

CAPÍTULO 5

Resultados



Esta obra está bajo una licencia
internacional Creative Commons
Atribución 4.0.



CAPÍTULO 5

Resultados

Results

DOI: <https://doi.org/10.71112/23nxem35>

Resumen

Este capítulo presenta los resultados y análisis de la investigación sobre la relación entre la productividad educativa y los algoritmos de aprendizaje automático. El análisis descriptivo detalla las percepciones de los 90 estudiantes encuestados sobre dimensiones como aptitud, instrucción, medio ambiente y aprendizaje. El análisis inferencial, mediante la prueba Rho de Spearman, revela una correlación positiva muy alta (0.940) entre ambas variables, confirmando todas las hipótesis específicas. Se concluye que los algoritmos (Decision Trees, Random Forest, Naive Bayes) son predictores efectivos de la productividad educativa, validando estudios previos.

Palabras clave: Resultados, Correlación, Rho de Spearman, Análisis Inferencial, Productividad Educativa, Aprendizaje Automático.

Abstract

This chapter presents the results and analysis of the research on the relationship between educational productivity and machine learning algorithms. The descriptive analysis details the perceptions of the 90 surveyed students regarding dimensions such as aptitude, instruction, environment, and learning. The inferential analysis, using Spearman's Rho test, reveals a very high positive correlation (0.940) between both variables, confirming all specific hypotheses. It is concluded that the algorithms (Decision Trees, Random Forest, Naive Bayes) are effective predictors of educational productivity, validating previous studies.

Keywords: Results, Correlation, Spearman's Rho, Inferential Analysis, Educational Productivity, Machine Learning.

Análisis descriptivo

Luego de la aplicación de la herramienta de recolección de datos, se realizó el procesamiento necesario para analizar los datos. En este punto, se analizaron internamente todos los indicadores suministrados por la EPISI de la (UNAM).

Descripción de encuestados

Tabla 2

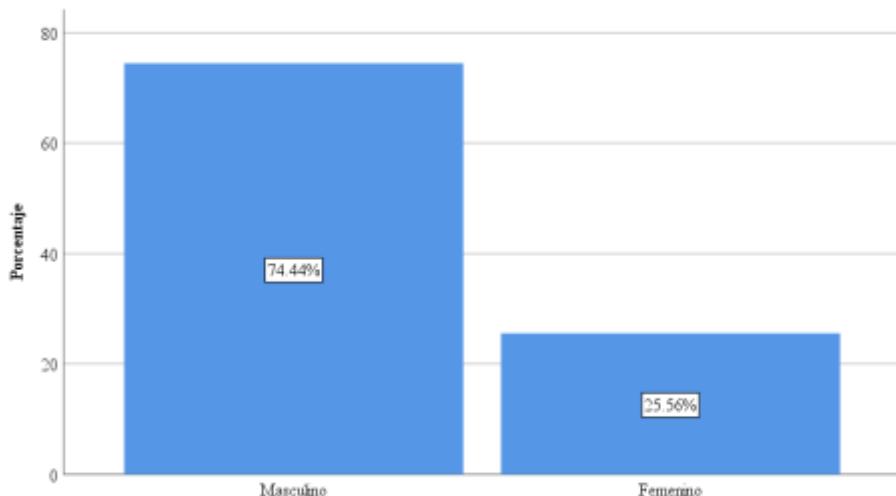
Totalidad de encuestados por genero

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Masculino	67	74.4	74.4	74.4
	Femenino	23	25.6	25.6	100.0
	Total	90	100.0	100.0	

Nota: En la tabla podemos observar la distribución de encuestados por frecuencia de género, de ellos 67 son Masculinos y 23 Femeninos que representan el 74.4% y 23% respectivamente en la presente investigación.

Figura 6

Encuestados según genero



Nota: La figura describe porcentualmente la muestra de representativa de los alumnos de la EPISI de la UNAM según genero considerado en la presente investigación.

Variable 1: productividad educativa

Tabla 3

Pregunta 1. Utilizo los recursos académicos disponibles para mis conocimientos

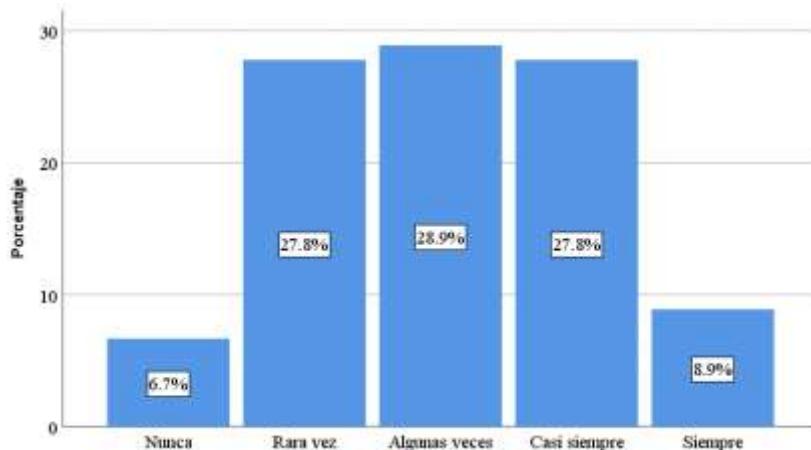
	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Nunca	6	6,7	6,7	6,7

Válido	Rara Vez	25	27,8	27,8	34,4
	Algunas Veces	26	28,9	28,9	63,3
	Casi Siempre	25	27,8	27,8	91,1
	Siempre	8	8,9	8,9	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 7

Pregunta 1. Utilizo los recursos académicos disponibles para mis conocimientos



Nota: Distribución porcentual de la pregunta 1.

Interpretación:

De acuerdo a la pregunta 1, acerca del uso de los recursos académicos disponibles para sus conocimientos podemos mencionar que 28.9% (26 encuestados) mencionan algunas veces, 27.8% (25 encuestados) mencionan casi siempre y rara vez, 8.9% (8 encuestado) mencionan siempre y 6.7% (6 encuestados) mencionan no utilizan.

Tabla 4

Pregunta 2. Planifico mis estudios académicos en la universidad

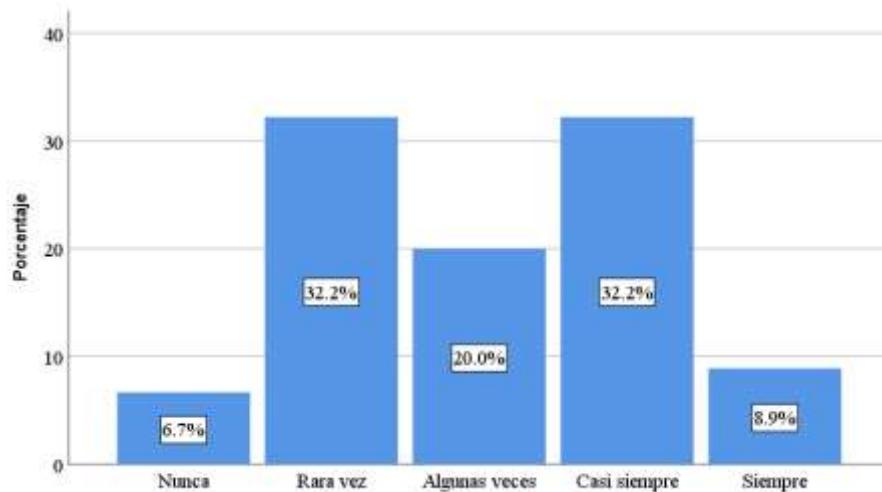
		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Nunca	6	6,7	6,7	6,7
	Rara Vez	29	32,2	32,2	38,9
	Algunas Veces	18	20,0	20,0	58,9

Casi Siempre	29	32,2	32,2	91,1
Siempre	8	8,9	8,9	100,0
Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 8

Pregunta 2. Planifico mis estudios académicos en la universidad



Nota: Distribución porcentual de la pregunta 2.

Interpretación:

De acuerdo a la pregunta 2, acerca de la planificación de estudios en la universidad podemos mencionar que 32.2% (29 encuestados) mencionan rara vez y casi siempre, el 20% (18 encuestados) mencionan algunas veces, el 8.9% (8 encuestados) mencionan siempre y 6.7% (6 encuestados) mencionan nunca.

Tabla 5

Pregunta 3: Los docentes felicitan mis esfuerzos académicos

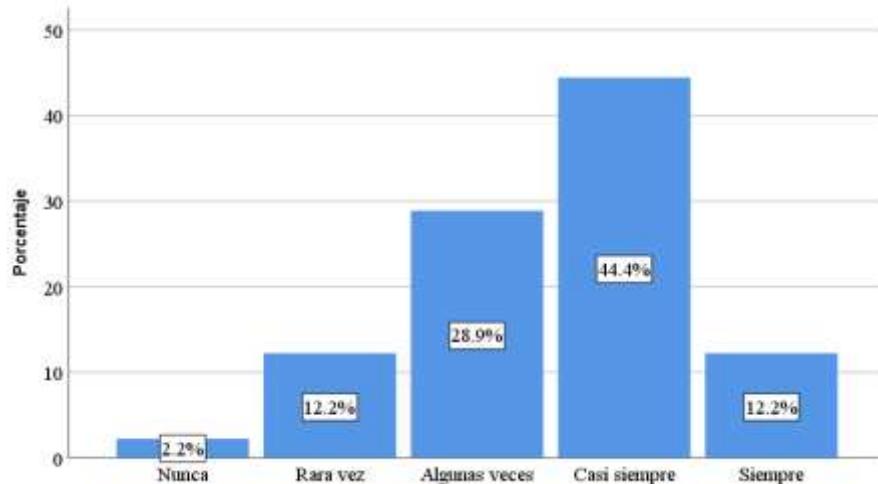
Válido		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
		2	2,2	2,2	2,2
	Rara Vez	11	12,2	12,2	14,4
	Algunas Veces	26	28,9	28,9	43,3
	Casi Siempre	40	44,4	44,4	87,8

Siempre	11	12,2	12,2	100,0
Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 9

Pregunta 3: Los docentes felicitan mis esfuerzos académicos



Nota: Distribución porcentual de la pregunta 3.

Interpretación:

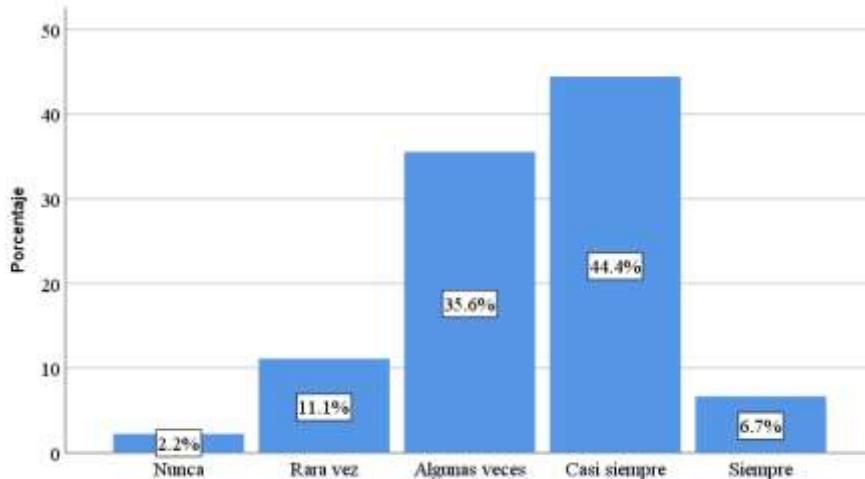
De acuerdo a la pregunta 3, referente al elogio establecido por los docentes al esfuerzo académico podemos mencionar que 44.4% (40 encuestados) mencionan casi siempre, el 28.9% (26 encuestados) mencionan algunas veces, mientras que el 12.2% (11 encuestados) mencionan rara vez y siempre y 2.2% (2 encuestados) mencionan nunca.

Tabla 6

Pregunta 4: Comprendo las sesiones de aprendizaje

Válido		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Nunca		2	2,2	2,2	2,2
Rara Vez		10	11,1	11,1	13,3
Algunas Veces		32	35,6	35,6	48,9
Casi Siempre		40	44,4	44,4	93,3
Siempre		6	6,7	6,7	100,0
Total		90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 10*Pregunta 4: Comprendo las sesiones de aprendizaje**Nota:* Distribución porcentual de la pregunta 4.**Interpretación:**

De acuerdo a la pregunta 4, acerca de la comprensión de las sesiones de aprendizaje mencionan que el 44.4% (40 encuestados) mencionan casi siempre, 35.6% (32 encuestados) mencionan algunas veces, 11.1% (10 encuestado) mencionan rara vez, 6.7% (6 encuestado) siempre y 2.2% (2 encuestados) mencionan nunca.

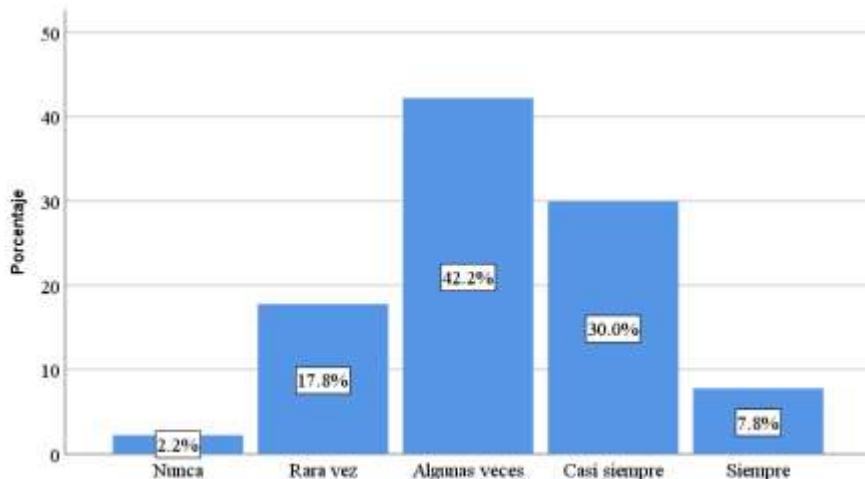
Tabla 7*Pregunta 5: Planifico mis tareas académicas*

Válido		Frecuencia	Porcentaje	Porcentaje	Porcentaje
				válido	acumulado
	Nunca	2	2,2	2,2	2,2
	Rara Vez	16	17,8	17,8	20,0
	Algunas Veces	38	42,2	42,2	62,2
	Casi Siempre	27	30,0	30,0	92,2
	Siempre	7	7,8	7,8	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 11

Pregunta 5: Planifico mis trabajos académicos



Nota: Distribución porcentual de la pregunta 5.

Interpretación:

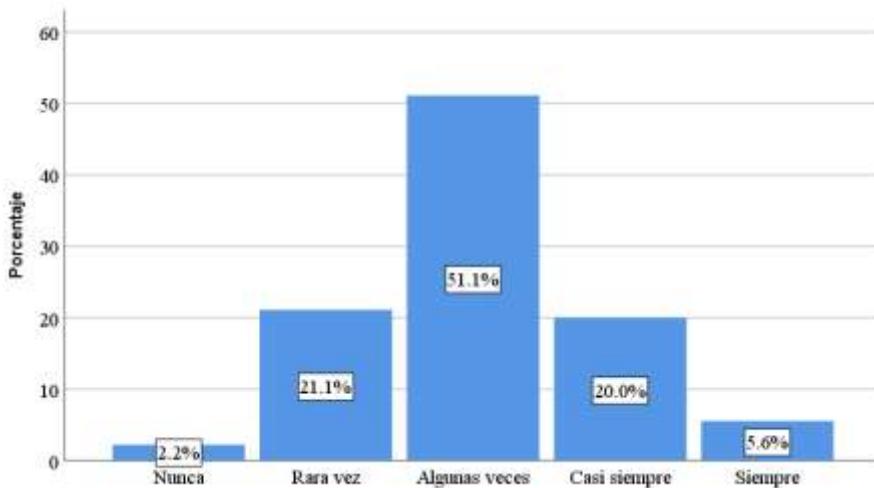
De acuerdo a la pregunta 5, acerca de la planificación de las tareas académicas mencionan que el 42.2% (38 encuestados) mencionan algunas veces, el 30.0% (27 encuestados) mencionan casi siempre, 17.8% (16 encuestado) mencionan rara vez, 7.8% (7 encuestado) siempre y 2.2% (2 encuestados) mencionan nunca.

Tabla 8

Pregunta 6: Utilizo la biblioteca para ampliar mis conocimientos

Válido		Frecuencia	Porcentaje		Porcentaje acumulado
			Porcentaje válido	acumulado	
0	Nunca	2	2,2	2,2	2,2
	Rara Vez	19	21,1	21,1	23,3
	Algunas Veces	46	51,1	51,1	74,4
	Casi Siempre	18	20,0	20,0	94,4
	Siempre	5	5,6	5,6	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 12*Pregunta 6: Utilizo la biblioteca para ampliar mis conocimientos**Nota:* Distribución porcentual de la pregunta 6.

Interpretación:

De acuerdo a la pregunta 6, acerca del uso de la biblioteca para ampliar los conocimientos mencionan que el 51.1% (46 encuestados) mencionan algunas veces, el 21.1% (19 encuestados) mencionan rara vez, el 20% (18 encuestados) mencionan casi siempre, el 5.6% (5 encuestados) siempre y el 2.2% (2 encuestados) mencionan nunca.

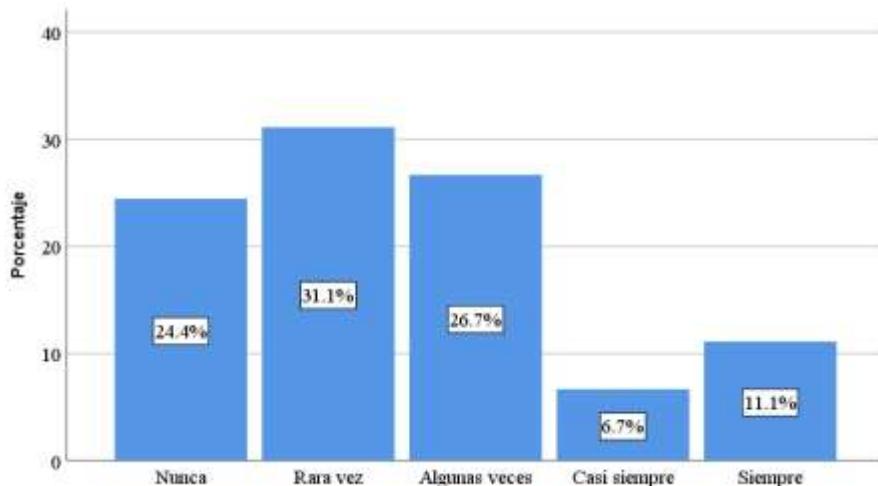
Tabla 9*Pregunta 7: Mis padres apoyan en mis conocimientos académicos*

		Frecuencia	Porcentaje		Porcentaje acumulado
			válido	acumulado	
Válido	Nunca	22	24,4	24,4	24,4
	Rara Vez	28	31,1	31,1	55,6
	Algunas Veces	24	26,7	26,7	82,2
	Casi Siempre	6	6,7	6,7	88,9
	Siempre	10	11,1	11,1	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 13

Pregunta 7: Mis padres apoyan en mis conocimientos académicos



Nota: Distribución porcentual de la pregunta 7.

Interpretación:

De acuerdo a la pregunta 7, acerca del apoyo de los padres en el conocimiento académico mencionan que el 31.1% (28 encuestados) mencionan rara vez, luego el 26.7% (24 encuestados) mencionan algunas veces, el 24.4% (22 encuestados) mencionan nunca, el 11.1% (10 encuestado) siempre y el 6.7% (6 encuestados) mencionan casi siempre.

