	CRE DIT O	PLAN DE ESTUDIO	T	P	TH	SE ME STR E	REQUISITO	CO DIG O CU	CO DIG O CUR S	CO DIG O CUR	CO DIG O CUR SO
2	ORGANIZACIÓN Y GESTION EMP	066-04	3	FLEXIBLE 04	2	2	4	10	ELECTIVO	066	04	66	5
5	ESTADISTICA BASICA	001-05	5	FLEXIBLE 05	4	2	6	1	NINGUNO	001	05	1	5
8	METODOS DE PROGRAMACION	002-05	5	FLEXIBLE 05	4	2	6	1	NINGUNO	002	05	2	5
11	TEORIA DE LENGUAJES	003-05	5	FLEXIBLE 05	4	2	6	1	NINGUNO	003	05	3	5
14	MATEMATICA PARA INFORMAT	004-05	5	FLEXIBLE 05	4	2	6	1	NINGUNO	004	05	4	5
17	ESTRATEGIAS DE APRENDIZAJE	005-05	2	FLEXIBLE 05	4	2	6	1	NINGUNO	005	05	5	5
20	GESTION Y LIDERAZGO	006-05	2	FLEXIBLE 05	4	2	6	1	NINGUNO	006	05	6	5
23	ESTADISTICA MULTIVARIABLE	007-05	5	FLEXIBLE 05	4	2	6	2	001-05	007	05	7	5
25	DEMOGRAFIA	008-05	3	FLEXIBLE 05	2	2	4	2	NINGUNO	008	05	8	5
27	FUNDAMENTOS DE PROGRAMA	009-05	4	FLEXIBLE 05	3	2	5	2	002-05	009	05	9	5
29	ANALISIS DE SISTEMAS DE INFO	010-05	4	FLEXIBLE 05	3	2	5	2	NINGUNO	010	05	10	5
31	ARQUITECTURA DE COMPUTAD	011-05	4	FLEXIBLE 05	3	2	5	2	NINGUNO	011	05	11	5
33	CALCULO DIFERENCIAL	012-05	4	FLEXIBLE 05	3	2	5	2	004-05	012	05	12	5
35	CALCULO DE PROBABILIDADES	013-05	4	FLEXIBLE 05	3	2	5	3	007-05	013	05	13	5
37	DISEÑO DE SISTEMAS DE INFOR	014-05	4	FLEXIBLE 05	3	2	5	3	010-05	014	05	14	5
39	ESTRUCTURA DE DATOS	015-05	4	FLEXIBLE 05	3	2	5	3	003-05	015	05	15	5
41	PROGRAMACION AVANZADA	016-05	4	FLEXIBLE 05	3	2	5	3	009-05	016	05	16	5
43	ALGEBRA LINEAL	017-05	4	FLEXIBLE 05	3	2	5	3	NINGUNO	017	05	17	5
45	CALCULO INTEGRAL	018-05	4	FLEXIBLE 05	3	2	5	3	012-05	018	05	18	5
47	ESTADISTICA INFERENCIAL	019-05	5	FLEXIBLE 05	4	2	6	4	NINGUNO	019	05	19	5
49	ESTADISTICA NO PARAMETRICA	020-05	5	FLEXIBLE 05	4	2	6	4	NINGUNO	020	05	20	5
51	FUNDAMENTOS DE BASE DE DA	021-05	4	FLEXIBLE 05	3	2	5	4	016-05	021	05	21	5
53	MODELOS PROBABILISTICOS	022-05	3	FLEXIBLE 05	2	2	4	4	013-05	022	05	22	5
55	ESTRUCTURA DE DATOS AVANZ	023-05	4	FLEXIBLE 05	3	2	5	4	015-05	023	05	23	5
57	PROGRAMACION OPERATIVA	024-05	3	FLEXIBLE 05	2	2	4	4	017-05	024	05	24	5
60	SERIES DE TIEMPO	025-05	3	FLEXIBLE 05	2	2	4	5	022-05	025	05	25	5
62	MUESTREO	026-05	5	FLEXIBLE 05	4	2	6	5	019-05	026	05	26	5
64	MODELOS LINEALES	027-05	5	FLEXIBLE 05	4	2	6	5	024-05	027	05	27	5
66	BASE DE DATOS AVANZADAS	028-05	4	FLEXIBLE 05	3	2	5	5	021-05	028	05	28	5
68	SISTEMAS DIGITALES	029-05	4	FLEXIBLE 05	3	2	5	5	011-05	029	05	29	5
71	PROGRAMACION NUMERICA	030-05	3	FLEXIBLE 05	2	2	4	5	018-05	030	05	30	5
