



Pronóstico de producción a través de un modelo matemático basado en regresión multivariada

Production forecast through a mathematical model based on multivariate regression

Previsão de produção através de modelo matemático baseado em regressão multivariada

Kleber Andrés Mora-Guevara ^I

kmorag2@unemi.edu.ec

<https://orcid.org/0000-0003-0768-0144>

Holguer Miguel Beltrán-Abreo ^{II}

holgerm.1294@outlook.com

<https://orcid.org/0000-0002-9105-6872>

Correspondencia: kmorag2@unemi.edu.ec

Ciencias de la Educación

Artículo de Investigación

* **Recibido:** 18 de agosto de 2024 * **Aceptado:** 05 de septiembre de 2024 * **Publicado:** 23 de octubre de 2024

I. Universidad Estatal de Milagro UNEMI, Milagro, Guayas, Ecuador.

II. Universidad Estatal de Milagro UNEMI, Milagro, Guayas, Ecuador.

Resumen

Este estudio examina la utilidad de los modelos matemáticos de regresión multivariada para predecir la producción. Estos modelos son esenciales en estadística, ya que analizan la relación entre varias variables independientes y una o más variables dependientes. Se destaca la importancia de las predicciones de producción, que ayudan a estimar la cantidad de bienes y servicios que una empresa puede generar en un período específico. Esto facilita una planificación adecuada y la toma de decisiones en producción, permitiendo gestionar los recursos de manera eficiente según la demanda del mercado. El objetivo se centró en proponer un modelo matemático adecuado que facilite la predicción ágil de la producción en una fábrica de barras de chocolate de 20 g, utilizando regresión multivariada. carácter cuantitativo, de tipo exploratoria y aplicada, tomando como punto de partida un estudio documental y una investigación de campo, la cual tuvo como finalidad diseñar un modelo matemático. Se concluye que, se identificaron variables clave en la producción, como la cantidad de producción planeada y las horas laborales planificadas, utilizando un modelo de regresión multivariable en SPSS, que permitió predecir la producción real con un 95.4% de significancia. Se recomienda que la microempresa recopile más datos y evalúe otras variables para mejorar el análisis, así como fomentar investigaciones en otras microempresas para equilibrar la oferta y demanda en el mercado.

Palabras claves: pronóstico de producción; modelo matemático; regresión multivariada.

Abstract

This study examines the usefulness of multivariate mathematical regression models for predicting production. These models are essential in statistics, since they analyze the relationship between several independent variables and one or more dependent variables. The importance of production predictions is highlighted, which helps estimate the amount of goods and services that a company can generate in a specific period. This facilitates adequate planning and decision-making in production, allowing resources to be managed efficiently according to market demand. The objective focused on proposing an appropriate mathematical model that facilitates the agile prediction of production in a 20 g chocolate bar factory, using multivariate regression. quantitative nature, exploratory and applied, taking as a starting point a documentary study and field research, which had the purpose of designing a mathematical model. It is concluded that key variables in

production were identified, such as the amount of planned production and planned work hours, using a multivariable regression model in SPSS, which allowed predicting actual production with 95.4% significance. It is recommended that the microenterprise collect more data and evaluate other variables to improve the analysis, as well as encourage research in other microenterprises to balance supply and demand in the market.

Keywords: production forecast; mathematical model; multivariate regression.

Resumo

Este estudo examina a utilidade de modelos de regressão matemática multivariada para prever a produção. Esses modelos são essenciais em estatística, pois analisam a relação entre diversas variáveis independentes e uma ou mais variáveis dependentes. Destaca-se a importância das previsões de produção, que ajudam a estimar a quantidade de bens e serviços que uma empresa pode gerar em um determinado período. Isso facilita o planejamento adequado e a tomada de decisões na produção, permitindo que os recursos sejam gerenciados de forma eficiente de acordo com a demanda do mercado. O objetivo centrou-se em propor um modelo matemático adequado que facilite a previsão ágil da produção em uma fábrica de barras de chocolate de 20 g, utilizando regressão multivariada. de natureza quantitativa, exploratória e aplicada, tomando como ponto de partida um estudo documental e uma pesquisa de campo, que teve por finalidade a concepção de um modelo matemático. Conclui-se que foram identificadas variáveis-chave na produção, como a quantidade de produção planejada e horas de trabalho planejadas, utilizando um modelo de regressão multivariável no SPSS, que permitiu prever a produção real com 95,4% de significância. Recomenda-se que a microempresa colete mais dados e avalie outras variáveis para melhorar a análise, bem como incentive pesquisas em outras microempresas para equilibrar oferta e demanda no mercado.