Tabla 10

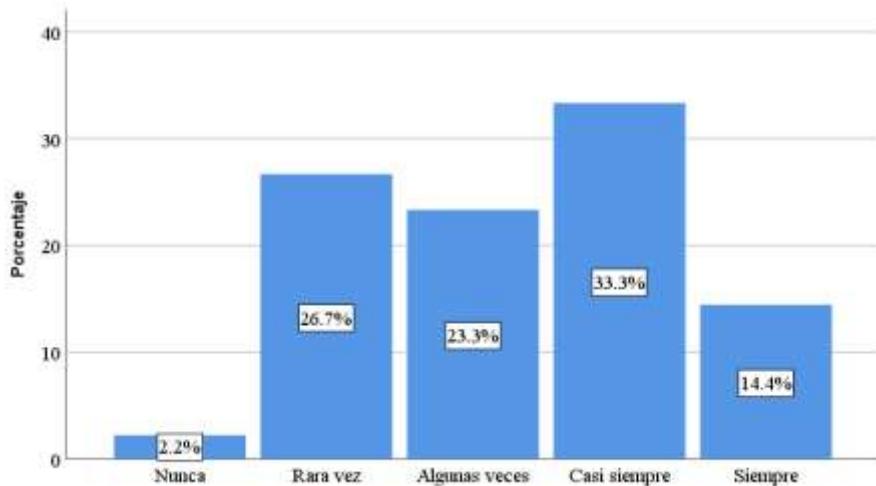
Pregunta 8: Utilizo equipos y herramientas académicas de casa para estudiar

Válido		Frecuencia	Porcentaje		Porcentaje acumulado
			Porcentaje	válido	
	Nunca	2	2,2	2,2	2,2
	Rara Vez	24	26,7	26,7	28,9
	Algunas Veces	21	23,3	23,3	52,2
	Casi Siempre	30	33,3	33,3	85,6
	Siempre	13	14,4	14,4	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 14

Pregunta 8: Utilizo equipos y herramientas académicas de casa para estudiar



Nota: Distribución porcentual de la pregunta 8.

Interpretación:

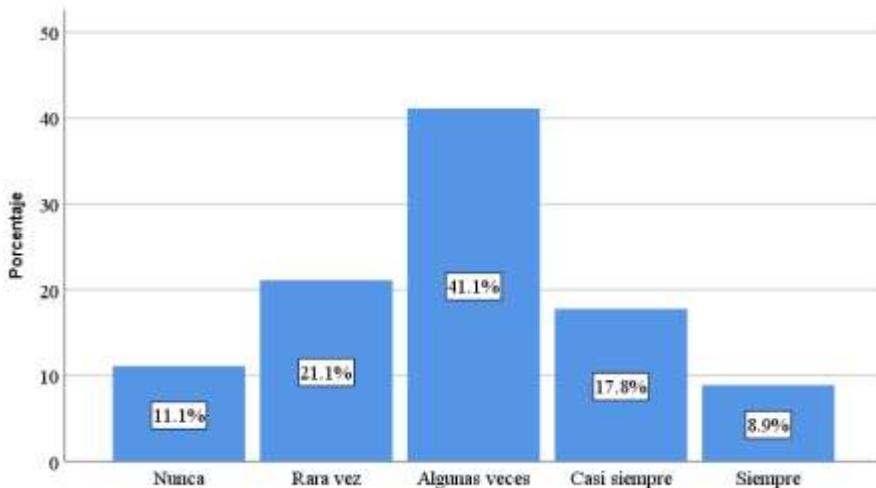
De acuerdo a la pregunta 8, acerca del uso de equipos y herramientas académicas para estudiar mencionan que el 33.3% (30 encuestados) mencionan casi siempre, mientras que el 26.7% (24 encuestados) mencionan rara vez, el 23.3% (21 encuestados) mencionan algunas veces, el 14.4% (13 encuestados) mencionan siempre y el 2.2% (2 encuestados) mencionan nunca.

Tabla 11

Pregunta 9: Recibo apoyo financiero familiar para mis estudios

Válido		Frecuencia	Porcentaje		Porcentaje acumulado
			Porcentaje válido	acumulado	
	Nunca	10	11,1	11,1	11,1
	Rara Vez	19	21,1	21,1	32,2
	Algunas Veces	37	41,1	41,1	73,3
	Casi Siempre	16	17,8	17,8	91,1
	Siempre	8	8,9	8,9	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 15*Pregunta 9: Recibo apoyo financiero familiar para mis estudios**Nota:* Distribución porcentual de la pregunta 9.

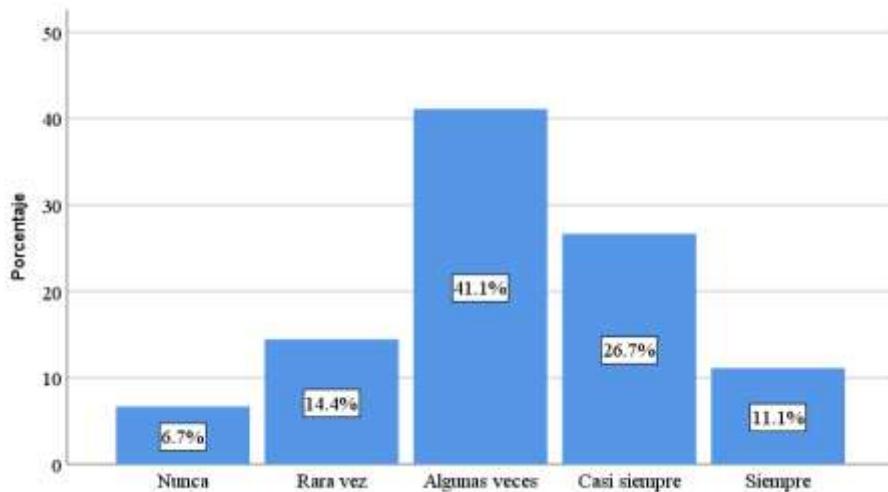
Interpretación:

De acuerdo a la pregunta 9, acerca del apoyo financiero para sus estudios mencionan que el 41.1% (37 encuestados) mencionan algunas veces, mientras que el 21.1% (19 encuestados) mencionan rara vez, el 17.8% (16 encuestados) mencionan casi siempre, el 11.1% (10 encuestados) mencionan nunca y el 8.9% (8 encuestados) mencionan siempre.

Tabla 12*Pregunta 10: Realizo desenvolvimiento social con mis vecinos*

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Nunca	6	6,7	6,7	6,7
	Rara Vez	13	14,4	14,4	21,1
	Algunas Veces	37	41,1	41,1	62,2
	Casi Siempre	24	26,7	26,7	88,9
	Siempre	10	11,1	11,1	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 16*Pregunta 10: Realizo desenvolvimiento social con mis vecinos**Nota:* Distribución porcentual de la pregunta 10.

Interpretación:

De acuerdo a la pregunta 10, acerca del desenvolvimiento social con los vecinos del encuestado manifiestan que el 41.1% (37 encuestados) mencionan algunas veces, mientras que el 26.7% (24 encuestados) mencionan casi siempre, el 14.4% (13 encuestados) mencionan rara vez, el 11.1% (10 encuestados) mencionan siempre y el 6.7% (6 encuestados) mencionan nunca.

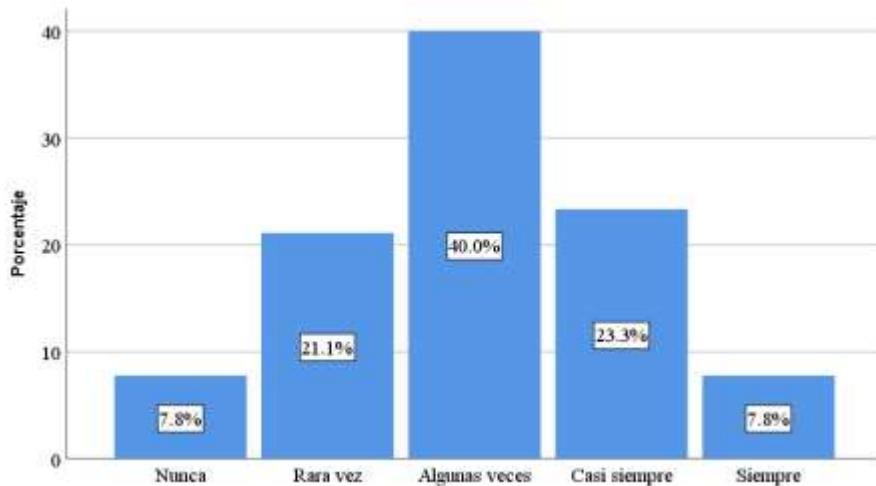
Tabla 13*Pregunta 11: Participo en actividades deportivas en mi barrio*

	Frecuencia	Porcentaje	Porcentaje	Porcentaje
			válido	acumulado
Válido	Nunca	7	7,8	7,8
	Rara Vez	19	21,1	21,1
	Algunas Veces	36	40,0	40,0
	Casi Siempre	21	23,3	23,3
	Siempre	7	7,8	100,0
	Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 17

Pregunta 11: Participo en actividades deportivas en mi barrio



Nota: Distribución porcentual de la pregunta 11.

Interpretación:

De acuerdo a la pregunta 11, acerca de la participación en actividades deportivas en sus barrios manifiestan que el 40% (36 encuestados) mencionan algunas veces, mientras que el 23.3% (21 encuestados) mencionan casi siempre, el 19% (19 encuestados) mencionan rara vez, el 7.8% (7 encuestados) mencionan siempre y nunca.

Tabla 14

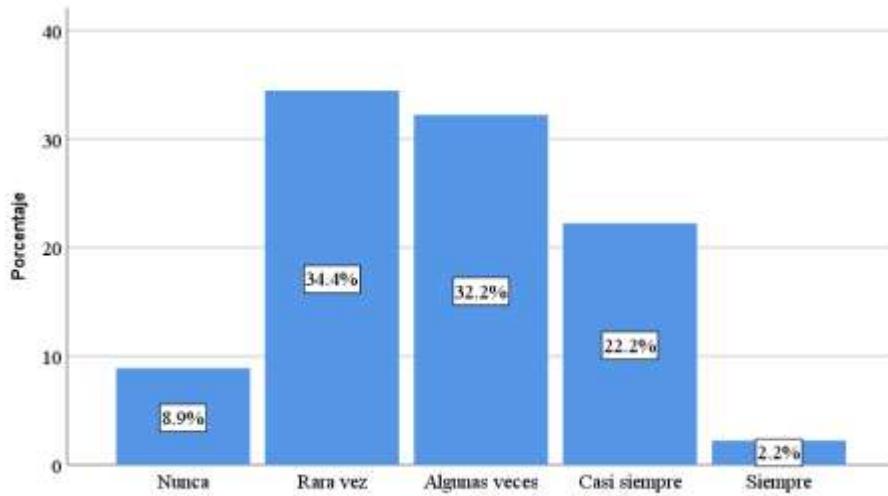
Pregunta 12: Participo en actividades comunitarias con los conocimientos adquiridos

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Nunca	8	8,9	8,9	8,9
	Rara Vez	31	34,4	34,4	43,3
	Algunas Veces	29	32,2	32,2	75,6
	Casi Siempre	20	22,2	22,2	97,8
	Siempre	2	2,2	2,2	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 18

Pregunta 12: Participo en actividades comunitarias con los conocimientos adquiridos



Nota: Distribución porcentual de la pregunta 12.

Interpretación:

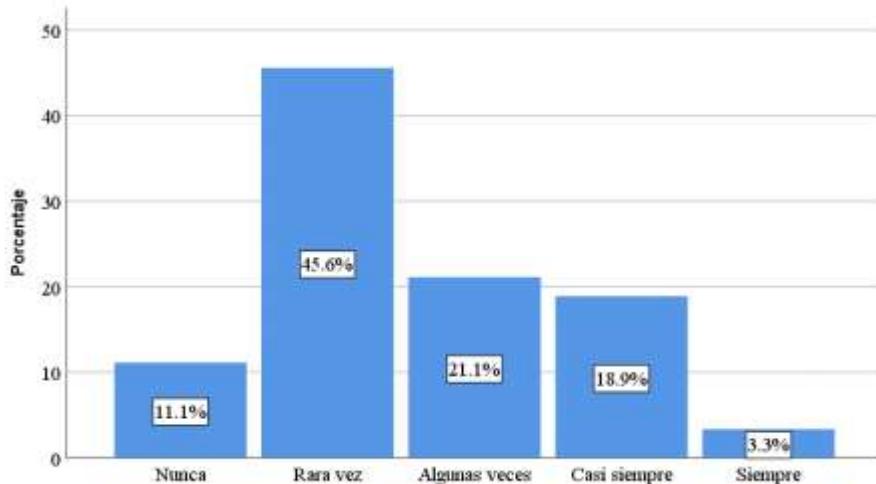
De acuerdo a la pregunta 12, acerca de la participación en actividades comunitarias con los conocimientos adquiridos manifiestan que el 34.4% (31 encuestados) mencionan rara vez, mientras que el 32.2% (29 encuestados) mencionan algunas veces, el 22.2% (20 encuestados) mencionan casi siempre, el 8.9% (8 encuestados) mencionan nunca y el 2.2% (2 encuestados) mencionaron siempre.

Tabla 15

Pregunta 13: Los medios de comunicación apoyan el desarrollo de mis conocimientos

		Frecuencia	Porcentaje		Porcentaje acumulado
			Porcentaje válido	Porcentaje	
Válido	Nunca	10	11,1	11,1	11,1
	Rara Vez	41	45,6	45,6	56,7
	Algunas Veces	19	21,1	21,1	77,8
	Casi Siempre	17	18,9	18,9	96,7
	Siempre	3	3,3	3,3	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 19*Pregunta 13: Los medios de comunicación apoyan el desarrollo de mis conocimientos**Nota:* Distribución porcentual de la pregunta 13.

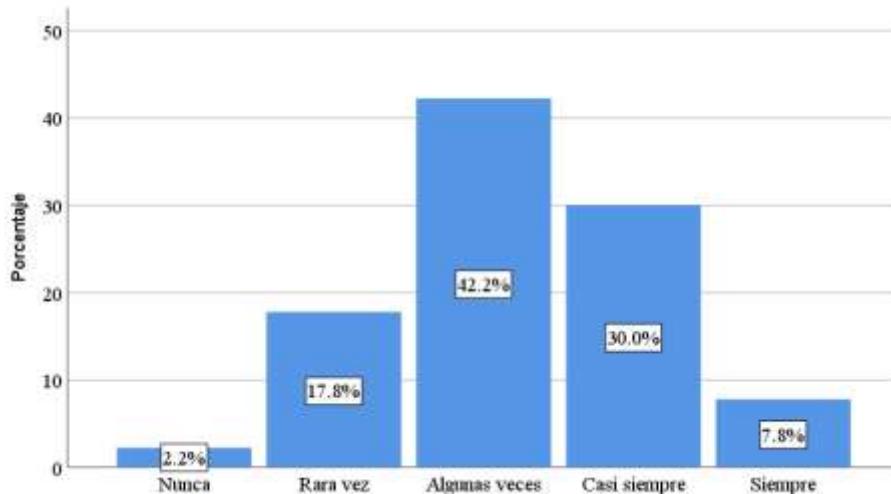
Interpretación:

De acuerdo a la pregunta 13, acerca de los aportes de medios de comunicación en el desarrollo del conocimiento manifiestan que el 45.6% (41 encuestados) mencionan rara vez, mientras que el 21.1% (19 encuestados) mencionan algunas veces, el 18.9% (17 encuestados) mencionan casi siempre, el 11.1% (10 encuestados) mencionan nunca y el 3.3% (3 encuestados) mencionaron siempre.

Tabla 16*Pregunta 14: Planifico mis actividades académicas constantemente*

		Frecuencia	Porcentaje		Porcentaje acumulado
			válido	acumulado	
Válido	Nunca	2	2,2	2,2	2,2
	Rara Vez	16	17,8	17,8	20,0
	Algunas Veces	38	42,2	42,2	62,2
	Casi Siempre	27	30,0	30,0	92,2
	Siempre	7	7,8	7,8	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 20*Pregunta 14: Planifico mis actividades académicas constantemente**Nota:* Distribución porcentual de la pregunta 14.

Interpretación:

De acuerdo a la pregunta 14, acerca de planificar los estudios constantemente manifiestan que el 42.2% (38 encuestados) mencionan algunas veces, mientras que el 30% (27 encuestados) mencionan casi siempre, el 17.8% (16 encuestados) mencionan rara vez, el 7.8% (7 encuestados) mencionan siempre y el 2.2% (2 encuestados) mencionaron nunca.

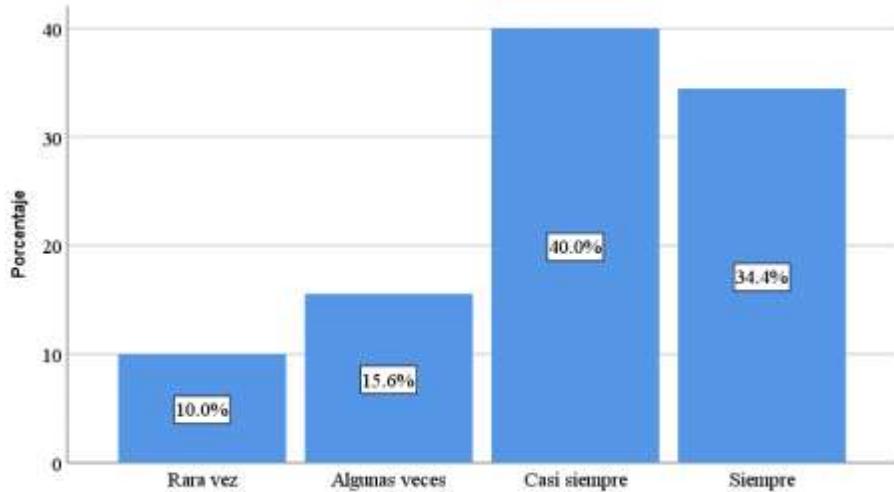
Tabla 17*Pregunta 15: Planifico el uso de TICs para mis estudios e investigaciones*

	Frecuencia	Porcentaje		Porcentaje acumulado
		válido	acumulado	
Válido	Rara Vez	9	10,0	10,0
	Algunas Veces	14	15,6	25,6
	Casi Siempre	36	40,0	65,6
	Siempre	31	34,4	100,0
	Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 21

Pregunta 15: Planifico el uso de TICs para mis estudios e investigaciones



Nota: Distribución porcentual de la pregunta 15.

Interpretación:

De acuerdo a la pregunta 15, acerca de planificar el uso de TICs para estudios e investigaciones manifiestan que el 40% (36 encuestados) mencionan casi siempre, mientras que el 34.4% (31 encuestados) mencionan siempre, el 15.6% (14 encuestados) mencionan algunas veces y el 10% (9 encuestados) mencionan rara vez.

Tabla 18

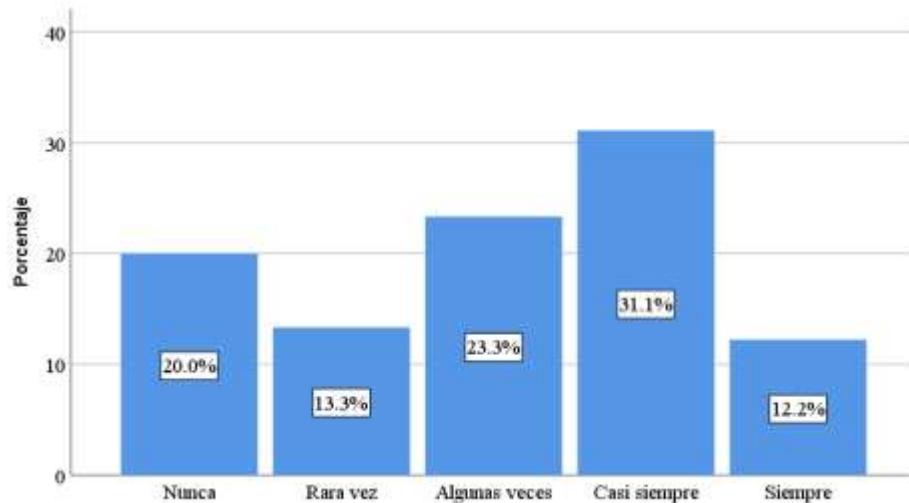
Pregunta 16: Planifico realizar proyectos de emprendimiento académico

		Frecuencia	Porcentaje		Porcentaje acumulado
			Porcentaje válido	Porcentaje	
Válido	Nunca	18	20,0	20,0	20,0
	Rara Vez	12	13,3	13,3	33,3
	Algunas Veces	21	23,3	23,3	56,7
	Casi Siempre	28	31,1	31,1	87,8
	Siempre	11	12,2	12,2	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 22

Pregunta 16: Planifico realizar proyectos de emprendimiento académico



Nota: Distribución porcentual de la pregunta 16.