73	MUESTREO AVANZADO	031-05	5	FLEXIBLE 05	4	2	6	6	026-05	031	05	31	5
75	MODELOS LINEALES AVANZADO	032-05	5	FLEXIBLE 05	4	2	6	6	027-05	032	05	32	5
77	INGENIERIA DE SOFTWARE E IN	033-05	4	FLEXIBLE 05	3	2	5	6	028-05	033	05	33	5
79	SISTEMAS OPERATIVOS	034-05	4	FLEXIBLE 05	3	2	5	6	NINGUNO	034	05	34	5
81	MICROECONOMIA Y MACROECON	035-05	3	FLEXIBLE 05	2	2	4	6	NINGUNO	035	05	35	5
83	SISTEMAS DISTRIBUIDOS	036-05	3	FLEXIBLE 05	2	2	4	6	029-05	036	05	36	5
85	CONTROL ESTADISTICO DE LA C	037-05	5	FLEXIBLE 05	4	2	6	7	NINGUNO	037	05	37	5
87	DISEÑOS EXPERIMENTALES	038-05	5	FLEXIBLE 05	4	2	6	7	031-05	038	05	38	5
89	ARQUITECTURA DE REDES Y PRO	039-05	4	FLEXIBLE 05	3	2	5	7	036-05	039	05	39	5
91	LABORATORIO DE PROGRAMACI	040-05	3	FLEXIBLE 05	2	2	4	7	NINGUNO	040	05	40	5
93	INTELIGENCIA ARTIFICIAL	041-05	4	FLEXIBLE 05	3	2	5	7	033-05	041	05	41	5
95	COMPUTACION GRAFICA	042-05	3	FLEXIBLE 05	2	2	4	7	NINGUNO	042	05	42	5
97	REGRESION AVANZADA	043-05	3	FLEXIBLE 05	2	2	4	8	032-05	043	05	43	5
99	DISEÑOS EXPERIMENTALES AVA	044-05	5	FLEXIBLE 05	4	2	6	8	038-05	044	05	44	5
101	COMPUTACION PARALELA	045-05	3	FLEXIBLE 05	2	2	4	8	041-05	045	05	45	5
103	ADMINISTRACION DE REDES	046-05	3	FLEXIBLE 05	2	2	4	8	039-05	046	05	46	5
105	SIMULACION	047-05	3	FLEXIBLE 05	2	2	4	8	042-05	047	05	47	5
107	CONTABILIDAD GENERAL	048-05	3	FLEXIBLE 05	2	2	4	8	NINGUNO	048	05	48	5
109	METODOLOGIA DE LA INVESTIG	049-05	3	FLEXIBLE 05	2	2	4	8	NINGUNO	049	05	49	5
111	METODOS MULTIVARIANTES	050-05	4	FLEXIBLE 05	3	2	5	9	043-05	050	05	50	5
113	ESTADISTICA PARA LA INVESTIG	051-05	4	FLEXIBLE 05	3	2	5	9	044-05	051	05	51	5
115	PROCESOS ESTOCASTICOS	052-05	3	FLEXIBLE 05	2	2	4	9	025-05	052	05	52	5
117	PROYECTOS DE PROGRAMACION	053-05	3	FLEXIBLE 05	2	2	4	9	040-05	053	05	53	5
119	SEGURIDAD Y AUDITORIA INFO	054-05	3	FLEXIBLE 05	2	2	4	9	046-05	054	05	54	5
121	AMBIENTES VIRTUALES	055-05	3	FLEXIBLE 05	2	2	4	9	047-05	055	05	55	5
123	PROYECTOS DE INVERSION	056-05	3	FLEXIBLE 05	2	2	4	9	048-05	056	05	56	5
125	GERENCIA DE CENTROS DE COM	057-05	3	FLEXIBLE 05	2	4	6	10	053-05	057	05	57	5
127	SOFTWARE LIBRE Y APLICACION	058-05	4	FLEXIBLE 05	2	4	6	10	054-05	058	05	58	5
129	TALLER DE TESIS	059-05	2	FLEXIBLE 05	0	4	4	10	049-05	059	05	59	5
131	TALLER DE PRE-PRACTICAS PRO	060-05	3	FLEXIBLE 05	0	6	6	10	NINGUNO	060	05	60	5
133	ADMINISTRACION Y GERENCIA	065-05	3	FLEXIBLE 05	2	2	4	10	NINGUNO	065	05	65	5