Palavras-chave: previsão de produção; modelo matemático; regressão multivariada.

Introducción

El presente estudio aborda la temática de la aplicabilidad de los modelos matemáticos basados en regresión multivariada en el pronóstico de producción, teniendo en consideración que, estos modelos constituyen una herramienta fundamental en el área de estadística que se utilizan para analizar la relación entre múltiples variables independientes y una o más variables dependiente

(Rodríguez & Steegmann, 2013). Por otro lado, se hace énfasis en el pronóstico de producción, el mismo que, sirven para estimar la cantidad de bienes y servicios que una determinada empresa puede producir en un determinado tiempo y permite una correcta planificación y toma de decisiones en el área de producción, puesto que permiten gestionar los recursos de una forma adecuada y de acuerdo a la demanda del mercado.

La industria alimentaria desempeña un papel crucial en la economía global, y las diversas empresas que forman parte de este sector abarcan un amplio rango de actividades, desde el tratamiento y la transformación hasta la preparación, conservación y envasado de productos alimenticios (FAO, 2020; CEPAL, 2020).

A nivel mundial, las MYPYMES constituyen el 90% de las micro y pequeñas empresas, empleando el 50% de la fuerza laboral y contribuyendo al 50% del PIB global (Valdés & Sánchez, 2012). El crecimiento de estas MYPYMES depende de las fuerzas productivas y de la capacidad de anticipar las demandas del mercado.

En América Latina, las MYPYMES son especialmente significativas por su papel en la creación de empleo (Tello, 2014). Sin embargo, uno de los principales desafíos que enfrentan es la capacidad de prever la producción (López & Zapata, 2018). Estas empresas a menudo cometen errores al intentar predecir la producción, tales como el uso de un único método de pronóstico de la demanda, la falta de correlación entre la demanda histórica y la información del mercado, la omisión de errores, la selección de bases de datos incompletas, la desconsideración de la demanda elástica y la ignorancia sobre la duración del ciclo de vida del producto, entre otros (Méndez & López, 2014). El principal desafío que enfrentan las MYPYMES al intentar pronosticar la demanda es la baja efectividad del valor pronosticado (Render & Heizer, 2007). Esta efectividad se puede evaluar a través del cálculo del error del pronóstico, es decir, cuán cercano está el valor estimado en comparación con la demanda real (Zafra & Gutiérrez, 2015). Entre las variables que pueden influir en el volumen de producción se encuentran las demandas del mercado, el número de trabajadores necesarios y las horas que deben laborar para cumplir con lo planificado (Llatas & Sandoval, 2018). Uno de los beneficios de los modelos de pronóstico es minimizar el error (Cabrera & De León, 2019). Para lograr esto, se pueden utilizar diversas métricas como el error estándar de la estimación (SEE), la desviación media absoluta (MAD), el error cuadrático medio (RMSE), el porcentaje del error medio absoluto (MAPE), el error medio absoluto (MAE) y la desviación estándar (SD), entre otros (Sánchez, 2018; Llatas & Sandoval, 2018).

Una alternativa efectiva es la implementación de modelos multivariados para realizar pronósticos. La ventaja de estos modelos radica en su capacidad para identificar relaciones entre múltiples variables independientes y una variable dependiente. Por lo tanto, el objetivo de este estudio fue proponer un modelo matemático adecuado que facilite la predicción ágil de la producción en una fábrica de barras de chocolate de 20 g, utilizando regresión multivariada.

Las MYPYMES enfrentan constantemente problemas relacionados con la precisión y exactitud de los resultados obtenidos de los modelos matemáticos que describen los diversos factores que afectan el proceso de producción (FAO, 2021). El error de los modelos utilizados se mide en función de la diferencia entre la producción real y la estimada por el modelo. Estos errores son inevitables y siempre estarán presentes, ya que el modelo es solo una representación de la realidad; por lo tanto, se busca que el error resultante sea lo más pequeño posible, convirtiéndose en una medida de cuán bien el modelo se aproxima a la realidad (Garcés & Barragán, 2015).