Interpretación:

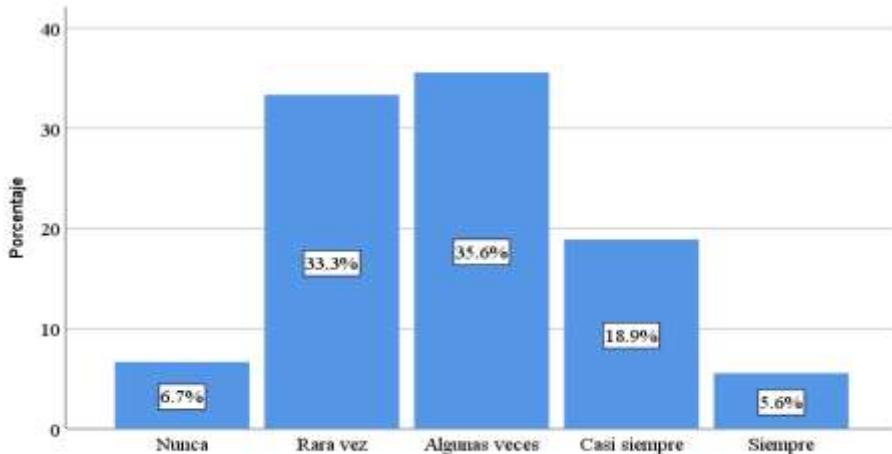
De acuerdo a la pregunta 16, acerca de planificar proyectos de emprendimiento académico manifiestan que el 31.1% (28 encuestados) mencionan casi siempre, mientras que el 23.3% (21 encuestados) mencionan algunas veces, el 20% (18 encuestados) mencionan nunca, el 13.3% (12 encuestados) mencionan rara vez y el 12.2% (11 encuestados) mencionan siempre.

Tabla 19

Pregunta 17: Existe socialización académica con los docentes

	Frecuencia	Porcentaje		Porcentaje acumulado
		Porcentaje válido	Porcentaje	
Válido	Nunca	6	6,7	6,7
	Rara Vez	30	33,3	33,3
	Algunas Veces	32	35,6	75,6
	Casi Siempre	17	18,9	94,4
	Siempre	5	5,6	100,0
	Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 23*Pregunta 17: Existe socialización académica con los docentes**Nota:* Distribución porcentual de la pregunta 17.

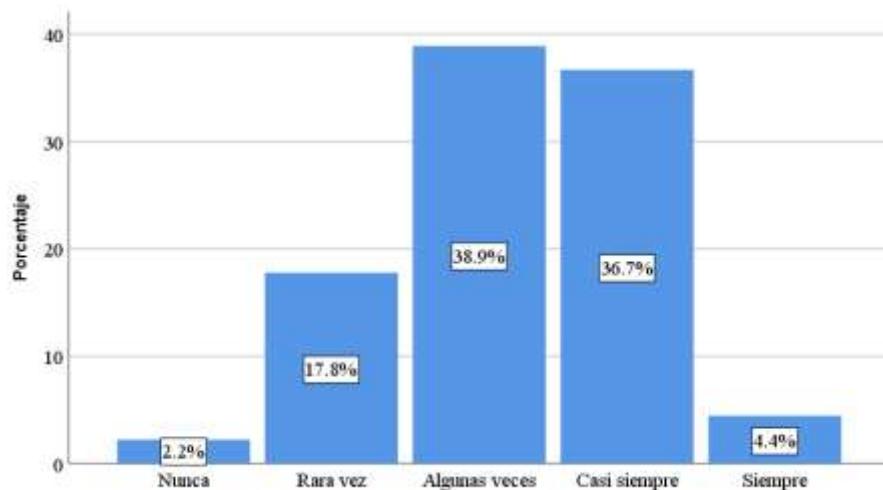
Interpretación:

De acuerdo a la pregunta 17, acerca de la socialización académica con los docentes manifiestan que el 35.6% (32 encuestados) mencionan algunas veces, mientras que el 33.3% (30 encuestados) mencionan rara vez, el 18.9% (17 encuestados) mencionan casi siempre, el 6.7% (6 encuestados) mencionan nunca y el 5.6% (5 encuestados) mencionan siempre.

Tabla 20*Pregunta 18: Existe satisfacción académica en mi experiencia universitaria*

		Frecuencia	Porcentaje		Porcentaje acumulado
			Porcentaje válido	Porcentaje	
Válido	Nunca	2	2,2	2,2	2,2
	Rara Vez	16	17,8	17,8	20,0
	Algunas Veces	35	38,9	38,9	58,9
	Casi Siempre	33	36,7	36,7	95,6
	Siempre	4	4,4	4,4	100,0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.**Figura 24***Pregunta 18: Existe satisfacción académica en mi experiencia universitaria*



Nota: Distribución porcentual de la pregunta 18.

Interpretación:

De acuerdo a la pregunta 18, acerca de la satisfacción académica como experiencia universitaria en general manifiestan que el 38.9% (35 encuestados) mencionan algunas veces, mientras que el 36.7% (33 encuestados) mencionan casi siempre, el 17.8% (16 encuestados) mencionan rara vez, el 4.4% (4 encuestados) mencionan siempre y el 2.2% (2 encuestados) mencionan nunca.

Tabla 21

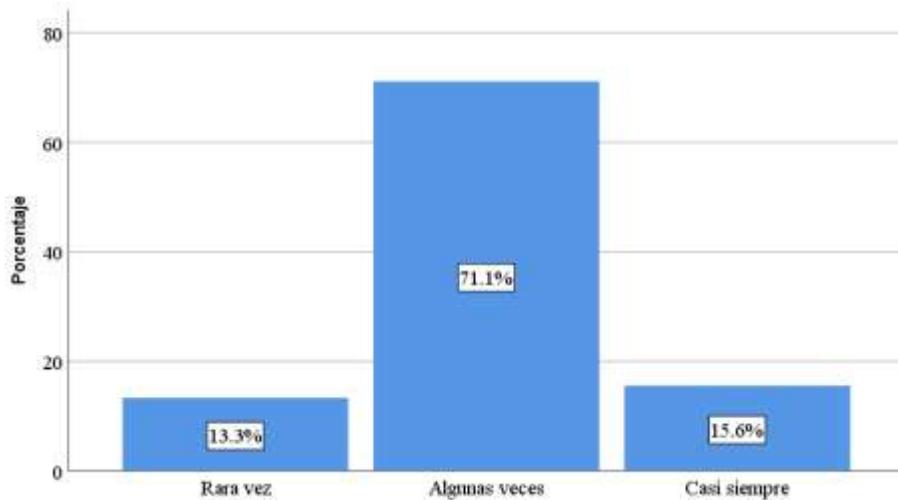
Pregunta 19: *El nivel de logro de aprendizaje es satisfactorio*

		Frecuencia	Porcentaje		Porcentaje acumulado
			válido	acumulado	
Válido	Insuficiente	12	13.3	13.3	13.3
	Aprobado	64	71.1	71.1	84.4
	Bueno	14	15.6	15.6	100.0
	Total	90	100.0	100.0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 25

Pregunta 19: El nivel de logro de aprendizaje es satisfactorio



Nota: Distribución porcentual de la pregunta 19.

Interpretación:

Conforme a la pregunta 19, acerca del logro de aprendizaje obtenido, en general manifiestan que el 13.3% (12 encuestados) mencionan rara vez, mientras que el 71.1% (64 encuestados) mencionan algunas veces y el 15.6% (14 encuestados) mencionan que el logro fue casi siempre.

Variable 2: algoritmos de aprendizaje automático

Tabla 22

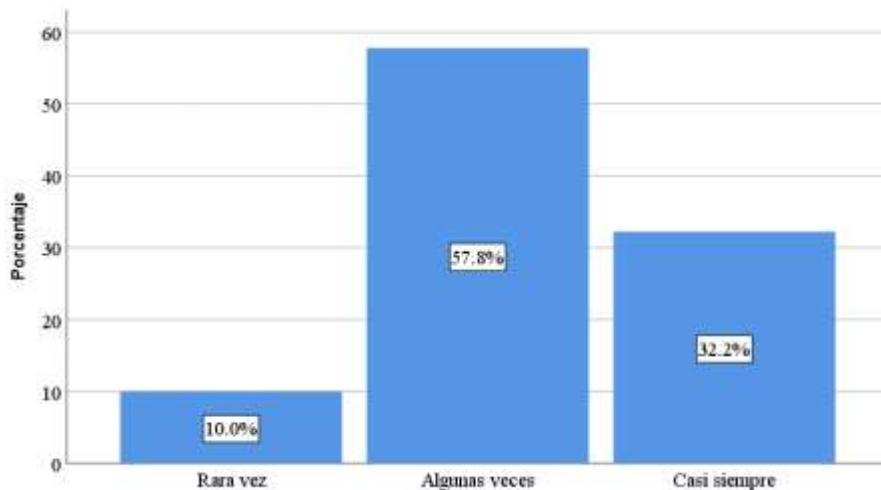
Po1: Aprendizaje dimensión actitud del algoritmo arboles de decisión

	Valido	Rara vez	Frecuencia	Porcentaje	
				válido	acumulado
		Rara vez	9	10.0	10.0
		Algunas veces	52	57.8	57.8
		Casi siempre	29	32.2	100.0
		Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 26

Po1: Aprendizaje dimensión actitud del algoritmo arboles de decisión



Nota: Distribución porcentual de la pregunta 01.

Interpretación:

De acuerdo al criterio 01, referente al aprendizaje en la dimensión actitud del algoritmo arboles de decisión establece que el 57.8% (52 encuestados) mencionan algunas veces, mientras que el 32.2% (29 encuestados) mencionan casi siempre y el 10% (9 encuestados) mencionan rara vez.

Tabla 23

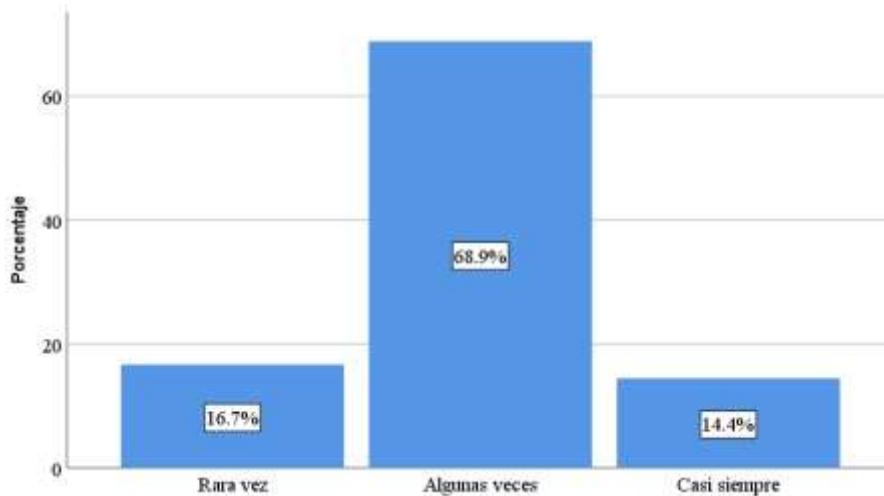
Po2: Aprendizaje dimensión medio ambiente del algoritmo arboles de decisión

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	15	16.7	16.7	16.7
	Algunas veces	62	68.9	68.9	85.6
	Casi siempre	13	14.4	14.4	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 27

Po2: Aprendizaje dimensión medio ambiente del algoritmo arboles de decisión



Nota: Distribución porcentual de la pregunta 02.

Interpretación:

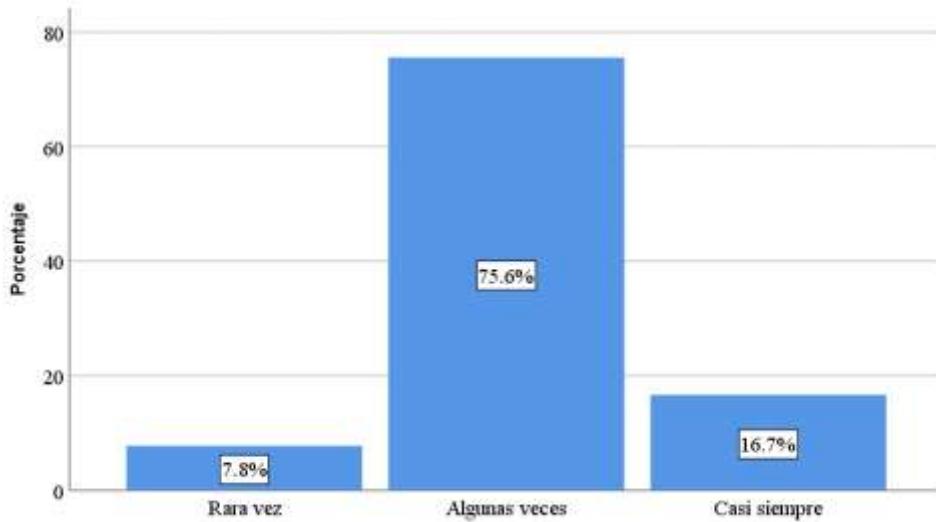
De acuerdo al criterio 02, referente al aprendizaje en la dimensión medio ambiente del algoritmo arboles de decisión establece que el 68.9% (62 encuestados) mencionan algunas veces, mientras que el 16.7% (15 encuestados) mencionan rara vez y el 14.4% (13 encuestados) mencionan casi siempre.

Tabla 24

Po3: Aprendizaje dimensión instrucción del algoritmo arboles de decisión

	Frecuencia	Porcentaje	Porcentaje	Porcentaje
			válido	acumulado
Válido	Rara vez	7	7.8	7.8
	Algunas veces	68	75.6	75.6
	Casi siempre	15	16.7	16.7
	Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 28*Po3: Aprendizaje dimensión instrucción del algoritmo arboles de decisión**Nota:* Distribución porcentual de la pregunta 03.

Interpretación:

De acuerdo al criterio 03, referente al aprendizaje en la dimensión instrucción del algoritmo arboles de decisión establece que el 75.6% (68 encuestados) mencionan algunas veces, mientras que el 16.7% (15 encuestados) mencionan casi siempre y el 7.8% (7 encuestados) mencionan rara vez.

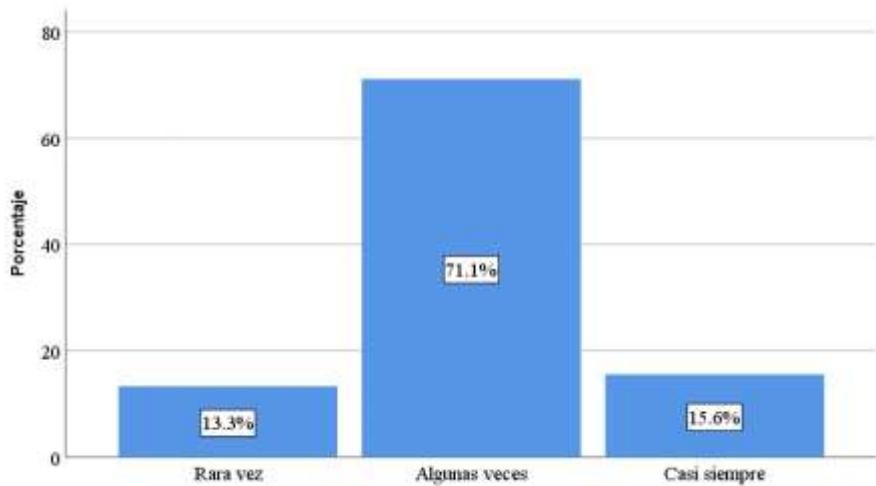
Tabla 25*Po4: Aprendizaje Logro del algoritmo arboles de decisión*

		Frecuencia	Porcentaje		Porcentaje acumulado
			válido	acumulado	
Válido	Rara vez	12	13.3	13.3	13.3
	Algunas veces	64	71.1	71.1	84.4
	Casi siempre	14	15.6	15.6	100.0
	Total	90	100.0	100.0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 29

Po4: Aprendizaje Logro del algoritmo arboles de decisión



Nota: Distribución porcentual de la pregunta 04.

Interpretación:

De acuerdo al criterio 04, referente al aprendizaje en la dimensión logro del algoritmo arboles de decisión establecen que el 13.3% (12 encuestados) mencionan rara vez, mientras que el 71.1% (64 encuestados) mencionan algunas veces y el 15.6% (14 encuestados) casi siempre.

Tabla 26

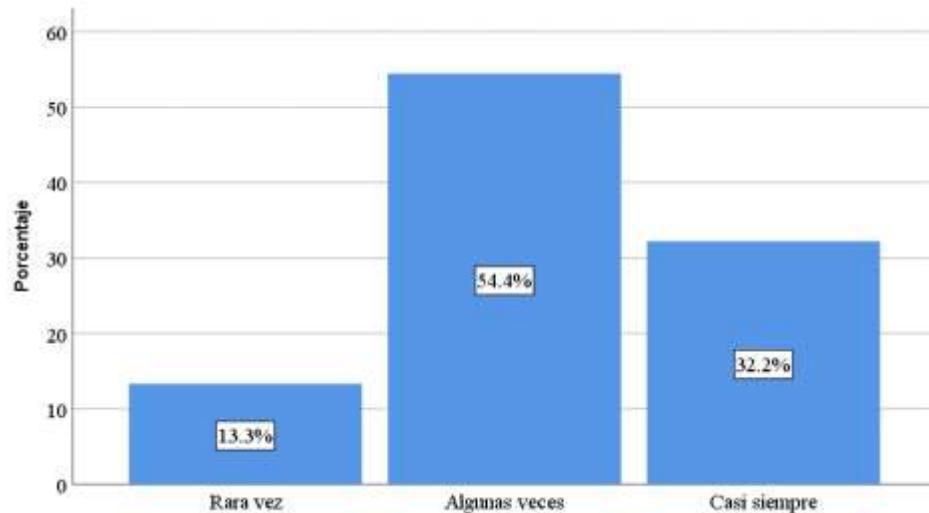
Po5: Asertividad dimensión aptitud del algoritmo arboles de decisión

	Frecuencia	Porcentaje	Porcentaje	Porcentaje
			válido	acumulado
Válido	Rara vez	12	13.3	13.3
	Algunas veces	49	54.4	54.4
	Casi siempre	29	32.2	32.2
	Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 30

Po5: Asertividad dimensión aptitud del algoritmo arboles de decisión



Nota: Distribución porcentual de la pregunta 05.

Interpretación:

De acuerdo al criterio 05, de asertividad en la dimensión aptitud del algoritmo arboles de decisión establece que el 54.4% (49 encuestados) mencionan algunas veces, mientras que el 32.2% (29 encuestados) mencionan casi siempre y el 13.3% (12 encuestados) mencionan rara vez.