MUESTRA DE DATOS DEL CURSO DE 010-05

Table with columns: nota01, X1, X2, X3, X4, X5, X6, X7, X8, X9, X10, X11, X12, X13, X14, X15, X16, X17, X18, X19, X20, X21, X22, X23. Contains numerical data for various students.

ANEXO 3: PROGRAMACIÓN EN VBA EXCEL.

CODIGO PARA GENERACIÓN VARIABLES INDEPENDIENTES

'PROMEDIO PONDERADO

```

Private Sub CommandButton10_Click()
Dim findit As Range
Dim ultimafila As Integer
Dim ColumnaTrabajo, crexnota, Buscacodig
Dim i, div, sum As Integer
  Workbooks("Maestro.xlsm").Sheets("1").Activate
  ColumnaTrabajo = 2
  'UltimaFila =Workbooks("Maestro.xlsm").Sheets("1") Range("D" & Rows.Count).End(xlUp).Row'numero
columnas con contenido
  ' UltimaFila = Workbooks("Maestro.xlsm").Sheets("1").Cells(Rows.Count, ColumnaTrabajo).End(xlUp).Row
'numero columnas con contenido
  'lastRow =Workbooks("Maestro.xlsm").Sheets("1"). Range("B" & Cells.Rows.Count).End(xlUp).Row 'numero
columnas con contenido
  lastrow = Workbooks("Maestro.xlsm").Sheets("1").Range("b:b").End(xlDown).Row 'numero columnas con
contenido
  TextBox2.Text = lastrow
  For i = 2 To lastrow
    With Workbooks("Maestro.xlsm").Sheets("1").Range("B2:B" & lastrow)
      'With Workbooks("Maestro.xlsm").Sheets("1").Range("B2:B" & ActiveSheet.UsedRange.Rows.Count)
      Buscacodig = Workbooks("Maestro.xlsm").Sheets("1").Cells(i, ColumnaTrabajo).Value
      'TextBox1.Text = lastrow 'ActiveCell.Offset(i, 0).Value
      Dim c As Range
      ' Set C = Cells.Find(What:=buscacodig, After:=.Cells(.Cells.Count), LookIn:=xlValues, LookAt:=xlPart,
MatchCase:=False)
      Set c = .Find(What:=Buscacodig)
    If Not c Is Nothing Then
      Dim inicio As String, Rslt As String
      ThisWorkbook.Sheets("PPonderado").Range("A2:h10000").ClearContents
      inicio = c.Address

      Do
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = c
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = c.Offset(0, 1).Value
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 3).End(xlUp).Offset(1, 0).Value = c.Offset(0, 3).Value
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 4).End(xlUp).Offset(1, 0).Value = c.Offset(0, 4).Value
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 5).End(xlUp).Offset(1, 0).Value = c.Offset(0, 5).Value
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 6).End(xlUp).Offset(1, 0).Value = c.Offset(0, 7).Value
      'semestre
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 7).End(xlUp).Offset(1, 0).Value = c.Offset(0, 12).Value
      'credito
      div = c.Offset(0, 3).Value 'ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 3).End(xlUp).Offset(0, 0).Value
      sum = c.Offset(0, 12).Value 'ThisWorkbook.Sheets("PPonderado").Cells(Rows.count,
7).End(xlUp).Offset(0, 0).Value
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 8).End(xlUp).Offset(1, 0).Value = div * sum
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 9).End(xlUp).Offset(1, 0).Value = c.Offset(0, 41).Value
      ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 11).End(xlUp).Offset(1, 0).Value =
c.Offset(0, 43).Value

      Set c = .FindNEXT(c)
      Loop While Not c Is Nothing And c.Address <> inicio
    End If
  End With
  'busqueda en promedios-----
  Workbooks("Maestro.xlsm").Sheets("promedios").Activate
  Dim buscacod As Range

  Set buscacod = Workbooks("Maestro.xlsm").Sheets("promedios").Range("A:A").Find(What:=Buscacodig)
  If buscacod Is Nothing Then
  Dim credito, PROMEDIO
    Set PROMEDIO = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("c2:c10000")
    Set credito = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("g2:g10000")
    Dim rangocriterio, rangosuma, rangocredito As Range
    Set rangocriterio = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("f2:f10000")
    Set rangosuma = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("h2:h10000")