El desarrollo de modelos matemáticos es una herramienta clave para analizar y estudiar problemas en diversas áreas del conocimiento. Su objetivo principal es describir, explicar y predecir fenómenos y procesos en distintos contextos (Montesinos & Hernández, 2007). Es relevante destacar que un modelo matemático se define por las relaciones entre las variables independientes y la variable dependiente, siendo estas relaciones independientes de los datos que se incluyan en el modelo, lo que permite su aplicación en diversas circunstancias (Aravena et al., 2008).

Un modelo matemático representa, en términos matemáticos, un objeto que pertenece a un ámbito no matemático. Muchas aplicaciones de las matemáticas, como el cálculo y la optimización, requieren el uso de modelos matemáticos. En términos generales, el desarrollo de modelos matemáticos consta de tres fases: la construcción del modelo, que traduce objetos no matemáticos a un lenguaje matemático; el análisis del modelo; y la explicación de los resultados del análisis matemático, que se relacionan con el objeto no matemático original. La efectividad o inexactitud de los modelos depende de cuán bien se ajusten a los datos originales, y no de la precisión con la que se analice el modelo en sí. Así, los modelos matemáticos deben ser considerados como un vínculo entre la teoría matemática y la realidad cotidiana, desarrollándose como una opción didáctica para su explicación, con un enfoque crítico y sistémico del pensamiento (Rodríguez & Steegmann, 2013).

Así, se puede afirmar que un modelo es una representación matemática simplificada de una realidad compleja (Plaza, 2016). Modelar implica la acción de construir un modelo, encapsulando la

realidad (Montesinos & Hernández, 2007). La creación de modelos matemáticos requiere un trabajo en equipo multidisciplinario, que aporte diversas perspectivas y conocimientos para representar adecuadamente la realidad. De este modo, un modelo se convierte en una herramienta útil para la toma de decisiones (Ramos et al., 2010).

La evolución de la tecnología de la información y la constante dinámica comercial exigen que todos los modelos utilizados en la gestión de inventarios sean revisados y actualizados de manera continua, lo que hace que la determinación de intervalos de revisión óptimos sea menos relevante. Por un lado, los tiempos de entrega de suministros tienden a reducirse gracias a los avances en la tecnología del transporte; sin embargo, esto se complica por la globalización y los tratados de libre comercio que se están estableciendo (Arango et al., 2013).

El pronóstico de ventas se ha convertido en una fuente esencial de datos para anticipar la demanda de productos, buscando alinearse lo más posible con la realidad del mercado. La aleatoriedad característica de muchos mercados puede ser abordada mediante modelos probabilísticos, que son más adecuados para la implementación informática. Todas las soluciones que aborden desde la previsión de la demanda hasta el cálculo de las cantidades de pedido son necesarias para diseñar modelos confiables y eficientes (Sánchez et al., 2013).

Las pequeñas y medianas empresas deben conocer la cantidad de productos que el mercado demanda para asegurarse de tener suficiente stock, lo que les permitirá satisfacer la demanda de los consumidores y minimizar el riesgo de obsolescencia o deterioro por exceso de inventario, así como los costos asociados al mantenimiento de productos no vendidos (Medina et al., 2009).

Las decisiones sobre el tamaño y la ubicación de la planta, así como la elección de los procesos productivos y el equipo a utilizar, son pasos fundamentales que deben dar las pequeñas empresas para intentar lograr un equilibrio a largo plazo entre la demanda y la producción. Si solo se considera el corto plazo, la variabilidad de la demanda del mercado respecto al producto es mucho más alta, por lo que es necesario implementar medidas correctivas para abordar este desafío. Por esta razón, la planificación y programación de la producción adquiere gran relevancia en cada micro y pequeña empresa (Escobar et al., 2010).

El pronóstico de producción se define como una previsión de lo que podría ocurrir en el futuro, convirtiéndose en una extensión de datos pasados; sin embargo, cualquier fenómeno aleatorio introduce incertidumbres, lo que convierte este proceso en uno que utiliza tanto métodos cuantitativos como cualitativos para su desarrollo (Galicia & Villegas, 2005).

La demanda de producción puede ser estimada mediante diversos métodos, cuya selección depende de varios factores, como la antigüedad de los datos, la existencia de patrones o tendencias y la estacionalidad del producto. Sin embargo, el factor más determinante es el comportamiento o tendencia de la demanda del producto y la comprensión de las causas que la generan (Saucedo et al., 2010).