Tabla 27

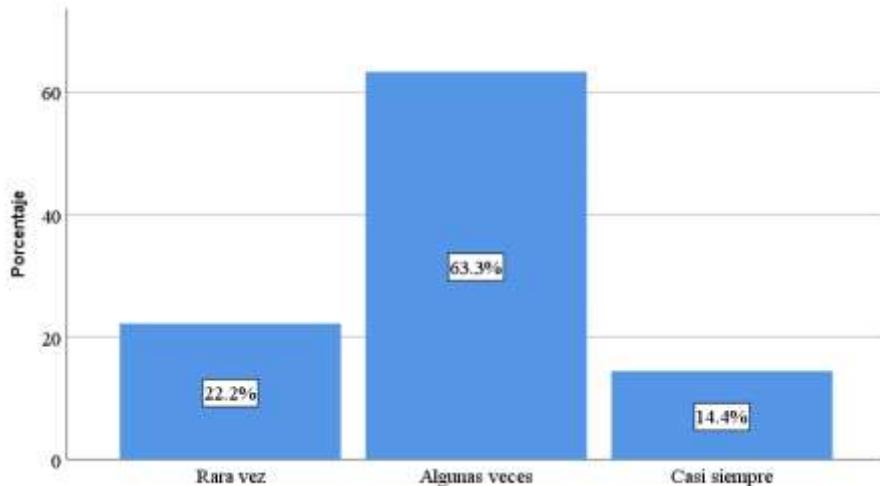
Po6: Asertividad dimensión medio ambiente del algoritmo arboles de decisión

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	20	22.2	22.2	22.2
	Algunas veces	57	63.3	63.3	85.6
	Casi siempre	13	14.4	14.4	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 31

Po6: Asertividad dimensión medio ambiente del algoritmo arboles de decisión



Nota: Distribución porcentual de la pregunta 05.

Interpretación:

De acuerdo al criterio 06, de asertividad en la dimensión medio ambiente del algoritmo arboles de decisión establece que el 63.3% (57 encuestados) mencionan algunas veces, mientras que el 22.2% (20 encuestados) mencionan rara vez y el 14.4% (13 encuestados) mencionan casi siempre.

Tabla 28

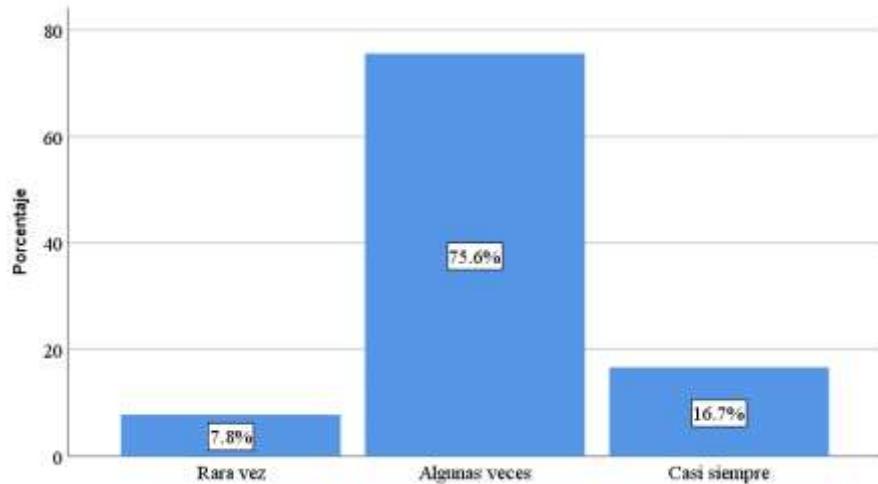
Po7: Asertividad dimensión instrucción del algoritmo arboles de decisión

	Frecuencia	Porcentaje	Porcentaje	Porcentaje
			válido	acumulado
Válido	Rara vez	7	7.8	7.8
	Algunas veces	68	75.6	75.6
	Casi siempre	15	16.7	16.7
	Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 32

Po7: Asertividad dimensión instrucción del algoritmo arboles de decisión



Nota: Distribución porcentual de la pregunta 07.

Interpretación:

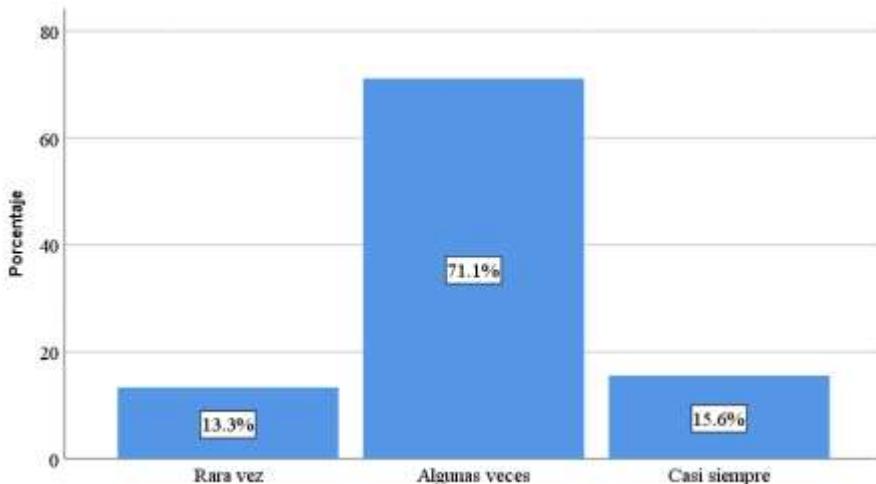
De acuerdo al criterio 07, de asertividad en la dimensión instrucción del algoritmo arboles de decisión establece que el 75.6% (68 encuestados) menciona algunas veces, mientras que el 16.7% (15 encuestados) menciona casi siempre y el 7.8% (7 encuestados) menciona rara.

Tabla 29

Po8: Asertividad dimensión logro del algoritmo arboles de decisión

	Frecuencia	Porcentaje		Porcentaje acumulado
		válido	acumulado	
Válido	Rara vez	12	13.3	13.3
	Algunas veces	64	71.1	84.4
	Casi siempre	14	15.6	100.0
	Total	90	100.0	100.0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 33*Po8: Asertividad dimensión logro del algoritmo arboles de decisión*

Nota: Distribución porcentual de la pregunta 08.

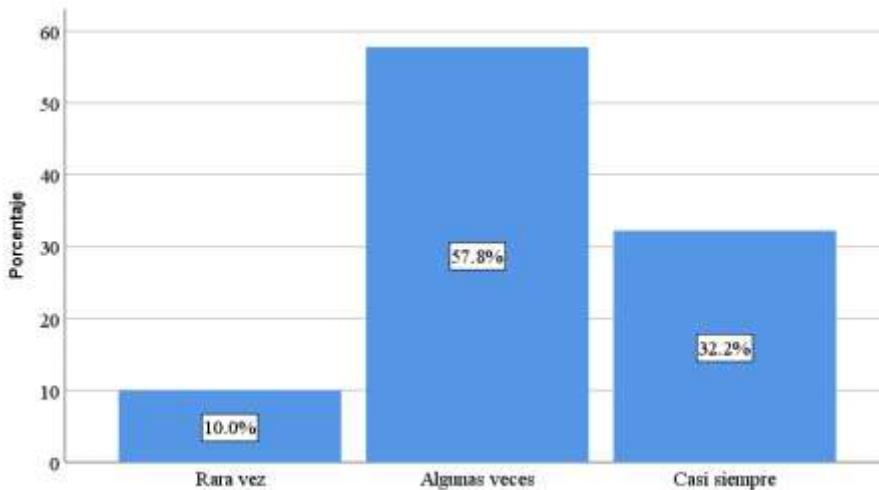
Interpretación:

De acuerdo al criterio 08, de asertividad en la dimensión logro del algoritmo arboles de decisión establece que el 13.3% (12 encuestados) menciona rara vez, mientras que el 71.1% (54 encuestados) menciona algunas veces y el 15.8.8% (14 encuestados) casi siempre.

Tabla 30*Po9: Aprendizaje dimensión aptitud del algoritmo Naive Bayes*

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Valido	Rara vez	9	10.0	10.0	10.0
	Algunas veces	52	57.8	57.8	67.8
	Casi siempre	29	32.2	32.2	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 34*Po9: Aprendizaje dimensión aptitud del algoritmo Naive Bayes**Nota:* Distribución porcentual de la pregunta 09.

Interpretación:

De acuerdo al criterio 09, referente al aprendizaje en la dimensión aptitud del algoritmo Naive Bayes establece que el 57.8% (52 encuestados) mencionan algunas veces, mientras que el 32.2% (29 encuestados) mencionan casi siempre y el 10% (9 encuestados) mencionan rara vez.

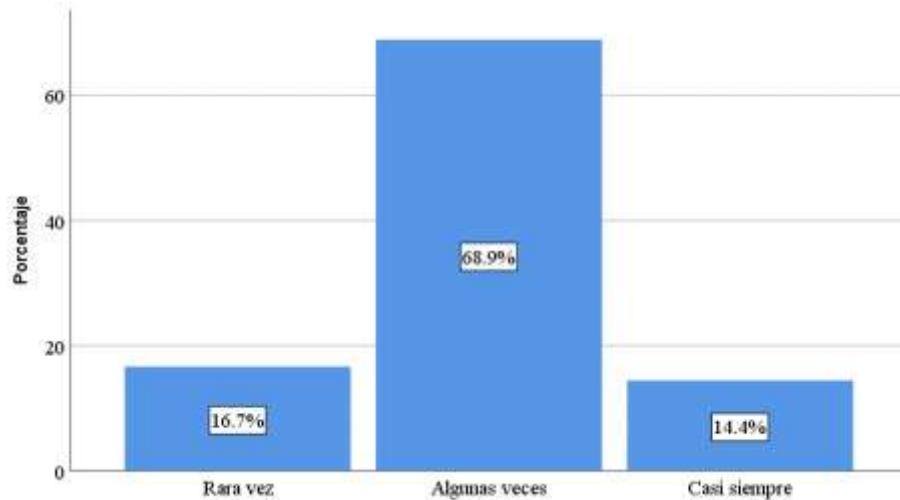
Tabla 31*Po10: Aprendizaje dimensión medio ambiente del algoritmo Naive Bayes*

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	15	16.7	16.7	16.7
	Algunas veces	62	68.9	68.9	85.6
	Casi siempre	13	14.4	14.4	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 35

Po10: Aprendizaje dimensión medio ambiente del algoritmo Naive Bayes



Nota: Distribución porcentual de la pregunta 010.

Interpretación:

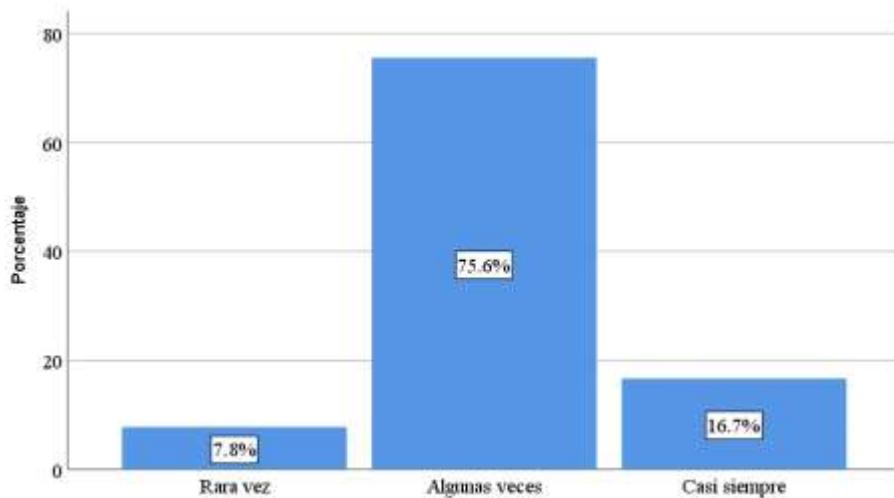
De acuerdo al criterio 010, referente al aprendizaje en la dimensión medio ambiente del algoritmo Naive Bayes establece que el 68.9% (62 encuestados) mencionan algunas veces, mientras que el 16.7% (15 encuestados) mencionan rara vez y el 14.4% (13 encuestados) mencionan casi siempre.

Tabla 32

Po11: Aprendizaje dimensión instrucción del algoritmo Naive Bayes

		Frecuencia	Porcentaje válido	Porcentaje	Porcentaje
				acumulado	
Válido	Rara vez	7	7.8	7.8	7.8
	Algunas veces	68	75.6	75.6	83.3
	Casi siempre	15	16.7	16.7	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 36*Po11: Aprendizaje dimensión instrucción del algoritmo Naive Bayes*

Nota: Distribución porcentual de la pregunta 011.

Interpretación:

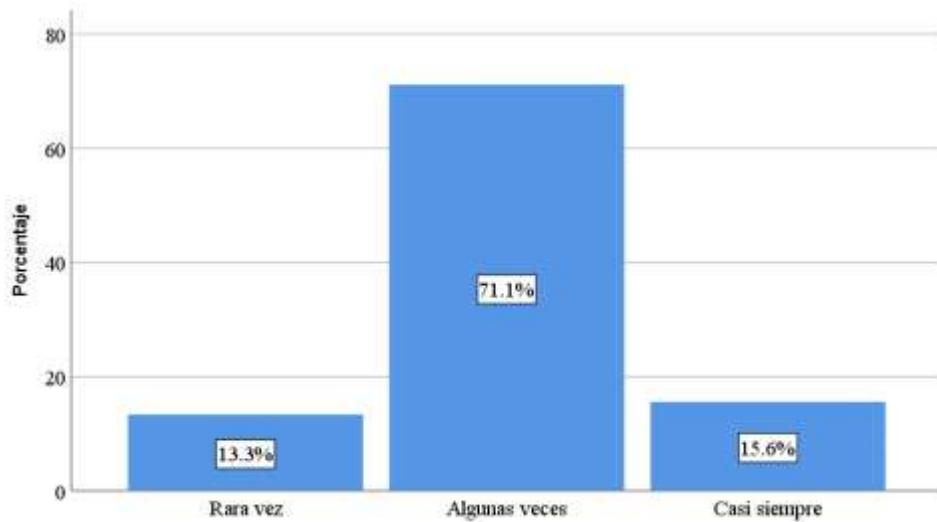
De acuerdo al criterio 011, referente al aprendizaje en la dimensión instrucción del algoritmo Naive Bayes establece que el 75.6% (68 encuestados) mencionan algunas veces, mientras que el 16.7% (15 encuestados) mencionan casi siempre y el 7.8% (7 encuestados) mencionan rara vez.

Tabla 33*Po12: Aprendizaje logro del algoritmo Naive Bayes*

	Frecuencia	Porcentaje		Porcentaje acumulado
		válido	acumulado	
Válido	Rara vez	12	13.3	13.3
	Algunas veces	64	71.1	71.1
	Casi siempre	14	15.6	100.0
	Total	90	100.0	100.0

Figura 37

P012: Aprendizaje logro del algoritmo Naive Bayes



Nota: Distribución porcentual de la pregunta 012.

Interpretación:

De acuerdo al criterio 012, referente al aprendizaje en la dimensión logro del algoritmo Naive Bayes establece que el 13.3% (12 encuestados) mencionan rara vez, mientras que el 71.1% (64 encuestados) mencionan algunas veces y el 15.6% (14 encuestados) mencionan casi siempre.

Tabla 34

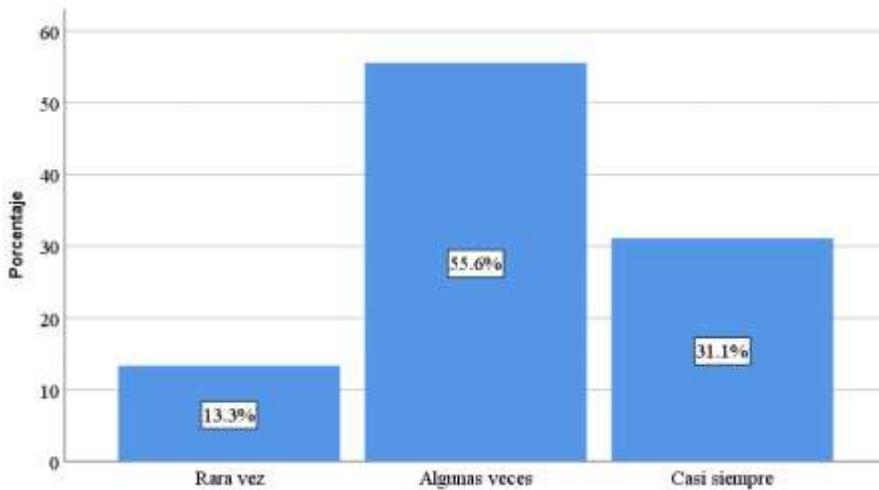
P013: Asertividad en la dimensión aptitud del algoritmo Naive Bayes

Válido		Frecuencia	Porcentaje válido	Porcentaje	
				acumulado	
	Rara vez	12	13.3	13.3	13.3
	Algunas veces	50	55.6	55.6	68.9
	Casi siempre	28	31.1	31.1	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 38

P013: Asertividad en la dimensión aptitud del algoritmo Naive Bayes



Nota: Distribución porcentual de la pregunta 013.

Interpretación:

De acuerdo al criterio 013, de asertividad en la dimensión aptitud del algoritmo Naive Bayes establece que el 55.6% (50 encuestados) responde algunas veces, mientras que el 31.1% (28 encuestados) responde casi siempre y el 13.3% (12 encuestados) responde rara vez.

Tabla 35

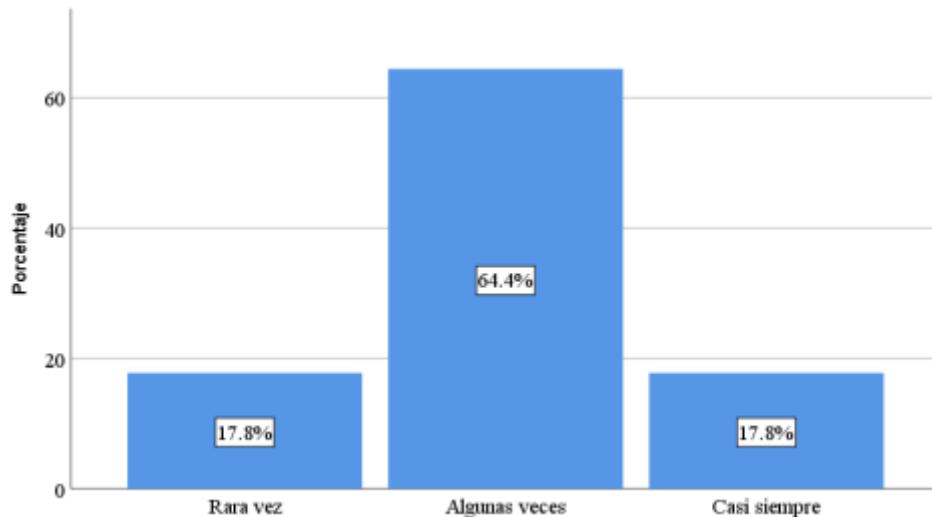
P014: Asertividad dimensión medio ambiente del algoritmo Naive Bayes

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	16	17.8	17.8	17.8
	Algunas veces	58	64.4	64.4	82.2
	Casi siempre	16	17.8	17.8	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 39

Po14: Asertividad en la dimensión medio ambiente del algoritmo Naive Bayes



Nota: Distribución porcentual de la pregunta 014.

Interpretación:

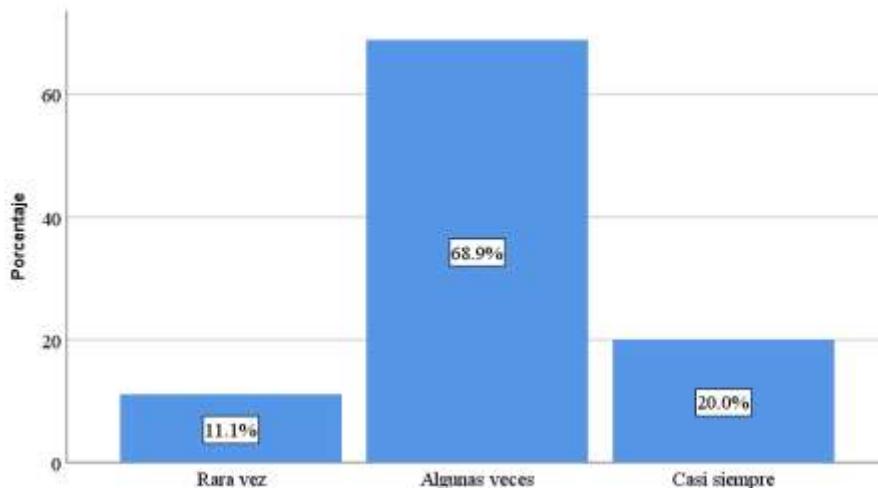
De acuerdo al criterio 014, de asertividad en la dimensión medio ambiente del algoritmo Naive Bayes establece que el 64.4% (58 encuestados) responde algunas veces, mientras que el 17.8% (16 encuestados) responde rara vez y, casi siempre.