```

```

Set rangocredito = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("g2:g10000")
Dim ultimafilavacio
  ultimafilavacio=
    ' Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("a2").Copy
Destination:=Workbooks("Maestro.xlsm").Sheets("promedios").Range("A 3")
'Workbooks("Maestro.xlsm").Sheets("promedios").Range("e" & Cells.Rows.Count).End(xlUp).Value =
Workbooks("Maestro.xlsm").Sheets("pponderado").Range("e2")

'Workbooks("Maestro.xlsm").Sheets("promedios").Activate
Dim uf
TextBox1.Text = uf
' uf = Workbooks("Maestro.xlsm").Sheets("promedios").Range("A" & Rows.Count).End(xlUp).Row
' uf = Workbooks("Maestro.xlsm").Worksheets("promedios").Cells(Rows.Count, "a").End(xlUp).Row
'Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("A2").Copy
Destination:=Workbooks("Maestro.xlsm").Sheets("promedios").Cells(1, "uf")
'Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("b2").Copy
Destination:=Workbooks("Maestro.xlsm").Sheets("promedios").Range(2, "uf")
'Workbooks("Maestro.xlsm").Sheets("pponderado").Cells(uf + 1, 2).Value =
Workbooks("Maestro.xlsm").Sheets("promedios").Range("a3").Value
'Workbooks("Maestro.xlsm").Sheets("pponderado").Cells(uf + 1, 4).Value =
Workbooks("Maestro.xlsm").Sheets("promedios").Range("a5").Value
'Workbooks("Maestro.xlsm").Sheets("promedios").Cells(Rows.Count, 1).End(xlUp).Offset(1, 0).Value = buscacodig
'Workbooks("Maestro.xlsm").Sheets("promedios").Cells(Rows.Count, 2).End(xlUp).Offset(1, 0).Value =
buscacodig.Offset(0, 1)

Dim j As Integer
ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = c
ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = c.Offset(0,
1).Value
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 9).End(xlUp).Offset(1, 0).Value =
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 3).End(xlUp).Offset(0, 0).Value *
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 7).End(xlUp).Offset(0, 0).Value
ThisWorkbook.Sheets("promedios").Cells(Rows.count, 14).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumProduct(PROMEDIO, credito) / Application.WorksheetFunction.sum(credito)

For j = 1 To lastrow
Select Case j
Case "10"
sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "10", rangocredito)
If sumcred <> 0 Then
' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "10", rangosuma) / sumcred
Else
ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
End If
Case "9"
sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "9", rangocredito)
If sumcred <> 0 Then
' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "9", rangosuma) / sumcred
Else
ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
End If
Case "8"
sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "8", rangocredito)
If sumcred <> 0 Then
' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "8", rangosuma) / sumcred
Else
ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
End If
Case "7"
sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "7", rangocredito)

```

```

If sumcred <> 0 Then
'ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
    ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "7", rangosuma) / sumcred

    Else
    ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
    End If
    Case "6"
        sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "6", rangocredito)
        If sumcred <> 0 Then
            ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
            ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
                ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "6", rangosuma) / sumcred
                Else
                ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
                End If
        Case "5"
            sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "5", rangocredito)
            If sumcred <> 0 Then
                ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
                ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
                    ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "5", rangosuma) / sumcred
                    Else
                    ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
                    End If
            Case "4"
                sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "4", rangocredito)
                If sumcred <> 0 Then
                    ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
                    ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
                        ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "4", rangosuma) / sumcred
                        Else
                        ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
                        End If
                Case "3"
                    sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "3", rangocredito)
                    If sumcred <> 0 Then
                        ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
                        ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
                            ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "3", rangosuma) / sumcred
                            Else
                            ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
                            End If
                    Case "2"
                        sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "2", rangocredito)
                        If sumcred <> 0 Then
                            ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
                            ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
                                ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "2", rangosuma) / sumcred
                                Else
                                ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
                                End If
                        Case "1"
                            sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "1", rangocredito)
                            If sumcred <> 0 Then
                                ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
                                ' ThisWorkbook.Sheets("promedios").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0,
1).Value
                                    ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "1", rangosuma) / sumcred
                                    Else
                                    ThisWorkbook.Sheets("promedios").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0

```

```

End If
End Select
Next j
'Workbooks("Maestro.xlsm").Sheets("promedios").Cells(Rows.Count, 1).End(xlUp).Offset(1, 0).Value =
Workbooks("Maestro.xlsm").Sheets("Ponderado").
'Dim rng As Range
'Set rng = Workbooks("Maestro.xlsm").Sheets("promedios").Cells(Rows.Count, 1).End(xlUp)
'Workbooks("Maestro.xlsm").Sheets("ponderado").Range("D3").Copy Destination:=rng
'Workbooks("Maestro.xlsm").Sheets("ponderado").Range("F3").Copy Destination:=rng.Offset(0, 1)
End If
'fin busqueda en promedios-----

'ThisWorkbook.Sheets("Ponderado").Range("A2:h10000").ClearContents
Next i
    With Application
        .ScreenUpdating = True
        .EnableEvents = True
    End With

    Workbooks("maestro.xlsm").Sheets("1").Select
    Range("B2").Select
End Sub
    
```