Entre los métodos más comúnmente empleados para el pronóstico se encuentran las series de tiempo, las regresiones lineales simples y múltiples, así como los métodos cualitativos. Las series de tiempo y los métodos de regresión son técnicas estadísticas o cuantitativas que requieren un conjunto de datos históricos de la demanda para prever la demanda futura. En contraste, los métodos cualitativos se fundamentan en los juicios de expertos para elaborar pronósticos sobre la producción o la demanda del mercado (Saucedo et al., 2010).

Al elegir un modelo de pronóstico adecuado, es esencial considerar las diferencias en el comportamiento de la demanda y la distribución en cada punto de venta (Pérez et al., 2012). La regresión multivariada implica ajustar modelos lineales o linealizables entre una variable dependiente y dos o más variables independientes. En este tipo de modelo matemático, es crucial evaluar la heterocedasticidad, la multicolinealidad y la especificación (Montero, 2016). La regresión multivariada utiliza múltiples variables independientes o explicativas, lo que permite incorporar más información en la construcción del modelo matemático, y así obtener estimaciones o predicciones más precisas (Rojo, 2007).

Metodología

El presente estudio es de carácter cuantitativo, de tipo exploratoria y aplicada, tomando como punto de partida un estudio documental y una investigación de campo, la cual tuvo como finalidad diseñar un modelo matemático que permita alcanzar un pronóstico de la producción de una fábrica de chocolate en barra a partir de una regresión multivariada, para lo cual se tomó como población y muestra, los datos recolectados de la producción de una empresa que comercializa chocolate en barra durante los últimos 24 meses.

A partir del uso del programa SPSS se realizó un análisis de variables excluidas para evaluar el nivel de aporte al modelo, es decir si alguna de las variables independientes debe de excluirse; se analiza la bondad de ajuste a través del coeficiente de determinación (R^2) y el análisis de varianza (ANOVA), finalmente se obtuvieron los coeficientes de la regresión multivariada y su grado de

significancia. La información será procesada mediante el software estadístico IBM SPSS versión 24, para el tratamiento y análisis de los datos.

Resultados

La variable dependiente o de salida corresponde a la Cantidad de Producción Real (CPR), las variables independientes corresponden a: Capacidad de Producción Programada, Horas Laborares Planificadas (HLP), Paradas No Programadas (PNP).

$$Y = \beta_0 + \beta_1X_1 + \beta_2X_2 + \beta_3X_3$$

En donde:

$Y = \text{CPR}$

$X_1 = \text{CPP}$

$X_2 = \text{HLP}$

$X_3 = \text{PNP}$

Para la comprensión adecuada del modelo de regresión, fue fundamental complementar la investigación con el diagnóstico y la validación del modelo. Este diagnóstico abarcó aspectos como la linealidad, la normalidad de los errores, la homocedasticidad, la independencia de los errores y las variables explicativas.

Supuesto de Normalidad de los Residuos

El supuesto de normalidad busca verificar que los residuos se distribuyen de manera normal. Dado que la muestra supera los 50 datos, es apropiado utilizar la prueba de Kolmogorov-Smirnov (K-S). Para considerar que los residuos provienen de una muestra con distribución normal, la significancia de esta prueba debe ser superior a 0.05.

Tabla 1 Prueba de Kolmogorov-Smirnov

		Standardized Residual
N		73
Parámetros normales ^{a,b}	Media	0,0000000
	Desviación estándar	0,97894501
Máximas diferencias extremas	Absoluta	0,234
	Positivo	0,224

	Negativo	-0,234
Estadístico de prueba		0,234
Sig. asintótica (bilateral)		0,000 ^c

Nota. En la tabla se observa la prueba de Kolmogorov-Smirnov. a. La distribución de prueba es normal. b. Se calcula a partir de datos. c. Corrección de significación de Lilliefors.

Como se observó en la tabla 6, el nivel de significancia fue de 0.000; por lo que el valor de p (sig) fue menor que 0.05. Esto demostró que se cumplió con el supuesto de normalidad de los datos. Por lo tanto, se rechazó la hipótesis nula, lo que significó que los residuos presentaron una distribución normal.