Tabla 36

Po15: Asertividad dimensión instrucción del algoritmo Naive Bayes

	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	10	11.1	11.1
	Algunas veces	62	68.9	68.9
	Casi siempre	18	20.0	100.0
Total		90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 40*P015: Asertividad dimensión instrucción del algoritmo Naive Bayes*

Nota: Distribución porcentual de la pregunta 015.

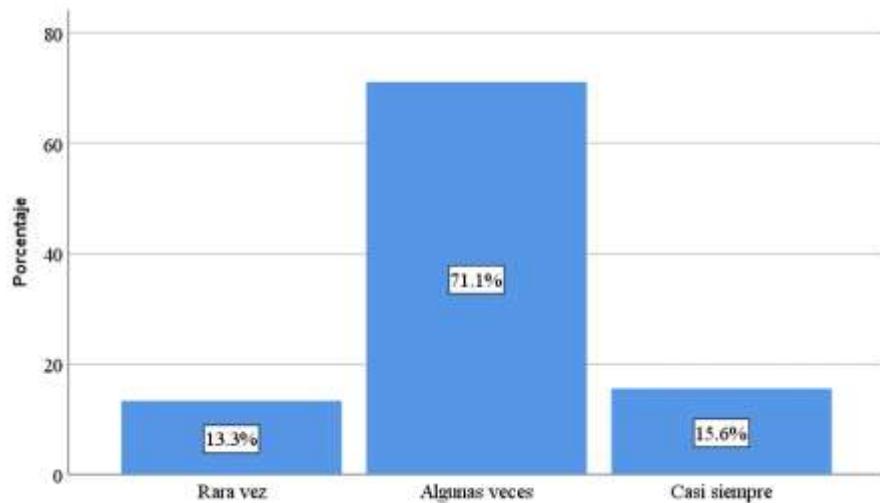
Interpretación:

De acuerdo al criterio 015, de asertividad en la dimensión instrucción del algoritmo Naive Bayes establece que el 68.9% (62 encuestados) responde algunas veces, mientras que el 20% (18 encuestados) responde casi siempre y 11.1% (10 encuestados) responde casi siempre.

Tabla 37*P016: Asertividad logro del algoritmo Naive Bayes*

	Frecuencia	Porcentaje		Porcentaje acumulado
		válido	acumulado	
Válido	Rara vez	12	13.3	13.3
	Algunas veces	64	71.1	84.4
	Casi siempre	14	15.6	100.0
	Total	90	100.0	100.0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 41*Po16: Asertividad logro del algoritmo Naive Bayes*

Nota: Distribución porcentual de la pregunta 016.

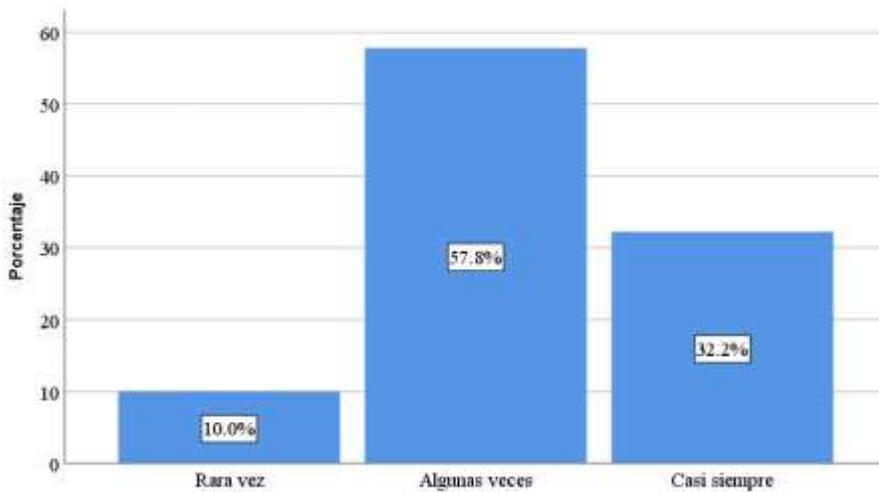
Interpretación:

De acuerdo al criterio 016, referente a asertividad en la dimensión logro del algoritmo Naive Bayes establece que el 13.3% (12 encuestados) mencionan rara vez, mientras que el 71.1% (64 encuestados) mencionan algunas veces y el 15.6% (14 encuestados) mencionan casi siempre.

Tabla 38*Po17: Aprendizaje dimensión instrucción del algoritmo Random Forest*

	Valido	Rara vez	Frecuencia	Porcentaje	
				válido	acumulado
		Rara vez	9	10.0	10.0
		Algunas veces	52	57.8	57.8
		Casi siempre	29	32.2	100.0
		Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 42*Po17: Aprendizaje dimensión instrucción del algoritmo Random Forest*

Nota: Distribución porcentual de la pregunta 017.

Interpretación:

De acuerdo al criterio 017, referente al aprendizaje en la dimensión instrucción del algoritmo Random Forest establece que el 57.8% (52 encuestados) responden algunas veces, mientras que el 32.2% (29 encuestados) responde casi siempre y el 10% (9 encuestados) mencionan rara vez.

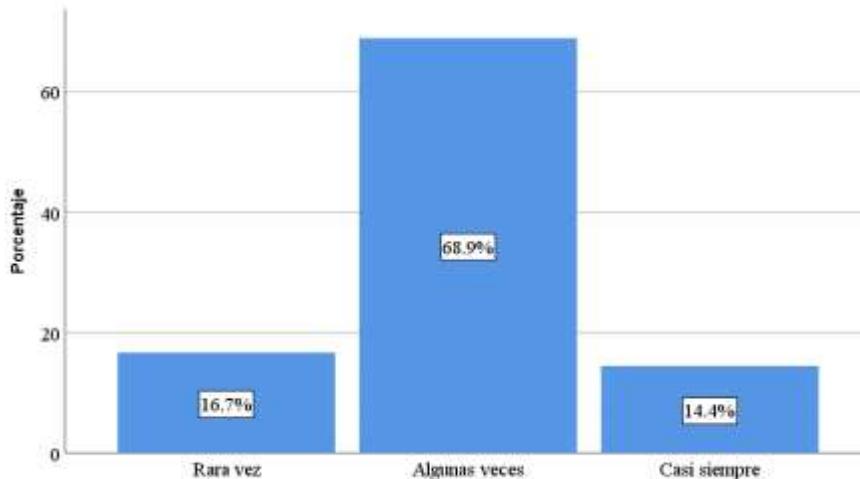
Tabla 39*Po18: Aprendizaje dimensión medio ambiente del algoritmo Random Forest*

	Frecuencia	Porcentaje	Porcentaje	
			e válido	acumulado
Válido	Rara vez	15	16.7	16.7
	Algunas veces	62	68.9	85.6
	Casi siempre	13	14.4	100.0
	Total	90	100,0	100,0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 43

Po18: Aprendizaje dimensión medio ambiente del algoritmo Random Forest



Nota: Distribución porcentual de la pregunta 018.

Interpretación:

De acuerdo al criterio 018, referente al aprendizaje en la dimensión medio ambiente del algoritmo Random Forest establece que el 68.9% (62 encuestados) responde algunas veces, mientras que el 16.7% (15 encuestados) responde rara vez y el 14.4% (13 encuestados) responde casi siempre.

Tabla 40

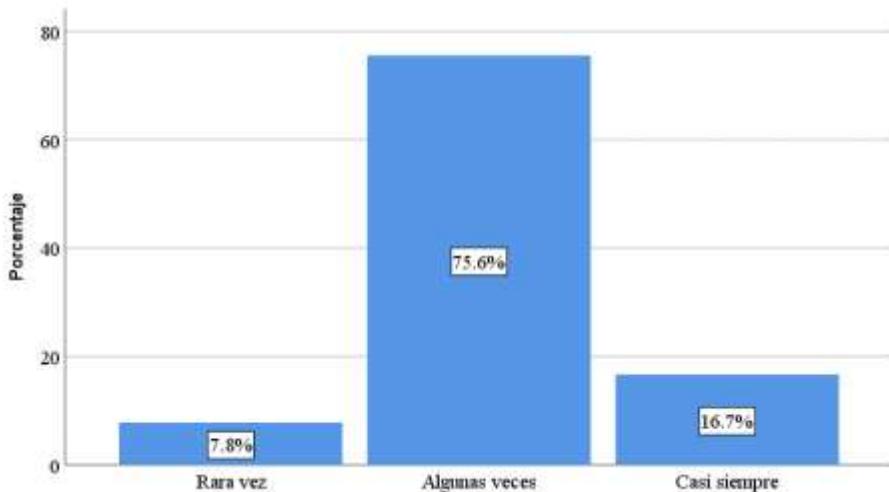
Po19: Aprendizaje dimensión instrucción del algoritmo Random Forest

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	7	7.8	7.8	7.8
	Algunas veces	68	75.6	75.6	83.3
	Casi siempre	15	16.7	16.7	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 44

Po19: Aprendizaje dimensión instrucción del algoritmo Random Forest



Nota: Distribución porcentual de la pregunta 019.

Interpretación:

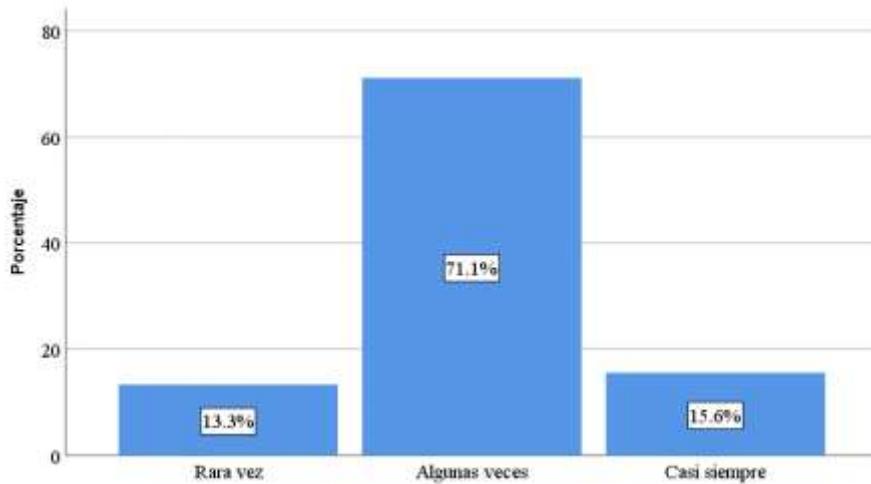
De acuerdo al criterio 019, referente al aprendizaje en la dimensión instrucción del algoritmo Random Forest establece que el 75.6% (68 encuestados) responde algunas veces, mientras que el 16.7% (15 encuestados) responde casi siempre y el 7.8% (7 encuestados) responde rara vez.

Tabla 41

Po20: Aprendizaje logro del algoritmo Random Forest

	Frecuencia	Porcentaje		Porcentaje acumulado
		válido	acumulado	
Válido	Rara vez	12	13.3	13.3
	Algunas veces	64	71.1	84.4
	Casi siempre	14	15.6	100.0
	Total	90	100.0	100.0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 45*Po20: Aprendizaje logro del algoritmo Random Forest*

Nota: Distribución porcentual de la pregunta o20.

Interpretación:

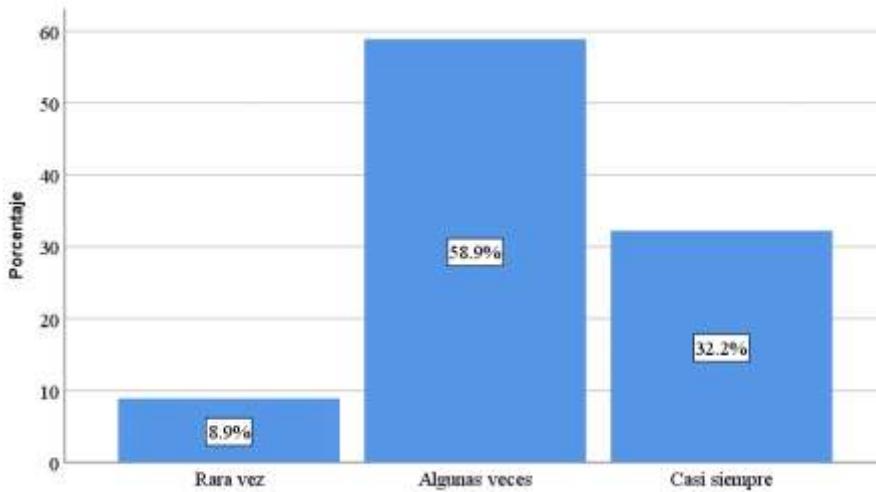
De acuerdo al criterio o20, referente a aprendizaje en la dimensión logro del algoritmo Random Forest establece que el 13.3% (12 encuestados) mencionan rara vez, mientras que el 71.1% (64 encuestados) mencionan algunas veces y el 15.6% (14 encuestados) mencionan casi siempre.

Tabla 42*Po21: Asertividad dimensión aptitud del algoritmo Random Forest*

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	8	8.9	8.9	8.9
	Algunas veces	53	58.9	58.9	67.8
	Casi siempre	29	32.2	32.2	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 46*Po21: Asertividad dimensión aptitud del algoritmo Random Forest*



Nota: Distribución porcentual de la pregunta 021.

Interpretación:

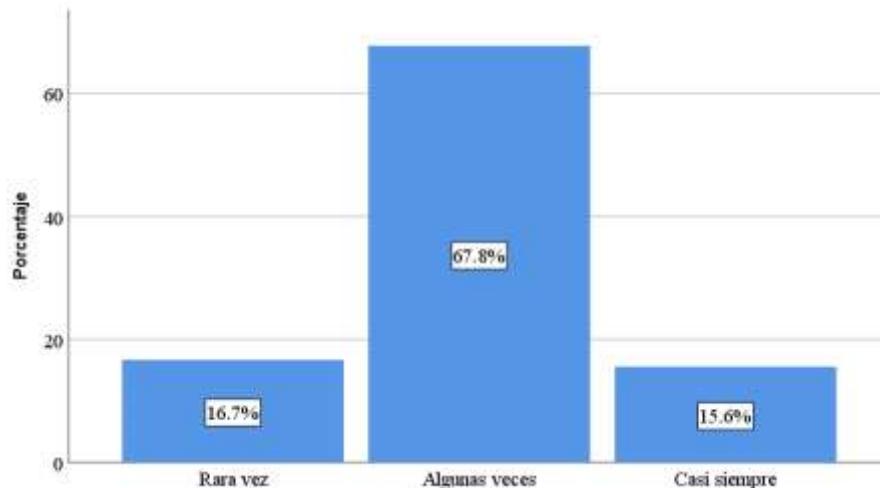
De acuerdo al criterio 021, de asertividad en la dimensión aptitud del algoritmo Random Forest establece que el 58.9% (53 encuestados) responde algunas veces, mientras que el 32.2% (29 encuestados) responde casi siempre y el 8.9% (8 encuestados) responde rara vez.

Tabla 43

P022: Asertividad dimensión medio ambiente del algoritmo Random Forest

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	15	16.7	16.7	16.7
	Algunas veces	61	67.8	67.8	84.4
	Casi siempre	14	15.6	15.6	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 47*Po22: Asertividad dimensión medio ambiente del algoritmo Random Forest*

Nota: Distribución porcentual de la pregunta 022.

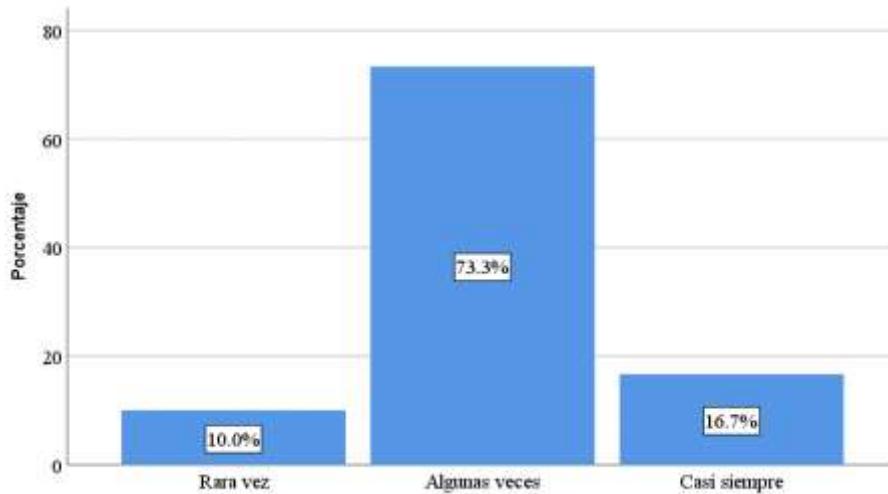
Interpretación:

De acuerdo al criterio 022, de asertividad en la dimensión medio ambiente del algoritmo Random Forest establece que el 67.8% (61 encuestados) responde algunas veces, mientras que el 16.7% (15 encuestados) responde rara vez y el 15.6% (14 encuestados) responde casi siempre.

Tabla 44*Po23: Asertividad dimensión instrucción del algoritmo Random Forest*

		Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	9	10.0	10.0	10.0
	Algunas veces	66	73.3	73.3	83.3
	Casi siempre	15	16.7	16.7	100.0
	Total	90	100,0	100,0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 48*Po23: Asertividad dimensión instrucción del algoritmo Random Forest*

Nota: Distribución porcentual de la pregunta 023.

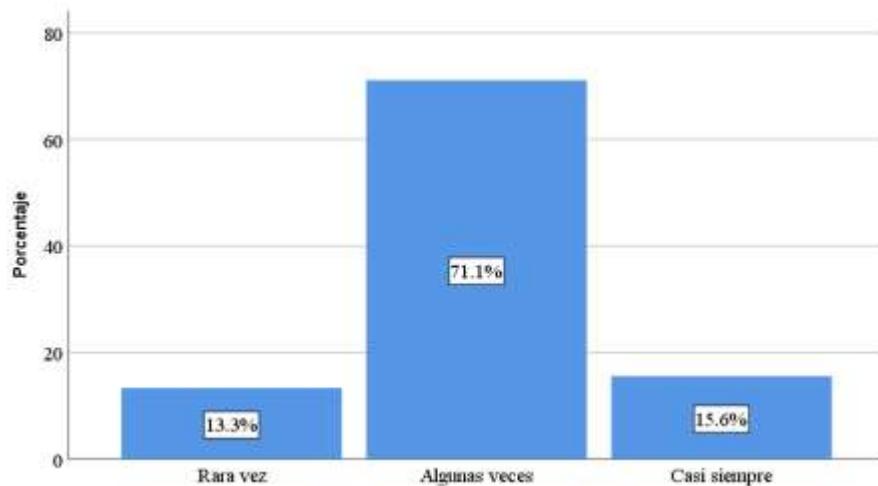
Interpretación:

De acuerdo al criterio 023, de asertividad en la dimensión instrucción del algoritmo Random Forest establece que el 73.3% (66 encuestados) responde algunas veces, mientras que el 16.7% (15 encuestados) responde casi siempre y el 10% (9 encuestados) responde rara vez.