VARIABLE PREREQUISITO

```

'PREREQUISITOS
Private Sub CommandButton13_Click()
NOTA_PRE_REQUISITO
PROMPRE
End Sub

Sub PREREQUISITO()
Dim c As Range
Dim FirstAddress
Dim oWkSht As Worksheet
Dim VALOR, LUGAR
    ultimafila = Cells(Rows.count, 2).End(xlUp).Row '
        ThisWorkbook.Sheets("1").Range("aq2:aq" & ultimafila).ClearContents
For i = 2 To ultimafila

On Error Resume Next
    With Worksheets(1).Range("B1:B" & ultimafila)
        ' Set c = .Find(VALOR, LookIn:=xlValues, lookat:=xlWhole)
        nombre = Workbooks("Maestro.xlsm").Sheets("1").Cells(i, 42).Value
        VALOR = Workbooks("Maestro.xlsm").Sheets("1").Cells(i, 2).Value
        Set c = Workbooks("Maestro.xlsm").Sheets("1").Range("b2:b" & ultimafila).Find(VALOR,
LookIn:=xlValues, lookat:=xlWhole)
        If c.Offset(0, 4).Value = nombre Then
            ThisWorkbook.Sheets("1").Cells(i, 43).End(xlUp).Offset(1, 0).Value = c.Offset(0, 3).Value '
& ":" & i
                ' MsgBox "LISTO"
            End If
            If c Is Nothing Or nombre = "NINGUNO" Or nombre = "ELECTIVO" Or c = Empty Then
                ' MsgBox "ELSE"
                ThisWorkbook.Sheets("1").Cells(i, 43).End(xlUp).Offset(1, 0).Value = "NO EXISTE" & i
            Else
                'Muestra un cuadro de diálogo con el número de coincidencias
                FirstAddress = c.Address

                Do
                    nombre = Workbooks("Maestro.xlsm").Sheets("1").Cells(i, 42).Value
                    LUGAR = c.Offset(0, 4).Value
                    'MsgBox LUGAR & ":" & nombre & " ." & c.Address & ":" & c
                    If nombre = LUGAR Then
                        ThisWorkbook.Sheets("1").Cells(i, 43).End(xlUp).Offset(1, 0).Value = c.Offset(0, 3).Value '
& ":" & i
                    Exit Do
                    ' MsgBox "LISTO"
                End If
                Set c = Workbooks("Maestro.xlsm").Sheets("1").Range("b2:b" & ultimafila).FindNEXT(c)
            End If
        End With
    End Sub
    
```

```
' Set c = .FindNEXT(c)
Loop While Not c Is Nothing And c.Address <> FirstAddress
ThisWorkbook.Sheets("1").Cells(i, 43).End(xlUp).Offset(1, 0).Value = "NO HAY DATOS" & i & i

End If
End With
Next i
End Sub
```