Supuesto de Independencia de las observaciones

Para evaluar el supuesto de independencia de los errores, se utilizó la prueba de Durbin-Watson. El criterio para afirmar que las observaciones son independientes es que el valor de Durbin-Watson debe acercarse lo más posible a 2, con una variación de ± 1 . Por lo tanto, los valores que se encuentren entre 1 y 3 son aceptables para considerar que los residuos son independientes.

Tabla 2 Resumen del modelo

Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación	Durbin-Watson
1	0,977 ^a	0,954	0,952	96,55973	1,815


Nota. En la tabla se observa la prueba de Durbin- Watson. a. a. Predictores: (Constante), PNP, CPP, HLR. b. Variable dependiente: CPR.

En la Tabla 2 se observó que el coeficiente de Durbin-Watson tenía un valor de 1.815, el cual es aceptable y se encuentra muy cercano a 2. Por lo tanto, se consideró satisfecho el supuesto de independencia de las observaciones.

Supuesto de Homocedasticidad

La homocedasticidad es una propiedad de un modelo de regresión lineal que indica que la varianza de los errores se mantiene constante a lo largo del tiempo. Además, si la varianza es constante y también menor, esto resultará en predicciones más confiables del modelo.

Figura 1 Gráfico de dispersión



A partir del análisis del gráfico de dispersión en la figura 1, se observó que los puntos estaban distribuidos de manera adecuada, lo que sugirió que no existía una relación sistemática entre los residuos tipificados y los valores pronosticados tipificados de la cantidad de producto a producir.

Supuesto de linealidad

El supuesto de linealidad implicaba que la relación entre la variable dependiente y las independientes debía ser lineal.

Tabla 3 Correlaciones

	CPP		HLR	PNP	CPR
CPP	Correlación de Pearson	1	0,472**	0,163	0,975**
	Sig. (bilateral)		0,000	0,169	0,000
	N	73	73	73	73
HLR	Correlación de Pearson	0,472**	1	0,325**	0,499**
	Sig. (bilateral)	0,000		0,005	0,000
	N	73	73	73	73
PNP	Correlación de Pearson	0,163	0,325**	1	0,191
	Sig. (bilateral)	0,169	0,005		0,105

	N	73	73	73	73
CPR	Correlación de Pearson	0,975**	0,499**	0,191	1
	Sig. (bilateral)	0,000	0,000	0,105	
	N	73	73	73	73

Como se pudo observar en la tabla 3, existió una correlación positiva entre todas las variables de entrada y la variable de salida. En la matriz se constató que todas las variables independientes de HLP, CPP y PNP tenían correlación con la variable dependiente CPR. La variable independiente con mayor relación fue la CPP, con un valor de 0.975, seguida por la variable HLR con 0.499, y finalmente la variable PNP con 0.191. Por lo tanto, se puede afirmar que efectivamente existe una correlación entre las variables independientes y la variable dependiente.

Supuesto de multicolinealidad o supuesto de ausencia de multicolinealidad

Para el diagnóstico de colinealidad se utilizó el factor de varianza inflada (VIF), un supuesto que ayuda a determinar la presencia de multicolinealidad entre las variables independientes. Ninguna variable independiente debe superar el valor de diez; de lo contrario, indicaría multicolinealidad entre las variables. En el modelo de regresión multivariada analizado, se constató que ningún valor del VIF era mayor a 10. En el caso del estudio, al trabajar con la matriz de diagnósticos de colinealidad, se deben seguir los siguientes pasos; identificar los índices que superen el umbral de 30 y, para los índices identificados, determinar las variables con proporciones de varianza por encima del 90%; se considerará que hay multicolinealidad si esto ocurre con dos o más coeficientes.

Tabla 4 Diagnósticos de colinealidad

Modelo	Dimensión	Autovalor	Índice de condición	Proporciones de varianza			
				(Constante)	CPP	HLR	PNP
1	1	3,408	1,000	0,01	0,01	0,01	0,03
	2	0,388	2,964	0,03	0,05	0,01	0,90
	3	0,119	5,348	0,47	0,84	0,04	0,02
	4	0,085	6,343	0,50	0,10	0,90	0,03

Nota. En la tabla se observan los diagnósticos de colinealidad. a. Variable dependiente: CPR

Se consideró que a partir de un valor de 20 podía haber cierta multicolinealidad, y que esta se

consideraba alta a partir de 30. Como se observó en la tabla 9, ningún índice de condición superó el valor de 30, por lo que se pudo concluir que no existía multicolinealidad, dado que esto se refería a dos o más variables.