Tabla 45*Po24: Asertividad logro del algoritmo Random Forest*

		Frecuencia	Porcentaje válido	Porcentaje acumulado
Válido	Rara vez	12	13.3	13.3
	Algunas veces	64	71.1	84.4
	Casi siempre	14	15.6	100.0
	Total	90	100.0	100.0

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 49*Po24: Asertividad logro del algoritmo Random Forest*

Nota: Distribución porcentual de la pregunta o24.

Interpretación:

De acuerdo al criterio o24, referente a la asertividad en la dimensión logro del algoritmo Random Forest establece que el 13.3% (12 encuestados) mencionan rara vez, mientras que el 71.1% (64 encuestados) mencionan algunas veces y el 15.6% (14 encuestados) mencionan casi siempre.

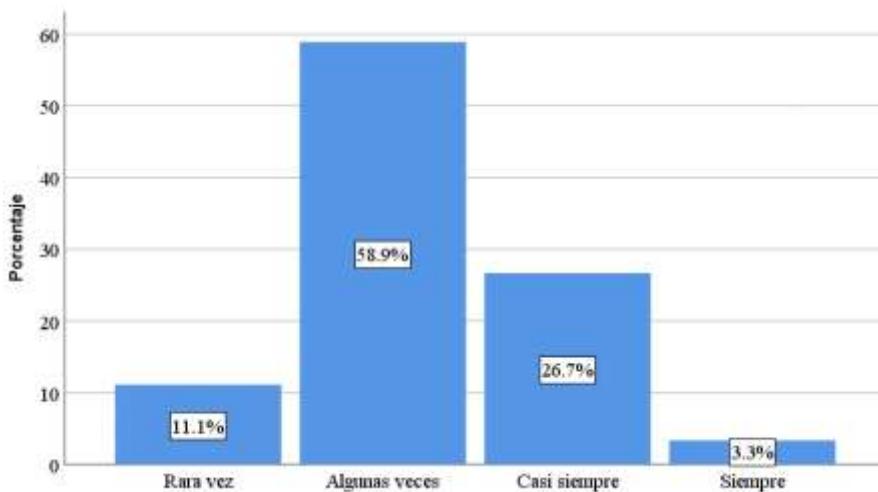
Tabla 46*Po25: Predicción*

		Frecuencia	Porcentaje		Porcentaje acumulado
			válido	acumulado	
Válido	Rara vez	10	11.1	11.1	11.1
	Algunas veces	53	58.9	58.9	70.0
	Casi siempre	24	26.7	26.7	96.7
	Siempre	3	3.3	3.3	100.0
	Total	90	100.0	100.0	

Nota: Elaboración propia a partir de SPSS versión 26.

Figura 50

Po25: Predicción



Nota: Distribución porcentual de la pregunta 025.

Interpretación:

De acuerdo al criterio 025, referente a la predicción de los algoritmos de aprendizaje automático mencionan que el 11.1% (10 encuestados) mencionan rara vez, mientras el 58.9% (53 encuestados) mencionan algunas veces, el 26.7% (24 encuestados) mencionan casi siempre y el 3.3% (3 encuestados) mencionan siempre.

Análisis inferencial

Luego de realizar el análisis del descriptivo de las variables, procederemos a realizar el análisis inferencial que consiste en la prueba de normalidad y prueba de hipótesis planteadas en el presente trabajo de investigación.

Prueba de normalidad

Una herramienta estadística para determinar si un conjunto de datos tiene una distribución normal o gaussiana es la prueba de normalidad (Ghasemi y Zahediasl, 2012), para ello vamos a utilizar la prueba Kolmogorov-Smirnov (K-S), a fin de comprobar si los datos de la muestra proceden de una distribución normal en variables cuantitativas y cuyo tamaño de muestra poblacional sea mayor a 50 (Ghasemi y Zahediasl, 2012; Mishra et al., 2019).

Tabla 47*Prueba de normalidad*

Kolmogorov-Smirnov ^a			
	Estadístico	gl	Sig.
Productividad Educativa	.113	90	.006
Algoritmos de Aprendizaje Automático	.143	90	.000

a. Corrección de significación de Lilliefors

Nota: Elaboración Propia con Software IBM SPSS versión 24

Interpretación:

Se observan en la tabla las pruebas de normalidad para las variables Productividad educativa y Algoritmos de Aprendizaje Automático no siguen una distribución normal, debido a que el p-valor es $< \alpha$ (0.05) para las dos variables, por lo tanto, utilizaremos pruebas no paramétricas; asimismo, al no pertenecer a una distribución normal se procesó con el Rho de Spearman

Prueba no paramétrica con rho de Spemann

Según Martínez Rebollar y Campos Francisco (2015), la prueba de Rho de Spearman es una prueba estadística no paramétrica que se utiliza para medir la asociación directa o inversa entre dos variables cuantitativas (monotónica), la interpretación de este tipo de prueba se basa en el valor de Rho de Spearman, que varía entre -1 y 1.

Tabla 48*Interpretación del coeficiente de correlación de Spearman*

Valor de Rho	Significado
-1	Correlación negativa grande y perfecta
-0,9 a -0,99	Correlación negativa muy alta
-0,7 a -0,89	Correlación negativa alta
-0,4 a -0,69	Correlación negativa moderada
-0,2 a -0,39	Correlación negativa baja
-0,01 a -0,19	Correlación negativa muy baja

0	Correlación nula
0,01 a 0,19	Correlación positiva muy baja
0,2 a 0,39	Correlación positiva baja
0,4 a 0,69	Correlación positiva moderada
0,7 a 0,89	Correlación positiva alta
0,9 a 0,99	Correlación positiva muy alta
1	Correlación positiva grande y perfecta

Nota: (Martínez Rebollar y Campos Francisco, 2015)

Hipótesis general

H_i : Existe relación significativa de la productividad educativa con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

H_o : No existe relación significativa de la productividad educativa con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

Tabla 49

Productividad Académica y Algoritmos de Aprendizaje Automático.

Productividad Académica			Algoritmos de Aprendizaje			Total	
			Automático				
			Insuficiente	Aprobado	Bueno		
Insuficiente		Recuento	12	0	0	12	
		% del total	13.3%	0.0%	0.0%	13.3%	
Aprobado		Recuento	0	64	0	64	
		% del total	0.0%	71.1%	0.0%	71.1%	
Bueno		Recuento	0	0	14	14	
		% del total	0.0%	0.0%	15.6%	15.6%	
Total		Recuento	12	64	14	90	
		% del total	13.3%	71.1%	15.6%	100.0%	

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

El grado de relación existente entre las variables productividad educativa y los algoritmos de aprendizaje automático es 113.3% (12) Insuficiente, 71.1% (64) Aprobado y 15.6% (14) Bueno.

Tabla 50

Prueba no paramétrica. Correlaciones Rho de Spearman entre Productividad Académica y Algoritmos de Aprendizaje Automático.

		Productividad Académica		Algoritmos de Aprendizaje Automático
Rho de Spearman	Productividad Académica	Coeficiente de correlación	1.000	.940**
		Sig. (bilateral)	.	.000
		N	90	90
	Algoritmos de Aprendizaje Automático	Coeficiente de correlación	.940**	1.000
		Sig. (bilateral)	.000	.
		N	90	90

**. La correlación es significativa en el nivel 0,01 (bilateral).

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

El coeficiente de correlación de Spearman indica una correlación positiva muy alta, y la Rho de Spearman es 0,940. Además, dado que el nivel de significación es 0,000 < 0,05, es posible rechazar la hipótesis nula y aceptar la alternativa, lo que indica que las variables están relacionadas. Esto permite concluir que la productividad académica y los algoritmos de aprendizaje automático están significativamente correlacionados en la EPISI de la UNAM en 2023.

Hipótesis específicas

Hipótesis específica 1

H_i : Existe relación significativa en la dimensión aptitud con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

H_o : No existe relación significativa en la dimensión aptitud con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

Tabla 51*Aptitud y Algoritmos de Aprendizaje Automático.*

		Algoritmos de Aprendizaje Automático			Total
		Insuficiente	Aprobado	Bueno	
Aptitud	Insuficiente	Recuento	7	2	0
		% del total	7.8%	2.2%	0.0%
Aptitud	Aprobado	Recuento	5	44	3
		% del total	5.6%	48.9%	3.3%
Aptitud	Bueno	Recuento	0	18	11
		% del total	0.0%	20.0%	12.2%
Total		Recuento	12	64	14
		% del total	13.3%	71.1%	15.6%
					100.0%

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

El nivel de relación que existe entre Aptitud y los algoritmos de aprendizaje automático es 7.8% (7) Insuficiente, 48.9% (44) Aprobado y 12.2% (11) Bueno.

Tabla 52*Prueba no paramétrica. Correlaciones Rho de Spearman entre Aptitud y Algoritmos de Aprendizaje Automático.*

Rho	deAptitud	Coeficiente de correlación	Algoritmos de Aprendizaje Automático	
			Aptitud	Automático
Spearman		Sig. (bilateral)	.000	.801**
		N	90	90
		Algoritmos de Aprendizaje Automático	.801**	1.000
		Sig. (bilateral)	.000	.
		N	90	90

**. La correlación es significativa en el nivel 0,01 (bilateral).

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

Se acepta la hipótesis alternativa y se rechaza la hipótesis nula porque la Rho de Spearman es 0.801, lo que indica una alta correlación positiva por el coeficiente de correlación de Spearman, y porque el nivel de significancia es 0.000, que es menor a 0.05. Esto implica que los factores tienen una relación considerable, por lo que se concluye que en la EPISI de la UNAM en 2023, la aptitud está correlacionada significativamente con los métodos de aprendizaje automático.

Hipótesis específica 2

H_i : Existe relación significativa en la dimensión instrucción con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

H_o : No existe relación significativa en la dimensión instrucción con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

Tabla 53

Instrucción y Algoritmos de Aprendizaje Automático.

		Algoritmos de Aprendizaje Automático			Total
		Insuficiente	Aprobado	Bueno	
Instrucción	Insuficiente	Recuento	6	1	0
		% del total	6.7%	1.1%	0.0%
	Aprobado	Recuento	6	54	8
		% del total	6.7%	60.0%	8.9%
	Bueno	Recuento	0	9	6
		% del total	0.0%	10.0%	6.7%
Total		Recuento	12	64	14
		% del total	13.3%	71.1%	15.6%
					100.0%

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

El nivel de relación que existe entre Instrucción y los algoritmos de aprendizaje automático es 6.7% (6) Insuficiente, 60% (54) Aprobado y 8.9% (8) Bueno.

Tabla 54

Prueba no paramétrica. Correlaciones Rho de Spearman entre Instrucción y Algoritmos de Aprendizaje Automático.

		Instrucción		Algoritmos de Aprendizaje Automático
Rho Spearman	de Instrucción	Coeficiente de correlación	1.000	.723**
		Sig. (bilateral)	.	.000
		N	90	90
Algoritmos de Aprendizaje Automático	de Instrucción	Coeficiente de correlación	.723**	1.000
		Sig. (bilateral)	.000	.
		N	90	90

**. La correlación es significativa en el nivel 0,01 (bilateral).

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

El valor del coeficiente de correlación de Spearman indica una fuerte asociación positiva, con un Rho de Spearman de 0,723. Además, se acepta la hipótesis alternativa y se rechaza la hipótesis nula porque el nivel de significación es 0.000, que es menor que 0.05. Esto muestra que las variables tienen una asociación significativa, lo que indica que en la EPISI de la UNAM en 2023, la instrucción tiene una relación significativa con los algoritmos de aprendizaje automático.

Hipótesis específica 3

H_i : Existe relación significativa en la dimensión medio ambiente con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

H_o : No existe relación significativa en la dimensión medio ambiente con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

Tabla 55

Medio ambiente y algoritmos de aprendizaje automático.

Algoritmos de Aprendizaje Automático			Total
Insuficiente	Aprobado	Bueno	

	Insuficiente	Recuento	7	8	0	15
		% del total	7.8%	8.9%	0.0%	16.7%
Medio	Aprobado	Recuento	5	53	4	62
Ambiente		% del total	5.6%	58.9%	4.4%	68.9%
	Bueno	Recuento	0	3	10	13
		% del total	0.0%	3.3%	11.1%	14.4%
Total		Recuento	12	64	14	90
		% del total	13.3%	71.1%	15.6%	100.0
						%

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

El nivel de relación que existe entre Medio ambiente y los algoritmos de aprendizaje automático es 7.8% (7) Insuficiente, 58.9% (53) Aprobado y 11.1% (10) Bueno.

Tabla 56

Prueba no paramétrica. correlaciones rho de Spearman entre medio ambiente y algoritmos de aprendizaje automático.

			Algoritmos de
		Medio	Aprendizaje
		Ambiente	Automático
Medio	Coeficiente de correlación	1.000	.626**
Ambiente	Sig. (bilateral)	.	.000
Rho de	N	90	90
Spearman	Algoritmos de	Coeficiente de correlación	.626**
	Aprendizaje	Sig. (bilateral)	.000
	Automático	N	90
			90

**. La correlación es significativa en el nivel 0,01 (bilateral).

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

La correlación moderadamente positiva entre las variables viene indicada por el coeficiente de correlación de Spearman (Rho), que se sitúa en 0,626. Además, dado que el nivel de significancia es de 0.000, es decir, menor a 0.05, se acepta la hipótesis alternativa y se rechaza

la hipótesis nula. Esto indica que, en el EPISI de la UNAM en 2023, habrá una interacción sustancial entre el entorno y los algoritmos de aprendizaje automático.

Hipótesis específica 4

H_i : Existe relación significativa en la dimensión aprendizaje con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

H_o : No existe relación significativa en la dimensión aprendizaje con los algoritmos de aprendizaje automático en estudiantes EPISI de UNAM, 2023.

Tabla 57

Aprendizaje y Algoritmos de Aprendizaje Automático.

		Algoritmos de Aprendizaje Automático			
		Insuficiente	Aprobado	Bueno	Total
Aprendizaje	Insuficiente	Recuento	12	0	0
		% del total	13.3%	0.0%	0.0%
	Aprobado	Recuento	0	64	0
		% del total	0.0%	71.1%	0.0%
Total	Bueno	Recuento	0	0	14
		% del total	0.0%	0.0%	15.6%
		Recuento	12	64	14
		% del total	13.3%	71.1%	15.6%
					90
					100.0%

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

El nivel de relación que existe entre aprendizaje y los algoritmos de aprendizaje automático es 13,3% (12) Insuficiente, 71,1% (64) Aprobado y 15,6% (14) Bueno.

Tabla 58

Aprendizaje y Algoritmos de Aprendizaje Automático.

Rho de	Aprendizaje	Coeficiente de correlación	Algoritmos de
Spearman		Sig. (bilateral)	Aprendizaje
		.	Automático
		.000	

	N	90	90
Algoritmos	deCoeficiente de correlación	.811**	1.000
Aprendizaje	Sig. (bilateral)	.000	.
Automático	N	90	90

**. La correlación es significativa en el nivel 0,01 (bilateral).

Nota: Elaboración Propia con Software IBM SPSS versión 26

Interpretación:

Con un coeficiente de correlación de Spearman (Rho) de 0,811, las variables muestran una fuerte asociación positiva entre sí. Además, dado que el nivel de significación es de 0.000, es decir, menor a 0.05, se acepta la hipótesis alternativa y se rechaza la hipótesis nula. Esto indica que, en el EPISI de la UNAM en 2023, los algoritmos de aprendizaje y aprendizaje automático tendrán una relación sustancial.

Discusión de resultados

En la actualidad, la educación superior se enfrenta a múltiples desafíos, entre ellos, la necesidad de mejorar la productividad educativa y la calidad de la formación de los estudiantes. En este sentido, la implementación de algoritmos de aprendizaje automático (AA) ha sido propuesta como una solución para optimizar el proceso de enseñanza y aprendizaje en la Escuela Profesional de Ingeniería de Sistemas e Informática de la Universidad Nacional de Moquegua. En este estudio, se evaluó la efectividad de la implementación de AA en la productividad educativa de la escuela, es por ello que la presente investigación consiste en determinar el nivel de relación entre la productividad educativa y los algoritmos de aprendizaje automático en la Universidad Nacional de Moquegua, 2023; con la prueba no paramétrica Rho de Spearman se descubrió un valor inferior a 0,05, es decir, un nivel de significación de 0,000. Esto sugiere que las variables tienen una asociación positiva muy fuerte entre sí. Esto sugiere que las variables tienen una asociación positiva muy fuerte entre sí. Por ejemplo, según los datos de 90 estudiantes evaluados en el EPISI de la UNAM, es probable que los elementos de aptitud, entorno e instrucción del constructo de productividad educativa estén significativamente conectados. en donde el 7.8% representado por 7 encuestados estableció insuficiente, el 48.9% representado por 44 encuestados estableció aprobado y el 12.2% representado por 11 encuestados estableció bueno, frente a ello se rechazó la hipótesis nula y aceptando la hipótesis planteada en la investigación referente a la existencia relacional entre la productividad educativa y los algoritmos de aprendizaje automático en EPISI de UNAM, 2023.

Los resultados mencionados confirman la investigación realizada por Parhizkar et al., (2023), denominada “Predicción del desempeño de los estudiantes utilizando algoritmos de clasificación de minería de datos: evaluación de la generalización de modelos desde el aspecto geográfico” Irán, en donde mostró un correlación positiva alta debido a que los algoritmos de aprendizaje automático Random forest y redes neuronales convolucionales (CNN) mostraron mejores rendimientos con un promedio de precisión y una puntuación F de 73,5 y 68,5, respectivamente.

La presente investigación corrobora el estudio "Algoritmos de aprendizaje automático para la predicción del rendimiento académico" de Morales Hernández et al. (2022) realizado en escuelas del estado mexicano de Tlaxcala, en donde se desarrollaron dos clasificadores de AA: el modelo de gradient boosting (GB) y la red neuronal multicapa (también conocida como perceptrón multicapa o MLP, por sus siglas en inglés). El objetivo fue predecir el nivel de productividad académica en las áreas de matemáticas y español. Los resultados demostraron que el clasificador MLP superó al modelo GB en términos de precisión de clasificación general (PG) para la asignatura de español, alcanzando un 70,1% en 2008 y un 61,1% en 2011. Sin embargo, el modelo GB obtuvo mejores resultados en la asignatura de matemáticas, con una PG del 68,8% en 2008 y del 63,5% en 2011. Estos resultados implican que existe una correlación significativa entre el nivel de rendimiento académico en matemáticas y el rendimiento en español.

Asimismo corrobora la investigación realizada por Yağcı (2022), en su modelo de estudio denominado Minería de datos educativos: predicción de la productividad académica de los estudiantes de una universidad estatal turca mediante algoritmos de aprendizaje automático, en donde propone predecir calificaciones de los exámenes finales de los estudiantes de pregrado, en donde referencia las calificaciones de las evaluaciones parciales para dicho estudio, asimismo utiliza algoritmos ML Random Forest, Vecinos más Cercanos, Regresión Logística, Naive Bayes y algoritmos de k-vecino más cercano para dicha investigación, cuyo resultado del modelo propuesto logró una precisión de clasificación del 70% al 75% de relación efectiva positiva.

También lo confirma la investigación realizada por Gismondi (2021) titulado “Modelo predictivo basado en machine learning como soporte para el seguimiento académico del estudiante universitario”, cuya finalidad fue mejorar los resultados en la educación universitaria, proponiendo aplicar la inteligencia artificial, machine learning y Deep learning a través de una red neuronal de seis capas con un 98.97% de precisión en el entrenamiento y

81,73 de precisión en el conjunto de prueba, estableciendo una relación efectiva positiva muy alta.

De la misma manera el estudio realizado por Quiñones y Quiñones (2020) "Rendimiento académico mediante minería de datos" consistió en utilizar técnicas de minería de datos para predecir el rendimiento académico de los alumnos matriculados en la carrera de Ingeniería en Industrias Alimentarias de la Universidad Nacional de Jaén (UNJ). Las oficinas de la universidad y un fichero proporcionaron acceso a la base de datos. CRISP-DM fue la metodología empleada. Los tres algoritmos de categorización del software Weka produjeron predicciones con una fiabilidad superior al 83%.