PROMEDIOS DE ACUERO AL RENDIMIENTO ACADEMICO

```
Dim findit As Range
Dim ultimafila, lastrow As Integer
Dim ColumnaTrabajo, crexnota, Buscacodig
Dim i, div, sum, sumcred As Integer
Workbooks("Maestro.xlsm").Sheets("1").Activate
ColumnaTrabajo = 2
lastrow = Workbooks("Maestro.xlsm").Sheets("1").Range("b:b").End(xlDown).Row 'numero columnas con
contenido
For i = 2 To lastrow
With Workbooks("Maestro.xlsm").Sheets("1").Range("B2:B" & lastrow)
'With Workbooks("Maestro.xlsm").Sheets("1").Range("B2:B" & ActiveSheet.UsedRange.Rows.Count)
Buscacodig = Workbooks("Maestro.xlsm").Sheets("1").Cells(i, ColumnaTrabajo).Value
'TextBox1.Text = lastrow 'ActiveCell.Offset(i, 0).Value
Dim c As Range
Set c = .Find(What:=Buscacodig)

If Not c Is Nothing Then
Dim inicio As String, Rslt As String
ThisWorkbook.Sheets("PPonderado").Range("A2:h10000").ClearContents
inicio = c.Address
Do
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = c
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = c.Offset(0, 1).Value
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 3).End(xlUp).Offset(1, 0).Value = c.Offset(0, 3).Value
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 4).End(xlUp).Offset(1, 0).Value = c.Offset(0, 4).Value
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 5).End(xlUp).Offset(1, 0).Value = c.Offset(0, 5).Value
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 6).End(xlUp).Offset(1, 0).Value = c.Offset(0, 7).Value
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 7).End(xlUp).Offset(1, 0).Value = c.Offset(0, 12).Value
div = c.Offset(0, 3).Value 'ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 3).End(xlUp).Offset(0, 0).Value
sum = c.Offset(0, 12).Value 'ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 7).End(xlUp).Offset(0,
0).Value
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 8).End(xlUp).Offset(1, 0).Value = div * sum
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 9).End(xlUp).Offset(1, 0).Value = c.Offset(0, 41).Value
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 11).End(xlUp).Offset(1, 0).Value = c.Offset(0,
43).Value

Set c = .FindNEXT(c)
Loop While Not c Is Nothing And c.Address <> inicio
End If
End With
'busqueda en hoja1-----
Workbooks("Maestro.xlsm").Sheets("hoja1").Activate
Dim buscacod As Range

Set buscacod = Workbooks("Maestro.xlsm").Sheets("hoja1").Range("A:A").Find(What:=Buscacodig)
If buscacod Is Nothing Then
Dim credito, PROMEDIO
Set PROMEDIO = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("c2:c10000")
Set credito = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("g2:g10000")
Dim rangocriterio, rangosuma, rangocredito As Range
Set rangocriterio = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("f2:f10000")
Set rangosuma = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("h2:h10000")
Set rangocredito = Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("g2:g10000")
Dim ultimafilavacio=
'ultimafilavacio=
' Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("a2").Copy
Destination:=Workbooks("Maestro.xlsm").Sheets("hoja1").Range("A 3")
'Workbooks("Maestro.xlsm").Sheets("hoja1").Range("e" & Cells.Rows.Count).End(xlUp).Value =
Workbooks("Maestro.xlsm").Sheets("pponderado").Range("e2")

'Workbooks("Maestro.xlsm").Sheets("hoja1").Activate
```

```

Dim uff Destination:=Workbooks("Maestro.xlsm").Sheets("hoja1").Cells(1, "uf")
'Workbooks("Maestro.xlsm").Sheets("PPonderado").Range("b2").Copy
Destination:=Workbooks("Maestro.xlsm").Sheets("hoja1").Range(2, "uf")
'Workbooks("Maestro.xlsm").Sheets("pponderado").Cells(uf + 1, 2).Value =
Workbooks("Maestro.xlsm").Sheets("hoja1").Range("a3").Value
'Workbooks("Maestro.xlsm").Sheets("pponderado").Cells(uf + 1, 4).Value =
Workbooks("Maestro.xlsm").Sheets("hoja1").Range("a5").Value
'Workbooks("Maestro.xlsm").Sheets("hoja1").Cells(Rows.Count, 1).End(xlUp).Offset(1, 0).Value = buscacodig
'Workbooks("Maestro.xlsm").Sheets("hoja1").Cells(Rows.Count, 2).End(xlUp).Offset(1, 0).Value =
buscacodig.Offset(0, 1)

    Dim j As Integer
    ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = c
    ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = c.Offset(0, 1).Value
    ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 9).End(xlUp).Offset(1, 0).Value =
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 3).End(xlUp).Offset(0, 0).Value *
ThisWorkbook.Sheets("PPonderado").Cells(Rows.count, 7).End(xlUp).Offset(0, 0).Value
    ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 14).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumProduct(PROMEDIO, credito) / Application.WorksheetFunction.sum(credito)

    For j = 1 To lastrow
    Select Case j
    Case "2008-1"
        sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "2008-1", rangocredito)
        If sumcred <> 0 Then
            ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
            'ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 44).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "10", rangosuma) / sumcred
        Else
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 44).End(xlUp).Offset(1, 0).Value = 0
        End If
    Case "9"
        sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "9", rangocredito)
        If sumcred <> 0 Then
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "9", rangosuma) / sumcred
        Else
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
        End If
    Case "8"
        sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "8", rangocredito)
        If sumcred <> 0 Then
            ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
            'ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "8", rangosuma) / sumcred
        Else
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
        End If
    Case "7"
        sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "7", rangocredito)

        If sumcred <> 0 Then
            'ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
            ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "7", rangosuma) / sumcred
        Else
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
        End If

    Case "6"
        sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "6", rangocredito)
        If sumcred <> 0 Then
            ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
            'ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
Application.WorksheetFunction.SumIf(rangocriterio, "6", rangosuma) / sumcred
        Else
            ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
        End If
    End Select
    End For
    
```

```

End If

Case "5"
    sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "5", rangocredito)
    If sumcred <> 0 Then
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
        Application.WorksheetFunction.SumIf(rangocriterio, "5", rangosuma) / sumcred
    Else
        ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
    End If

Case "4"
    sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "4", rangocredito)
    If sumcred <> 0 Then
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
        Application.WorksheetFunction.SumIf(rangocriterio, "4", rangosuma) / sumcred
    Else
        ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
    End If

Case "3"
    sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "3", rangocredito)
    If sumcred <> 0 Then
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
        Application.WorksheetFunction.SumIf(rangocriterio, "3", rangosuma) / sumcred
    Else
        ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
    End If

Case "2"
    sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "2", rangocredito)
    If sumcred <> 0 Then
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
        Application.WorksheetFunction.SumIf(rangocriterio, "2", rangosuma) / sumcred
    Else
        ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
    End If

Case "1"
    sumcred = Application.WorksheetFunction.SumIf(rangocriterio, "1", rangocredito)
    If sumcred <> 0 Then
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 1).End(xlUp).Offset(1, 0).Value = C
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, 2).End(xlUp).Offset(1, 0).Value = C.Offset(0, 1).Value
        ' ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value =
        Application.WorksheetFunction.SumIf(rangocriterio, "1", rangosuma) / sumcred
    Else
        ThisWorkbook.Sheets("hoja1").Cells(Rows.count, j + 3).End(xlUp).Offset(1, 0).Value = 0
    End If

End Select
Next j

'Workbooks("Maestro.xlsm").Sheets("hoja1").Cells(Rows.Count, 1).End(xlUp).Offset(1, 0).Value =
Workbooks("Maestro.xlsm").Sheets("PPonderado").
'Dim rng As Range
'Set rng = Workbooks("Maestro.xlsm").Sheets("hoja1").Cells(Rows.Count, 1).End(xlUp)
'Workbooks("Maestro.xlsm").Sheets("pponderado").Range("D3").Copy Destination:=rng
'Workbooks("Maestro.xlsm").Sheets("pponderado").Range("F3").Copy Destination:=rng.Offset(0, 1)
End If
'fin busqueda en hoja1-----

'ThisWorkbook.Sheets("PPonderado").Range("A2:h10000").ClearContents
Next i
    With Application
        .ScreenUpdating = True
        .EnableEvents = True
    End With
    Workbooks("maestro.xlsm").Sheets("1").Select
    Range("B2").
End Sub
    
```