Modelo Matemático de Regresión Multivariada

El valor de R cuadrado, conocido como el coeficiente de determinación, osciló entre 0 y 1, representando un rango del 0% al 100%. Esto indicaba que, con las variables disponibles, solo se podía predecir un cierto porcentaje de la ecuación lineal. El valor del R cuadrado ajustado tomó en cuenta el número de variables independientes utilizadas para predecir la variable dependiente. En el modelo se trabajó con tres variables independientes: la cantidad de producción planificada (CPP), las horas laborales planificadas (HLP) y las paradas no programadas (PNP), teniendo como variable dependiente la cantidad de producción real (CPR). En este modelo, el R^2 fue de 0,954, lo que significó que esas tres variables independientes podían explicar el 95,4% de la varianza. Además, se obtuvo un R^2 ajustado de 0,952.

Tabla 5 Análisis de la Varianza

Modelo	Suma de cuadrados	Gl	Media cuadrática	F	Sig.
1 Regresión	13240605,160	3	4413535,054	473,363	0,000 ^b
Residuo	643340,949	69	9323,782		
Total	13883946,110	72			

Nota. En la tabla se observa el análisis de varianza. a. Variable dependiente: CPR, b. Predictores: (Constante), PNP, CPP, HLR

Se observó que era válido trabajar con un modelo matemático que incluía tres variables, dado que este ofrecía un mejor ajuste a la realidad y las tres variables seleccionadas contribuían positivamente a la predicción de la variable dependiente. El valor p fue menor a 0.05, lo que indicaba que el modelo era adecuado. El modelo matemático utilizado presentó un valor del estadístico de prueba F igual a 473,363 y un valor p igual a 0, lo cual es menor que 0.05. Por lo tanto, se rechazó la hipótesis nula y se concluyó que existía una dependencia significativa entre las variables.

Tabla 6 Coeficientes

Modelo	Coeficientes no estandarizados		Coeficientes estandarizados	T	Sig.	Estadísticas de colinealidad	
	B	Error estándar	Beta			Tolerancia	VIF
1 (Constante)	-27,046	29,549		-0,915	0,363		
CPP	0,970	0,030	0,952	32,379	0,000	0,777	1,288
HLR	1,558	1,152	0,041	1,353	0,181	0,714	1,401
PNP	6,648	8,043	0,023	0,827	0,411	0,894	1,118

Nota. En la tabla se muestran los coeficientes no estandarizados, estandarizados y estadísticas de colinealidad.

Teniendo en cuenta los resultados de la tabla 6, se dedujo que el modelo matemático basado en la regresión multivariada para el pronóstico fue:

$$Y = -27,046 + 0,970 X1 + 1,558 X2 + 6,848 X3.$$

Como se mostró en la ecuación, se logró construir una fórmula que permitía predecir la cantidad de producción real en función de tres variables de entrada. La ecuación de regresión estandarizada mostró las variables en la misma dimensión de la siguiente manera:

$$Y = 0,952 X1 + 0,041 X2 + 0,023 X3.$$

A continuación, se procedió a comparar los datos de producción real CPR con los datos obtenidos a partir del modelo matemático propuesto CPR_RM.

Tabla 7 Estadísticas de muestras emparejadas

Media	N	Desviación estándar	Media de error estándar
Par 1 CPR_R	73	428,61822	50,16597
M			
CPR	73	439,12707	51,39594

Nota. En la tabla se encuentra la estadística de las muestras emparejadas.

La media de los datos obtenidos con el modelo matemático CPR_RM fue de 797,9279, mientras que la media de los datos reales observados CPR fue de 798,3288. Estas medias resultaron ser muy semejantes, lo que indica que, al existir una diferencia muy pequeña entre ellas, se puede afirmar que el modelo matemático fue bastante bueno.

Tabla 8 Correlaciones de muestras emparejadas

N			Correlación	Sig.
Par 1	CPR_RM & CPR	73	0,977	0,000

Nota. En la tabla se observa la correlación de muestras emparejadas.