Conclusiones

1. Conforme al objetivo general en determinar el nivel de relación entre la productividad educativa y los algoritmos de aprendizaje automático, se determinó estadísticamente que existe una correlación positiva muy alta, debido al valor del coeficiente de correlación de Spearman que fue de 0,940 y conforme al baremo de significancia del valor hallado; Por tanto, se destaca que los algoritmos de aprendizaje automático (árboles de decisión, random fores y naive bayes) demostraron un alto grado de precisión en la predicción de la productividad educativa respaldado por el Rho de Spearman.
2. En cuanto al objetivo específico referente al nivel de relación entre la dimensión aptitud y los algoritmos de aprendizaje automático, se determinó estadísticamente que existe una correlación positiva alta debido al valor del coeficiente de correlación de Spearman que fue de 0,801 y el baremo de significancia del valor hallado.
3. En relación al objetivo específico del nivel de relación entre la dimensión instrucción y los algoritmos de aprendizaje automático, se estableció estadísticamente una correlación positiva alta debido al valor del coeficiente de correlación de Spearman que fue de 0,723 y el baremo de significancia del valor hallado.
4. En cuanto al objetivo específico concerniente al nivel de relación entre la dimensión medio ambiente y los algoritmos de aprendizaje automático, se especificó estadísticamente una correlación positiva moderada debido al valor del coeficiente de correlación de Spearman que fue de 0,626 y el baremo de significancia del valor hallado.
5. Respecto al objetivo específico del nivel de relación entre la dimensión aprendizaje y los algoritmos de aprendizaje automático, se analizó estadísticamente en donde se determinó el coeficiente de correlación de Spearman en 0,811 y de acuerdo al baremo de significancia se estableció una correlación positiva alta.

Recomendaciones

1. La recomendación en el ámbito general recae en promover la implementación y uso de algoritmos de aprendizaje automático en el ámbito educativo de EPISI de UNAM, con el objetivo de mejorar la productividad educativa, debido a la alta correlación positiva existente entre dichas variables. Además, recomendar a la vice presidencia académica, decano de ingeniería, jefe de departamento y dirección de EPISI de UNAM brindar el apoyo correspondiente en la asignación de recursos y capacitaciones tanto a estudiantes, docentes y personal involucrado fortaleciendo de esta forma habilidades en el uso y comprensión de los algoritmos de aprendizaje automático (AAA), con la finalidad de lograr mejores niveles de confianza en los AAA, integrar a los sistemas automatizados existentes para una mejor gestión educativa.
2. Con referencia a la dimensión aptitud y los algoritmos de aprendizaje automático, se encontró una correlación positiva alta, por tanto, se recomienda continuar con el fortalecimiento de los datos a fin de mejorar el rendimiento predictivo de los AAA, esto significa incrementar la data historia personalizada, para ello se sugiere a los directivos y autoridades mencionados asignar recursos y capacitaciones a EPISI basado en especialización en inteligencia artificial y Big Data a fin de lograr establecer estrategias y políticas de almacenamiento de datos del modelo inteligente en los servidores de UNAM, para una mejor gestión académica.
3. Respecto a la dimensión instrucción y los algoritmos de aprendizaje automático se obtuvo una correlación alta para lo cual también recomienda ampliar los datos históricos con la finalidad de mejorar las predicciones de los AAA para ello se sugiere a los directivos y autoridades mencionados asignar recursos y capacitaciones a EPISI basado en especialización en inteligencia artificial y Big Data a fin de lograr establecer estrategias y políticas de almacenamiento de datos del modelo inteligente en los servidores de UNAM, para una mejor gestión académica.
4. Respecto a la dimensión medio ambiente y los algoritmos de aprendizaje automático se obtuvo una correlación positiva moderada para lo cual se recomienda mejorar la ampliación de los datos históricos a fin de mejorar las predicciones de los algoritmos de aprendizaje automático para ello se sugiere a los directivos y autoridades mencionados asignar recursos y capacitaciones en Inteligencia artificial y Big Data a fin de establecer estrategias de almacenamiento de datos en los servidores de UNAM, para una mejor gestión académica.

5. Respecto a la dimensión aprendizaje y los algoritmos de aprendizaje automático se obtuvo una correlación positiva alta para lo cual se recomienda mejorar la ampliación de los datos históricos a fin de mejorar las predicciones de los algoritmos de aprendizaje automático para ello se sugiere a los directivos y autoridades mencionados asignar recursos y capacitaciones en Inteligencia artificial y Big Data a fin de establecer estrategias de almacenamiento de datos en los servidores de UNAM, para una mejor gestión académica.

Referencias

- Arias González, J. L. (2021). *Diseño y metodología de la investigación*. Enfoques Consulting E.I.R.L. https://apps.utel.edu.mx/recursos/files/r161r/w26022w/Arias_S2.pdf
- Ghasemi, A., y Zahediasl, S. (2012). Normality tests for statistical analysis: A guide for non-statisticians. *International Journal of Endocrinology and Metabolism*, 10(2), 486–489. <https://doi.org/10.5812/ijem.3505>
- Quiñones, L. y Quiñones, Y. L. (2020). Rendimiento académico empleando minería de datos. *Espacios*, 41(44), 277–285. <https://doi.org/10.48082/espacios-a20v41n44p17>
- Martínez Rebollar, A. y Campos Francisco, W. (2015). The Correlation Among Social Interaction Activities Registered Through New Technologies and Elderly's Social Isolation Level. *Revista Mexicana de Ingeniería Biomédica*, 36(3), 177–188. <https://doi.org/10.17488/RMIB.36.3.4>
- Mishra, P., Pandey, C. M., Singh, U., Gupta, A., Sahu, C., & Keshri, A. (2019). Application of Student's t-test, analysis of variance, and covariance in research. *Annals of Cardiac Anaesthesia*, 22(4), 407–411. https://doi.org/10.4103/aca.ACA_94_19
- Morales Hernández, M. Á. y González Camacho, J. M. y Robles Vásquez, H. y Del Valle Paniagua, D. H. y Durán Moreno, J. R. (2022). Algoritmos de aprendizaje automático para la predicción del logro académico. *RIDE Revista Iberoamericana Para La Investigación y El Desarrollo Educativo*, 12(24). <https://doi.org/10.23913/ride.v12i24.1180>
- Parhizkar, A. y Tejeddin, G. y Khatibi, T. (2023). Student performance prediction using datamining classification algorithms: Evaluating generalizability of models from geographical aspect. *Education and Information Technologies*
- Yağcı, M. (2022). Educational data mining: prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 9(1), 11. <https://doi.org/10.1186/s40561-022-00192-z>

Referencias generales.

- Abid, N. y Ali, R. y Akhter, M. (2021). Exploring gender-based difference towards academic enablers scales among secondary school students of Pakistan. *Psychology in the Schools*, 58(7), 1380–1398. <https://doi.org/10.1002/pits.22538>
- Ahmed Khan, Z. y Adnan, J. y Adnan Raza, S. (2023). *Cognitive Learning Theory and Development: Higher Education Case Study*. <https://doi.org/10.5772/intechopen.110629>
- Al-Ababneh M. (2020). Linking Ontology, Epistemology and Research Methodology. *Science & Philosophy*.
- Al-Ababneh, M. M. (2020). Linking Ontology, Epistemology and Research Methodology. *Science & Philosophy*, 75–91.
- Al-Ani, O. y Das, S. (2022). Reinforcement Learning: Theory and Applications in hems. *Mathematics & computer science, Artificial Intelligence & Robotics* .
- Alban, J. y Calero J. L. (2017). El rendimiento académico: aproximación necesaria a un problema pedagógico actual. *Revista Conrado*.
- Alkin, M. C. y King, J. A. (2016). The Historical Development of Evaluation Use. *American Journal of Evaluation*, 37(4), 568–579. <https://doi.org/10.1177/1098214016665164>
- Andrade, M. S. y Freitas, J. C. de. (2023). Analysis of Performance Metrics on the Conjunction of Intrusions in IEEE 802.11 Networks with Machine Learning at Hospital N.S.C. In *connecting expertise multidisciplinary development for the future*. Seven Editora. <https://doi.org/10.56238/Connexpemultidisdevolpfut-116>
- Anyoha, R. (2017). *La historia de la inteligencia artificial - Ciencia en las noticias*. <https://sitn.hms.harvard.edu/flash/2017/history-artificial-intelligence/>
- Auffarth, B. (2021). *Machine Learning for Time-Series with Python*. https://books.google.com.pe/books?id=a7tLEAAAQBAJ&pg=PA99&lpg=PA99&dq=author+of+nearest+neighbors+algorithm++Evelyn+Fix+y+Joseph+Hodges&source=bl&ots=D19ck8Ao7W&sig=ACfU3UovGNfCvt_kI7tpjETbQgZOOGuyAA&hl=es&sa=X&ved=2ahUKEwiTt474wcj4AhVVAdQKHUSABNUQ6AF6B AgoEAM#v=onepage&q=author%20of%20nearest%20neighbors%20algorithm%20%20Evelyn%20Fix%20y%20Joseph%20Hodges&f=false
- Avila, Á. (2022). *La motivación en los estudiantes: 3 Claves para aumentarla*. <https://www.enriccorberainstitute.com/blog/motivacion-en-los-estudiantes/>
- Bagnato Juan Ignacio. (2020). *Aprende Machine Learning en Español Teoría + Práctica Python*. 1–184.

- Bernal Torres, C. A. (2016). *Metodología de la investigación: Administración, economía, humanidades y ciencias sociales* (4^a ed.). Pearson Educación. <https://drive.google.com/file/d/1-3wqx7vGGCn6O4FxMPkzKwl5E4tByYXX/view?pli=1>
- Barus, S. P. (2021). Implementation of Naïve Bayes Classifier-based Machine Learning to Predict and Classify New Students at Matana University. *Journal of Physics: Conference Series*, 1842(1), 012008. <https://doi.org/10.1088/1742-6596/1842/1/012008>
- BBVA. (2019). “Machine learning”: ¿qué es y cómo funciona?
- Biblioteca Nacional de Chile. (2021). *La Filosofía Positivista*. <http://www.memoriachilena.gob.cl/602/w3-article-93966.html>
- Brew, E. A. y Nketiah, B. y Koranteng, R. (2021). A Literature Review of Academic Performance, an Insight into Factors and their Influences on Academic Outcomes of Students at Senior High Schools. *OALib*, 08(06), 1–14. <https://doi.org/10.4236/oalib.1107423>
- Brownlee, J. (2018). *Machine Learning Algorithms From Scratch* (v.1.8, Ed.).
- Carroll, J. B. (1989). The Carroll Model: A 25-Year Retrospective and Prospective View. *Educational Researcher*, 18(1), 26. <https://doi.org/10.2307/1176007>
- Carrasco Díaz, S. (2006). *Metodología de la investigación científica: pautas metodológicas para diseñar y elaborar el proyecto de investigación*. San Marcos. <https://drive.google.com/file/d/1GTWMTyAZDmzEohJbUKSxsR-QJWsYugBV/view>
- Caselli Gismondi, H. E. (2021). *Modelo predictivo basado en machine learning como soporte para el seguimiento académico del estudiante universitario* [Universidad Nacional del Santa]. <http://repositorio.uns.edu.pe/bitstream/handle/UNS/3804/52337.pdf?sequence=5&isAllowed=y>
- Caselli Gismondi, H. E. y Urrelo Huiman, L. V. (2021). Características para un modelo de predicción de la deserción académica universitaria. Caso Universidad Nacional de Santa. *Llamkasun*, 2(4), 02–22. <https://doi.org/10.47797/llamkasun.v2i4.61>
- Castañon, E. R. (2023). *¿Qué es un ambiente de aprendizaje según autores?* <https://www.centrobanamex.com.mx/que-es-un-ambiente-de-aprendizaje-segun-autores/>
- Castrillón, O. D. y Sarache, W. y Ruiz-Herrera, S. (2020). Predicción del rendimiento académico por medio de técnicas de inteligencia artificial. *Formación Universitaria*, 13(1), 93–102. <https://doi.org/10.4067/S0718-50062020000100093>
- Cecilia, O. N. y Bernedette, C.-U. y Emmanuel, A. E. y Hope, A. N. (2020). Enhancing students academic performance in Chemistry by using kitchen resources in Ikom, Calabar. *Educational Research and Reviews*, 15(1), 19–26. <https://doi.org/10.5897/ERR2019.3810>

Charbuty, B. y Abdulazeez, A. (2021). Classification Based on Decision Tree Algorithm for Machine Learning. *Journal of Applied Science and Technology Trends*, 2(01), 20–28. <https://doi.org/10.38094/jastt20165>

Contreras, L. E. y Fuentes, H. J. y Rodríguez, J. I. (2020). Predicción del rendimiento académico como indicador de éxito/fracaso de los estudiantes de ingeniería, mediante aprendizaje automático. *Formación Universitaria*, 13(5), 233–246. <https://doi.org/10.4067/S0718-50062020000500233>

Correia, M. I. T. D. (2023). Ethics in research. *Clinical Nutrition Open Science*, 47, 121–130. <https://doi.org/10.1016/j.nutos.2022.12.010>

de Oliveira Chagas, E. T. (2019). Deep Learning and its applications today. *Revista Científica Multidisciplinar Núcleo Do Conhecimento*, 04(05), 05–26. <https://doi.org/10.32749/nucleodoconhecimento.com.br/business-administration/deep-learning-2>

Díaz-Landa, B. y Meleán-Romero, R. y Marín-Rodriguez, W. (2021). Rendimiento académico de estudiantes en Educación Superior: predicciones de factores influyentes a partir de árboles de decisión. *Telos Revista de Estudios Interdisciplinarios En Ciencias Sociales*, 23(3), 616–639. <https://doi.org/10.36390/telos233.08>

Dong, Y. y Hou, J. y Zhang, N. y Zhang, M. (2020). Research on How Human Intelligence, Consciousness, and Cognitive Computing Affect the Development of Artificial Intelligence. *Complexity*, 2020, 1–10. <https://doi.org/10.1155/2020/1680845>

Edgard, T. W. y Manz, D. O. (2017). *Research Methods for Cyber Security* (1ra ed.). Elsevier Inc.

Escobar-Pérez, J. y Cuervo-Martínez, Á. (2008). Validez de contenido y juicio de expertos: una aproximación a su utilización. *Avances En Medición*, 27–36. https://www.humanas.unal.edu.co/lab_psicometria/application/files/9416/0463/3548/Vol_6._Articulo3_Juicio_de_expertos_27-36.pdf

Esteso, A. y Peidro, D. y Mula, J. y Díaz-Madroñero, M. (2022). Reinforcement learning applied to production planning and control. *International Journal of Production Research*, 1–18. <https://doi.org/10.1080/00207543.2022.2104180>

Fernandes, E. y Holanda, M. y Victorino, M. y Borges, V. y Carvalho, R. y Erven, G. van. (2019). Educational data mining: Predictive analysis of academic performance of public school students in the capital of Brazil. *Journal of Business Research*, 94, 335–343. <https://doi.org/10.1016/j.jbusres.2018.02.012>

Fernández-Mellizo, M. y Constante-Amores, A. (2020). Determinantes del rendimiento académico de los estudiantes de nuevo acceso a la Universidad Complutense de Madrid. *Revista de Educación*, 213–240.

Figueroa-Abarzúa, C. y Meza-Vásquez, S. y Estrada-Lagos, R. (2022). Desarrollo de capacidad argumentativa en estudiantes universitarios, mediante uso del debate como estrategia didáctica. *South Florida Journal of Development*, 3(6), 6328–6346. <https://doi.org/10.46932/sfjdv3n6-001>

Fu, M. y Zhang, C. y Hu, C. y Wu, T. y Dong, J. y Zhu, L. (2023). Achieving Verifiable Decision Tree Prediction on Hybrid Blockchains. *Entropy*, 25(7), 1058. <https://doi.org/10.3390/e25071058>

Géron, A. (2019). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow Concepts, Tools, and Techniques to Build Intelligent System* (Ni. Tache, Ed.; 2nd ed.).

Ghasemi, A. y Zahediasl, S. (2012). Normality Tests for Statistical Analysis: A Guide for Non-Statisticians. *International Journal of Endocrinology and Metabolism*, 10(2), 486–489. <https://doi.org/10.5812/ijem.3505>

Gogus, A. (2012). Bloom's Taxonomy of Learning Objectives. In *Encyclopedia of the Sciences of Learning* (pp. 469–473). Springer US. https://doi.org/10.1007/978-1-4419-1428-6_141

Gopani, A. (2022). *La historia de los algoritmos de aprendizaje automático*. <https://analyticsindiamag.com/the-history-of-machine-learning-algorithms/>

Grasso Imig, P. (2020). *Rendimiento académico: un recorrido conceptual que aproxima a una definición unificada para el ámbito superior*. https://fhmdp.edu.ar/revistas/index.php/r_educ/article/view/4165

Guill, K. y Ömeroğulları, M. y Köller, O. (2021). Intensity and content of private tutoring lessons during German secondary schooling: effects on students' grades and test achievement. *European Journal of Psychology of Education*. <https://doi.org/10.1007/s10212-021-00581-x>

Hajjej, F. y Alohalí, M. A. y Badr, M. y Rahman, M. A. (2022). A Comparison of Decision Tree Algorithms in the Assessment of Biomedical Data. *BioMed Research International*, 2022, 1–9. <https://doi.org/10.1155/2022/9449497>

Hathcoat, J. D. y Meixner, C. y Nicholas, M. C. (2019). Ontology and Epistemology. In *Handbook of Research Methods in Health Social Sciences* (pp. 99–116). Springer Singapore. https://doi.org/10.1007/978-981-10-5251-4_56

Hawkins, C. y Bailey, L. E. (2020). A New Data Landscape: IR's Role in Academic Analytics. *New Directions for Institutional Research*, 2020(185–186), 87–103. <https://doi.org/10.1002/ir.20331>

Hernández Sampieri, R. y Fernández Collado, C. y Baptista Lucio, M. del P. (2014). *Metodología de la investigación*. Mc Graw Hill.

Hernandez-Manxilla J.M. (2011). El racionalismo cartesiano y su particular conquista de la subjetividad en el mundo moderno. *FRENIA*.

Hernández-Sampieri R. (2018). *Metodología de la investigación* (1ra Ed.).

Herrera Acosta, C. E. y Sánchez Pinedo, L. D. (2019). METODOLOGÍA DE APRENDIZAJE Y SISTEMA DE EVALUACIÓN PARA ALCANZAR RESULTADOS EN EL PROCESO EDUCATIVO . *Evaluación de La Calidad Educativa*. <https://www.igobernanza.org/index.php/IGOB/Contacto>

Hiller, J. (2016). *Epistemological foundations of objectivist and interpretivist research* (pp. 99–127).