ANEXO 4: PROGRAMACIÓN EN R STUDIO.

CODIGO PREDICCIÓN DE REGRESIÓN

```

install.packages("fuzzySim", repos = "http://R-Forge.R-project.org")
install.packages("ppcor")
install.packages("pastecs")
install.packages("DAAG")
library(foreign)
library("psych")
library("ppcor")
library(DAAG)

#seleccionamos data
traindata1005<-read.table("C:/data1005.txt",header = TRUE, sep = "\t", dec = ".")
# modelo inicial para seleccionar variables predictoras
modelgeneral1005<-lm(nota01 ~ ., traindata1005)
pairs(modelgeneral1005)
cor(modelgeneral1005)
modelstepwise1005
anova(modelstepwise1005)
#seleccionando variables predictoras funcion step "paso a paso"
modelstepwise1005=MASS::stepAIC(object=modelgeneral1005,scope=list(upper=~.,lower=~1),direction="backward",trace=F)
modelstepwise1005<-bootStepAIC::boot.stepAIC(object=modelgeneral1005,data=traindata1005)
#Nuevo modelo de regresión con 17 variables seleccionado por método paso a paso
Modeloregresion1005<-
lm(RA1005~X1+X3+X4+X6+X7+X8+X9+X10+X13+X15+X16+X17+X19+X21+X22+X23
,data=traindata1005)
summary(Modeloregresion1005 )
summary(Modeloregresion1005) $coefficients
#analisis residuos
cor.test(traindata1005$X2, traindata1005$X3, traindata1005$X5, traindata1005$X6,
traindata1005$X7,traindata1005$X8,traindata1005$X16,traindata1005$X18,traindata1005$X22,train
data1005$X27,traindata1005$X28,traindata1005$X30,traindata1005$X41,traindata1005$X45,traind
ata1005$X46,traindata1005$X53,traindata1005$X56, method = "pearson")
#prueba de normalidad
residuos01005<-rstandard(Modeloregresion1005)
win.graph()
par(mfrow=c(1,3))
hist(residuos01005)
boxplot(residuos01005)
qqnorm(residuos01005)
qqline(residuos01005)
# Utilizamos el test de normalidad de Shapiro-Wilks:
shapiro.test(residuos01005)
# Y el test de Kolmogorov-Smirnov para normalidad:
ks.test(residuos01005)
ks.test(x =residuos01005,"pnorm", mean(residuos01005), sd(residuos01005))