La correlación entre los datos generados con el modelo matemático y los datos reales observados fue de 0,977, un valor muy cercano a 1. Además, el P-valor fue igual a 0, lo que es menor que 0,05, por lo que se pudo concluir que sí existía correlación entre las variables.

Tabla 9 Prueba de muestras emparejadas

		Diferencias emparejadas					t	gl	Sig. (bilateral)
Media	Desviación estándar	Media de error estándar	95% de intervalo de confianza de la diferencia		t				
			Inferior	Superior					
Par 1	CPR_RM - CPR	-0,40089	94,52691	11,06354	- 22,45565	21,65387	- 0,036	72	0,971

Nota. En la tabla se observa la prueba de muestras emparejadas.

En la tabla 9, se observó que la diferencia emparejada entre las medias fue muy baja, con un valor de -0,40089. Esto indica que ese fue el error cometido con el modelo matemático propuesto.

Conclusiones

Se identificaron y presentaron las variables más relevantes para el proceso de producción de barras de chocolate de 20 gramos, que incluyeron la cantidad de producción planeada (CPP), las horas laborales planificadas (HLP) y las paradas no programadas (PNP), con la cantidad de producción

real (CPR) como variable dependiente. Se construyó un modelo de regresión multivariable utilizando estas variables y se ingresaron los datos en el programa SPSS. Al evaluar el modelo, se concluyó que, para la microempresa en la elaboración de galletas de 20 g, era posible predecir la CPR con un nivel de significancia del 95,4%, reflejado en su R^2 .

Por lo tanto, se considera importante evaluar otras posibles variables independientes según lo determine el departamento de producción. Para ello, la microempresa debería fomentar una cultura de recopilación de datos que pueda servir para un análisis posterior. Se sugiere promover investigaciones que desarrollen modelos matemáticos mediante el uso de regresión multivariada en diversas microempresas, ya que esto beneficiará al sector al reducir la brecha entre la oferta y la demanda del mercado.

Referencias

1. Galicia, P., & Villegas Valladares, E. (2005). La importancia de los criterios cualitativos de los pronósticos en los Agronegocios. *Revista Mexicana de Agronegocios*, 9(16), 464-477. <https://www.redalyc.org/articulo.oa?id=14101606>
2. Arango Marín, J. A., Giraldo García, J. A., & Castrillón Gómez, O. D. (2013). Gestión de compras e inventarios a partir de pronósticos Holt-Winters y diferenciación de nivel de servicio por clasificación ABC. *Scientia Et Technica*, 18(4), 743-747. <https://www.redalyc.org/pdf/849/84929984023.pdf>
3. Aravena, M., Caamaño, C., & Giménez, J. (2008). Modelos matemáticos a través de proyectos. *Revista latinoamericana de investigación en matemática educativa*, 11(1). http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1665-24362008000100003&lng=es&nrm=iso&tlng=es
4. Damián Llatas, M. R., & Sandoval Santamaría, N. J. (2018). Modelo óptimo de Pronóstico del índice mensual de Producción de Electricidad"-Perú en el Periodo 2006 – 2015. Facultad de Ciencias Físicas y Matemáticas.
5. Escobar-Gómez, E. N., Díaz-Núñez, J. J., & Taracena-Sanz, L. F. (2010). Modelo para el ajuste de pronósticos agregados utilizando lógica difusa. *Ingeniería. Investigación y Tecnología*, 11(3), 289-302. <https://www.redalyc.org/articulo.oa?id=40415987005>
6. FAO (2021). FAO. (Situación Alimentaria Mundial) Retrieved 08 de octubre de 2021. <http://www.fao.org/worldfoodsituation/csdb/es/>