IBM Cloud Education. (2020). *Machine Learning This introduction to machine learning provides an overview of its history, important definitions, applications, and concerns within businesses today*. <https://www.ibm.com/cloud/learn/machine-learning>

Ilić, M. y Srdjević, Z. y Srdjević, B. (2022). Water quality prediction based on Naïve Bayes algorithm. *Water Science and Technology*, 85(4), 1027–1039. <https://doi.org/10.2166/wst.2022.006>

Janiesch, C. y Zschech, P. y Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>

Jiang, T. y Gradus, J. L. y Rosellini, A. J. (2020). Supervised Machine Learning: A Brief Primer. *Behavior Therapy*, 51(5), 675–687. <https://doi.org/10.1016/j.beth.2020.05.002>

Jin, S. y Fang, G. y Cheung, K. C. y Sit, P. S. (2022). Factors associated with academic resilience in disadvantaged students: An analysis based on the PISA 2015 B-S-J-G (China) sample. *Frontiers in Psychology*, 13. <https://doi.org/10.3389/fpsyg.2022.846466>

Jovel, J. y Greiner, R. (2021). An Introduction to Machine Learning Approaches for Biomedical Research. *Frontiers in Medicine*, 8. <https://doi.org/10.3389/fmed.2021.771607>

Kaun, C. y Jhanjhi, N. Z. y Goh, W. W. y Sukumaran, S. (2021). Implementation of Decision Tree Algorithm to Classify Knowledge Quality in a Knowledge Intensive System. *MATEC Web of Conferences*, 335, 04002. <https://doi.org/10.1051/matecconf/202133504002>

Kaur Arora, S. (2022). *Top Steps To Learn Naïve Bayes Algorithm*. <https://hackr.io/blog/top-steps-to-learn-naive-bayes-algorithm>

KOÇOĞLU, F. Ö. (2022). Research on the success of unsupervised learning algorithms in indoor location prediction. *International Advanced Researches and Engineering Journal*, 6(2 (under construction)), 148–153. <https://doi.org/10.35860/iarej.1096573>

Krathwohl, D. R. (2002). A Revision of Bloom's Taxonomy: An Overview. In *Theory Into Practice* (Vol. 41, Issue 4). https://doi.org/10.1207/s15430421tip4104_2

Lampropoulos, A. S. y Tsihrintzis, G. A. (2015). *Machine Learning Paradigms* (Vol. 92). Springer International Publishing. <https://doi.org/10.1007/978-3-319-19135-5>

Laplante, P. A. (2001). *Dictionary of computer science, engineering, and technology*. www.crcpress.com

Lee, J. y Warner, E. y Shaikhouni, S. y Bitzer, M. y Kretzler, M. y Gipson, D. y Pennathur, S. y Bellovich, K. y Bhat, Z. y Gadegbeku, C. y Massengill, S. y Perumal, K. y Saha, J. y Yang, Y. y Luo, J. y Zhang, X. y Mariani, L. y Hodgin, J. B. y Rao, A. (2022). Unsupervised machine learning for identifying important visual features through bag-of-words using histopathology data from chronic kidney disease. *Scientific Reports*, 12(1), 4832. <https://doi.org/10.1038/s41598-022-08974-8>

Mahesh, B. (2018). Machine Learning Algorithms - A Review. *International Journal of Science and Research*, 381–386.

Maina, J. J. y Zakari, A. T. y Alkali, I. A. y Salisu, R. A. (2021). Academic success predictors for architecture students at Kano University of Science and Technology, Wudil, Kano State, Nigeria. *Bayero Journal of Pure and Applied Sciences*, 13(2), 125–133. <https://doi.org/10.4314/bajopas.v13i2.17>

Mandal, L. y Jana, N. D. (2019). A Comparative Study of Naive Bayes and k-NN Algorithm for Multi-class Drug Molecule Classification. *2019 IEEE 16th India Council International Conference (INDICON)*, 1–4. <https://doi.org/10.1109/INDICON47234.2019.9029095>

Martínez Rebollar, A. y Campos Francisco, W. (2015). The Correlation Among Social Interaction Activities Registered Through New Technologies and Elderly's Social Isolation Level. *Revista Mexicana de Ingeniería Biomédica*, 36(3), 177–188. <https://doi.org/10.17488/RMIB.36.3.4>

Mazana, M. Y. y Montero, C. S. y Casmir, R. O. (2019). Investigating Students' Attitude towards Learning Mathematics. *International Electronic Journal of Mathematics Education*, 14(1). <https://doi.org/10.29333/iejme/3997>

McDaniel, M. y Storey, V. C. (2020). Evaluating Domain Ontologies. *ACM Computing Surveys*, 52(4), 1–44. <https://doi.org/10.1145/3329124>

McGinnis, D. (2020). *¿Qué es la Cuarta Revolución Industrial? | Fuerza de ventas.* <https://www.salesforce.com/blog/what-is-the-fourth-industrial-revolution-4ir/>

Medina N. y Fereira J. y Marzol R. (2018). Factores personales que inciden en el bajo rendimiento académico de los estudiantes de geometría. *Revista de Estudios Interdisciplinarios En Ciencias Sociales*.

Menacho Chiok, C. H. (2017). Predicción del rendimiento académico aplicando técnicas de minería de datos. *Anales Científicos*, 78(1), 26. <https://doi.org/10.21704/ac.v78i1.811>

Mienye, I. D. y Sun, Y. y Wang, Z. (2019). Prediction performance of improved decision tree-based algorithms: a review. *Procedia Manufacturing*, 35, 698–703. <https://doi.org/10.1016/j.promfg.2019.06.011>

Mishra, P. y Pandey, C. y Singh, U. y Gupta, A. y Sahu, C. y Keshri, A. (2019). Descriptive statistics and normality tests for statistical data. *Annals of Cardiac Anaesthesia*, 22(1), 67. https://doi.org/10.4103/aca.ACA_157_18

Misra, S. y Li, H. (2020). Noninvasive fracture characterization based on the classification of sonic wave travel times. In *Machine Learning for Subsurface Characterization* (pp. 243–287). Elsevier. <https://doi.org/10.1016/B978-0-12-817736-5.00009-0>

Mohammed, M. y Khan, M. B. y Mohammed Bashier, E. B. (2017). *Machine Learning Algorithms and Applications*.

Morales Hernández, M. Á. y González Camacho, J. M. y Robles Vásquez, H. y Del Valle Paniagua, D. H. y Durán Moreno, J. R. (2022). Algoritmos de aprendizaje automático para la predicción del logro académico. *RIDE Revista Iberoamericana Para La Investigación y El Desarrollo Educativo*, 12(24). <https://doi.org/10.23913/ride.v12i24.1180>

Münch, M. y Raab, C. y Biehl, M. y Schleif, F.-M. (2020). Data-Driven Supervised Learning for Life Science Data. *Frontiers in Applied Mathematics and Statistics*, 6. <https://doi.org/10.3389/fams.2020.553000>

Nedeva, V. y Pehlivanova, T. (2021). Students' Performance Analyses Using Machine Learning Algorithms in WEKA. *IOP Conference Series: Materials Science and Engineering*, 1031(1), 012061. <https://doi.org/10.1088/1757-899X/1031/1/012061>

Ong, A. K. S. y Chueyindee, T. y Prasetyo, Y. T. y Nadlifatin, R. y Persada, S. F. y Gumasing, Ma. J. J. y German, J. D. y Robas, K. P. E. y Young, M. N. y Sitiwatethanasiri, T. (2022). Utilization of Random Forest and Deep Learning Neural Network for Predicting Factors Affecting Perceived Usability of a COVID-19 Contact Tracing Mobile Application in Thailand “ThaiChana.” *International Journal of Environmental Research and Public Health*, 19(10), 6111. <https://doi.org/10.3390/ijerph19106111>

Orlikowsld W. y Baroudi J. (1991). Studying Information Technology in Organimtions: Research Approaches and Assumptions. *Information Systems Research*.

Osisanwo, F. Y. y Akinsola, J. E. T. y Awodele, O. y Hinmikaiye, J. O. y Olakanmi, O. y Akinjobi, J. (2017). Supervised Machine Learning Algorithms: Classification and Comparison. *International Journal of Computer Trends and Technology*, 48(3), 128–138. <https://doi.org/10.14445/22312803/IJCTT-V48P126>

Oxford University. (2016). *A Dictionary of Computer Science*.

Padilla-Cuevas, J. y Reyes-Ortiz, J. A. y Bravo, M. (2021). Ontology-Based Context Event Representation, Reasoning, and Enhancing in Academic Environments. *Future Internet*, 13(6), 151. <https://doi.org/10.3390/fi13060151>

Palanichamy, K. (2019). Integrative Omic Analysis of Neuroblastoma. In *Computational Epigenetics and Diseases* (pp. 311–326). Elsevier. <https://doi.org/10.1016/B978-0-12-814513-5.00019-2>

Parhizkar, A. y Tejeddin, G. y Khatibi, T. (2023). Student performance prediction using datamining classification algorithms: Evaluating generalizability of models from geographical aspect. *Education and Information Technologies*, 28(11), 14167–14185. <https://doi.org/10.1007/s10639-022-11560-0>

Park, Y. S. y Konge, L. y Artino, A. R. (2020). The Positivism Paradigm of Research. *Academic Medicine*, 95(5), 690–694. <https://doi.org/10.1097/ACM.ooooooooooooo3093>

Parth Shukla. (2023). *Naive Bayes Algorithms: A Complete Guide for Beginners*. <https://www.analyticsvidhya.com/blog/2023/01/naive-bayes-algorithms-a-complete-guide-for-beginners/>

Pastor, M. (1997). *Deep Blue venció a Kasparov en un campo donde el hombre no tenía rival* | | ComputerWorld. Computer World. <https://www.computerworld.es/archive/deep-blue-vencio-a-kasparov-en-un-campo-donde-el-hombre-no-tenia-rival>

Peconcillo Jr, L. B. y D. Peteros, E. y O. Mamites, I. y T. Sanchez, D. y L. Tenerife, J. J. y L. Suson, R. (2020). Structuring Determinants to Level Up Students Performance. *International Journal of Education and Practice*, 8(4), 638–651. <https://doi.org/10.18488/journal.61.2020.84.638.651>

Pellegrino, E. y Jacques, C. y Beaufils, N. y Nanni, I. y Carlio, A. y Metellus, P. y Ouafik, L. (2021). Machine learning random forest for predicting oncosomatic variant NGS analysis. *Scientific Reports*, 11(1), 21820. <https://doi.org/10.1038/s41598-021-01253-y>

Pirneskoski, J. y Tamminen, J. y Kallonen, A. y Nurmi, J. y Kuisma, M. y Olkkola, K. T. y Hoppu, S. (2020). Random forest machine learning method outperforms prehospital National

Early Warning Score for predicting one-day mortality: A retrospective study. *Resuscitation Plus*, 4, 100046. <https://doi.org/10.1016/j.resplu.2020.100046>

Prabhakaran, S. (2018). *How Naive Bayes Algorithm Works?* Machine Learning. <https://www.machinelearningplus.com/predictive-modeling/how-naive-bayes-algorithm-works-with-example-and-full-code/>

Pugliese, R. y Regondi, S. y Marini, R. (2021). Machine learning-based approach: global trends, research directions, and regulatory standpoints. *Data Science and Management*, 4, 19–29. <https://doi.org/10.1016/j.dsm.2021.12.002>

Quiñones, L. y Quiñones, Y. L. (2020). Rendimiento académico empleando minería de datos. *Espacios*, 41(44), 277–285. <https://doi.org/10.48082/espacios-a20v41n44p17>

Ray, S. (2019). A Quick Review of Machine Learning Algorithms. *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*, 35–39. <https://doi.org/10.1109/COMITCon.2019.8862451>

Raynor, W. J. (1999). *The International Dictionary of Artificial Intelligence*.

Rigdon, J. C. (2016). *Dictionary of Computer and Internet Terms* (Microsoft Corporation, Ed.; 1st Edition). <http://www.wordsrus.info>

Roman, V. (2019). *Algoritmos Naive Bayes: Fundamentos e Implementación*. Ciencia de Datos. <https://medium.com/datos-y-ciencia/algoritmos-naive-bayes-fundamentos-e-implementaci%C3%B3n-4bcb24b307f>

Rosales Sánchez, E. M. y Rodríguez Ortega, P. G. y Romero Ariza, M. (2020). Conocimiento, demanda cognitiva y contextos en la evaluación de la alfabetización científica en PISA. *Revista Eureka Sobre Enseñanza y Divulgación de Las Ciencias*, 17(2), 1–22. https://doi.org/10.25267/Rev_Eureka_ensen_divulg_cienc.2020.v17.i2.2302

Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 19–27.

Russell, S. y Norvig, P. (2008). *Inteligencia Artificial Un Enfoque Moderno* (D. F. Aragón, Ed.; 2nd ed.).

Salatino, A. A. y Thanapalasingam, T. y Mannocci, A. y Birukou, A. y Osborne, F. y Motta, E. (2020). The Computer Science Ontology: A Comprehensive Automatically-Generated Taxonomy of Research Areas. *Data Intelligence*, 2(3), 379–416. https://doi.org/10.1162/dint_a_00055

Sarker, I. H. (2021a). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>

Sarker, I. H. (2021b). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>

Sauce, B. y Liebherr, M. y Judd, N. y Klingberg, T. (2022). The impact of digital media on children's intelligence while controlling for genetic differences in cognition and socioeconomic background. *Scientific Reports*, 12(1), 7720. <https://doi.org/10.1038/s41598-022-11341-2>

Saunders M. y Lewis, P. y Thornhill, A. (2019). *Research Methods for Business Students* (Pearson Education, Ed.; Eighth).

Saunders, M. N. K. y Lewis, P. y Thornhill, A. (2029). *Research Methods for Business Students* (8va ed.).

Schonlau, M. y Zou, R. Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal: Promoting Communications on Statistics and Stata*, 20(1), 3–29. <https://doi.org/10.1177/1536867X20909688>

Scriven, Mi. (1967). *The methodology of evaluation*.

Seel, N. M. (2012a). Bloom's Model of School Learning. In *Encyclopedia of the Sciences of Learning* (pp. 466–469). Springer US. https://doi.org/10.1007/978-1-4419-1428-6_979

Seel, N. M. (2012b). Carroll's Model of School Learning. In *Encyclopedia of the Sciences of Learning* (pp. 501–503). Springer US. https://doi.org/10.1007/978-1-4419-1428-6_980

Sepúlveda, A. y Minte, A. y Díaz-Levicoy, D. (2020). Caracterización de preguntas en libros de texto de Ciencias Naturales en Educación Primaria chilena. *Educação e Pesquisa*, 46. <https://doi.org/10.1590/s1678-4634202046224118>

Serumena D. y Utan F. y Poernomo M. (2021). The Effectiveness of Social Media as An Online Learning Pattern in Improving the 3 Domains of Student Intellectual Ability During the Pandemic (Covid-19). *Advances in Engineering Research*.

Sharma, N. y Sharma, R. y Jindal, N. (2021). Machine Learning and Deep Learning Applications-A Vision. *Global Transitions Proceedings*, 2(1), 24–28. <https://doi.org/10.1016/j.gltip.2021.01.004>

Simplilearn. (2022). *The Complete Guide to Machine Learning Steps*. <https://www.simplilearn.com/tutorials/machine-learning-tutorial/machine-learning-steps>

Singh, V. y Chen, S.-S. y Singhania, M. y Nanavati, B. y kar, A. kumar y Gupta, A. (2022). How are reinforcement learning and deep learning algorithms used for big data based decision making in financial industries—A review and research agenda. *International Journal of Information Management Data Insights*, 2(2), 100094. <https://doi.org/10.1016/j.ijimei.2022.100094>

Sivasubramaniam, S. y Dlabolová, D. H. y Kralikova, V. y Khan, Z. R. (2021). Assisting you to advance with ethics in research: an introduction to ethical governance and application procedures. *International Journal for Educational Integrity*, 17(1), 14. <https://doi.org/10.1007/s40979-021-00078-6>

Stern, M. y Arinze, C. y Perez, L. y Palmer, S. E. y Murugan, A. (2020). Supervised learning through physical changes in a mechanical system. *Proceedings of the National Academy of Sciences*, 117(26), 14843–14850. <https://doi.org/10.1073/pnas.2000807117>

Tai, M.-T. (2020). The impact of artificial intelligence on human society and bioethics. *Tzu Chi Medical Journal*, 32(4), 339. https://doi.org/10.4103/tcmj.tcmj_71_20

Tamayo y Tamayo, M. (2004). *El proceso de la investigación científica*. Limusa. https://www.academia.edu/29308889/Tamayo_Mario_El_Proceso_De_La_Investigacion_Cientifica_pdf

Tebani, A. y Bekri, S. (2020). High-throughput omics in the precision medicine ecosystem. In *Precision Medicine for Investigators, Practitioners and Providers* (pp. 19–31). Elsevier. <https://doi.org/10.1016/B978-0-12-819178-1.00003-4>

Torres-Malca, J. R. y Vera-Ponce, V. J. y Zuzunaga-Montoya, F. E. y Talavera, J. E. y De La Cruz-Vargas, J. A. (2022). Content validity by expert judgment of an instrument to measure knowledge, attitudes and practices about salt consumption in the peruvian population. *Revista de La Facultad de Medicina Humana*, 22(2), 273–279. <https://doi.org/10.25176/RFMH.v22i2.4768>

Triwiyanto T. y Suyanto y Prasojo L.D. y Wardana Y. (2020). Factors Affecting Educational Productivity at Private Elementary Schools in Indonesia. *Advances in Social Science, Education and Humanities Research*, 487, 318–323.

Universidad de Lehigh. (2013). *Historia de las Pruebas Estandarizadas*. <https://ed.lehigh.edu/news-events/news/history-standardized-testing>

Vadlamudi, P. S. y Gunasekaran, M. y Nagalakshmi, T. J. (2023). An Analysis of the Effectiveness of the Naive Bayes Algorithm and the Support Vector Machine for Detecting Fake News on Social Media. *2023 International Conference on Intelligent and Innovative Technologies in Computing, Electrical and Electronics (IITCEE)*, 726–731. <https://doi.org/10.1109/IITCEE57236.2023.10090978>

Vigo, R. y Zeigler, D. E. y Wimsatt, J. (2022). Uncharted Aspects of Human Intelligence in Knowledge-Based “Intelligent” Systems. *Philosophies*, 7(3), 46. <https://doi.org/10.3390/philosophies7030046>

- Villalba, F. (2018). Naive Bayes- clasificación bayesiano ingenuo. In *Aprendizaje supervisado en R*. <https://fervilber.github.io/Aprendizaje-supervisado-en-R/ingenuo.html>
- Vostroknutov, A. y Polonio, L. y Coricelli, G. (2018). The Role of Intelligence in Social Learning. *Scientific Reports*, 8(1), 6896. <https://doi.org/10.1038/s41598-018-25289-9>
- Walberg, H. J. (1984). *Improving the Productivity of America's Schools*.
- Wang, P. (2019). On Defining Artificial Intelligence. *Journal of Artificial General Intelligence*, 10(2), 1–37. <https://doi.org/10.2478/jagi-2019-0002>
- Xiang, X. y Foo, S. y Zang, H. (2021). Recent Advances in Deep Reinforcement Learning Applications for Solving Partially Observable Markov Decision Processes (POMDP) Problems Part 2—Applications in Transportation, Industries, Communications and Networking and More Topics. *Machine Learning and Knowledge Extraction*, 3(4), 863–878. <https://doi.org/10.3390/make3040043>
- Yağcı, M. (2022). Educational data mining: prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 9(1), 11. <https://doi.org/10.1186/s40561-022-00192-z>
- Yeturu, K. (2020). *Machine learning algorithms, applications, and practices in data science* (pp. 81–206). <https://doi.org/10.1016/bs.host.2020.01.002>
- Yıldız, M. y Börekci, C. (2020). Predicting Academic Achievement with Machine Learning Algorithms. *Journal of Educational Technology and Online Learning*. <https://doi.org/10.31681/jetol.773206>
- Zambrano Aranda, G. (2022). Análisis de la satisfacción con respecto a una maestría de una universidad de Lima desde la perspectiva de sus egresados. *Revista Educación y Sociedad*, 3(5), 9–22. <https://doi.org/10.53940/reys.v3i5.89>
- Zhao, W. (2022). Inspired, but not mimicking: a conversation between artificial intelligence and human intelligence. *National Science Review*, 9(6). <https://doi.org/10.1093/nsr/nwac068>
- Zheng, Y. (2019). Identification of microRNAs From Small RNA Sequencing Profiles. In *Computational Non-coding RNA Biology* (pp. 35–82). Elsevier. <https://doi.org/10.1016/B978-0-12-814365-0.00012-9>
- Žukauskas, P. y Vveinhardt, J. y Andriukaitienė, R. (2018). Philosophy and Paradigm of Scientific Research. In *Management Culture and Corporate Social Responsibility*. InTech. <https://doi.org/10.5772/intechopen.70628>