```

```
# Incorrelación.Gráfico de las autocorrelaciones de los residuos:
plot(acf(residuos010055))
# Ttest de Durbin-Watson:
library(lmtest)
dwtest(Modeloregresion1005,alternative="two.sided")
# Ttest Vif:
vif(Modeloregresion1005)
t.test(prediction1005,preddata1005$pronostico, alternative="g")
wilcox.test(prediction0905,preddata1005$pronostico, alternative="g")
ks.test(prediction0905,preddata1005$pronostico, alternative="l")
```

CODIGO PREDICCIÓN DE REDES NEURONALES

```
install.packages("neuralnet")
install.packages("caret", contriburl = "file:///usr/repo_AO/CRAN/")
install.packages('caret', repos="http://cran.rstudio.com/")
install.packages("ggplot2", "stringr", "munsell", "BradleyTerry2", "minqa", "nloptr")
install.packages("caret")
install.packages("ggplot2")
library(neuralnet)
library(caret)
library(foreign)
library(Rcmdr)
library("psych")
library("ppcor")
library(DAAG)

traindata1005<-read.table("C:/data1005.txt",header = TRUE, sep = "\t", dec = ".")

sigmoid = function(x) {
  1 / (1 + exp(-x))
}

neunet100516var<-neuralnet(formula =nota01 ~
X1+X3+X4+X6+X7+X8+X9+X10+X13+X15+X16+X17+X19+X21+X22+X23,datamodelbootStepAIC1
005, hidden = 3,learningrate = 0.01, algorithm = "rprop+", err.fct = "sse", linear.output = FALSE,
lifesign = "minimal",learningrate.limit = NULL, act.fct = sigmoid,threshold = 0.01
summary(neunet100516var)
plot(neunet100516var)
valdaciondata1005<-read.table("C:/valdata1005.txt",header = TRUE, sep = "\t", dec = ".")
#prediccion de RN
predneunet100516var <- neuralnet::compute (neunet100516var, valdaciondata1005[, 2:20])
#residual
residualespredneunet100516var<-valdaciondata1005$nota01-c(predneunet100516var $ net.result
#mse
library(hydroGOF)
#19variables
obs19 <- prevalmodeldata1005$nota01
sim19 <- c(predneunet100516var$net.result)
```

```

mse(obs19,sim19)
gof(obs19,sim19)
#graficos
ggof(sim=sim19, obs=obs19, ftype="dm", FUN=mean)# grafica
mean(residualesprediction1005bootstepAIC)
MSEreglmulti1005119 = mean( (((residualesprediction1005bootstepAIC)^2)), na.rm = TRUE)
MSEreglmulti1005119
MSE.lm <- sum ((residualesprediction1005bootstepAIC) ^ 2) / nrow (prevalmodeldata1005)
rmse19var<- sqrt(MSEreglmulti1005119)

mseRN19var = mean( (residualespredneunet100516var)^2, na.rm = TRUE)
abline(0,1,lwd=1)
legend('bottomright',legend='RNA',pch=18,col='red', bty='n')

par(mfrow=c(1,1))#limpia pantalla
plot(valdaciondata1005$nota01,predneunet100516var, col='red',main='Real vs prediccion
RNA',pch=15,cex=0.7)
points(valdaciondata1005$nota01,prediction1005bootstepAIC,col='blue',pch=18,cex=0.7)
abline(0,1,lwd=2)
legend('bottomright',legend=c('NN','LM'),pch=18,col=c('red','blue'))
valoriginal19var <- max.col (valdaciondata1005 [,1 ])
valpredeci19var <- max.col (predneunet100516var $ net.result)
print(paste("Model Accuracy: ", round(mean(valpredeci19var==valoriginal19var)*100, 2), "%.", sep =
""))
plot(test$medv,pr.nn_,col='red',main='Real vs predicted NN',pch=18,cex=0.7)
points(test$medv,pr.lm,col='blue',pch=18,cex=0.7)
abline(0,1,lwd=2)
legend('bottomright',legend=c('NN','LM'),pch=18,col=c('red','blue'))

```