7. FAO y CEPAL (2020). Sistemas alimentarios y COVID-19 en América Latina y el Caribe. Santiago de Chile: FAO. <https://doi.org/https://doi.org/10.4060/ca8677es>
8. López Rodríguez, S. M., & Zapata Zuluaga, T. (2018). Técnicas de pronósticos en revisión sistémica de literatura para empresas de confecciones. Bogotá: Universidad Cooperativa de Colombia. <http://repository.ucc.edu.co/handle/ucc/12151>
9. Medina Varela, P. D., Restrepo Correa, J. H., & Cruz Trejos, E. A. (2009). Plan de producción para la compañía de helados "Nata". *Scientia Et Technica*, 15(43), 311-315. <https://www.redalyc.org/articulo.oa?id=84917310055>
10. Plaza Gálvez, L. F. (2016). Modelación matemática en ingeniería. *IE Revista de investigación educativa de la REDIECH*, 7(13), 47-57. <https://www.redalyc.org/journal/5216/521655237005/>
11. Ramos, A., Sánchez, P., Ferrer, J. M., Barquín, J., & Linares, P. (2010). Modelos matemáticos de optimización. Madrid: Universidad Pontificia Comillas. https://d1wqtxts1xzle7.cloudfront.net/34357606/modelado_en_gams-with-cover-page-v2.pdf?Expires=1633687201&Signature=EzhFiG-skxPtDHclAwcIQ08Qgji~w3TqbHmhGJKqaRfyW1SAIdIZH5DDJXiHRLC8v2Tdb-zncNZYV4WfKu0LVXNlkmLiT6Noochcf21rjOhupk0bIXvhHdDbsWtw~Me7oBaSZ0g4ocy
12. Render, B., & Heizer, J. (2007). Administración de la producción. México: Pearson Educación.
13. Rodríguez Velázquez, J. A., & Steegmann Pascual, C. (2013). Modelo Matemáticos. https://recursos.salonesvirtuales.com/wp-content/uploads/bloques/2012/08/Modelos_matematicos.pdf
14. Rodríguez Gallegos, R., & Bourguet-Diaz, R. E. (2015). Identifying Modeling Practices Through Differential Equations and Simulation. 122nd SEE Annual Conference-Exposition. <https://www.asee.org/public/conferences/56/papers/13153/view>
15. Rojo Abuín, J. M. (2007). Regresión lineal múltiple. Instituto de Economía y Geografía, 2-33. https://d1wqtxts1xzle7.cloudfront.net/36787341/REGRESION_LINEAL_MULTIPLE_3-with-cover-page-v2.PDF?Expires=1640663317&Signature=MH9ICvACS9azM8zOaqrxKMjbZKnQ49AngSm4U1Hz2XG-

EePgqOo413~c6mu4HBGfaWrBXsHftzJ9KYmY070cTcz6ReXEL2alQyNbk~wa
uciIFjWwWzIYf7fwji2iiDJo

16. Sánchez Sánchez, D. A. (2018). Modelo ARIMA para el pronóstico de la producción de cacao en el Perú 2012 - 2018. Facultad de Ciencias Físicas y Matemáticas. Trujillo: Universidad Nacional de Trujillo
<https://doi.org/http://190.223.54.254/bitstream/handle/UNITRU/11563/SÁNCHEZ%20SÁNCHEZ%2c%20David%20Alexander.pdf?sequence=1&isAllowed=y>
17. Sánchez-López, E., Barreras-Serrano, A., Pérez-Linares, C., Figueroa-Saavedra, F., & Olivas-Valdez, J. A. (2013). Aplicación de un modelo arima para pronosticar la producción de leche de bovino en Baja California, México. *Tropical And Subtropical Agroecosystems*, 16(3), 315-324. <https://www.redalyc.org/articulo.oa?id=93929595004>
18. Saucedo Castillo, O., Pérez, L. V., Herrera Isla, L., & Fernández Pérez, L. (2010). Sistema de pronóstico climático del tizón tardío (*phytophthora infestans*) en el cultivo de la papa en la provincia de Villa Clara. *REDVET. Revista Electrónica de Veterinaria*, 11(38), 1-12. <https://www.redalyc.org/articulo.oa?id=63613140038>
19. Tello Cabello, S. Y. (2014). Importancia de la micro, pequeñas y medianas empresas en el desarrollo del país. *LEX*, 12(14), 199-218. <https://doi.org/http://dx.doi.org/10.21503/lex.v12i14.623>
20. Valdés Díaz de Villegas, J. A., & Sánchez Soto, G. A. (2012). Las mipymes en el contexto mundial: sus particularidades en México. *Iberóforum*, VII (14), 126-156. <https://www.redalyc.org/pdf/2110/211026873005.pdf>
21. Zafra Mejía, C. A., & Gutiérrez Gil, V. H. (2015). Análisis de la producción de lixiviado y biogás bajo condiciones de extracción activa. *Ingenium Revista De La Facultad De ingeniería*, 16(31), 9-23. <https://doi.org/https://doi.org/10.21500/01247492.1365>