

Evaluar la capacidad predictiva de los métodos series de tiempo, regresión lineal y RNA Poda exhaustiva considerando el mínimo margen de error, una aplicación a la demanda

**Cesar Contreras Serpa; Daniel Peña Muguértgui; José M. Esquivel Beteta; Edwin Llerena Poma
Dr. Palza Vargas, Edgardo; Dr. Mamani Apaza, Guillermo.**

Palabras Claves : Series de tiempo, Pronóstico, Regresión Lineal, Redes Neuronales

Resumen

El objetivo de la investigación es determinar la eficiencia de los modelos Series de Tiempo, Regresión Lineal y Red Neuronal Artificial para el pronóstico de la demanda de medicamentos en la Entidad Privada de Salud Ricardo Palma (EPS_RP). Se empleó la metodología Box Jenkins para el desarrollo de la presente investigación, además se consideró como unidad de análisis la cantidad de ventas semanales de los medicamentos en estudio. Para evaluar la eficiencia de los modelos se trabajó con el medicamento, que tuvo mayor demanda en los últimos 5 años, OPTIRAY VIA 320/1 100ML. Luego de comparar la eficiencia de los modelos se determinó que el pronóstico basado en Redes Neuronales Artificiales es el que presenta el menor margen de error en el pronóstico de las ventas.

To evaluate the predictive ability of time series methods, linear regression and pruningRNA exhaustive considering the minimum margin of error, an application to the demandfor drugs in the clinic Ricardo Palma, Lima-Peru 2010.

Abstract

The objective of this research is to determine the efficiency of Time Series Models, Linear, Regression and Artificial Neural Network for forecasting the demand for drugs inthe Private Health Institution Ricardo Palma (EPS_RP). We used the Box Jenkinsmethodology for the development of this research also considered as the unit ofanalysis, the weekly sales number of drugs under study. To evaluate the efficiency of themodels we used the drug, which had increased demand over the past 5 years, VIAOPTIRAY 320 / 1 100ML. After comparing the efficiency of the models was determinedthat the forecast based on Artificial Neural Networks is the one with the smallest marginof error in forecasting sales.

keywords: Time series, Forecasting, Linear Regression, Neural Networks

1. Introducción

Hoy en día, en muchas áreas como la ingeniería, medicina, biología, entre otros, aparecen eventos inciertos, donde los atributos de los datos tienen la forma de series de tiempo. Desde el punto de vista del aprendizaje automático, en cada punto de una data histórica se puede aplicar modelos de predicción.

Un hecho real es que muchas empresas anhelan pronosticar sus activos o flujos de salida para una mejor toma de decisiones. En Perú las empresas también necesitan de herramientas de pronóstico, debido al constante desarrollo de los mercados, lo cual genera escenarios cada vez más competitivos y cambiantes, por lo que es necesario disponer de modelos y métodos que sean capaces de pronosticar activos de entrada y salida.

La EPS_RP actualmente, recurre a generar pronósticos de venta de medicamentos para una mejor toma de decisiones. El pronóstico, es realizado por el personal de logística de la siguiente forma: se toma las ventas de las dos semanas anteriores, se calcula el promedio y en función a ello se genera una orden de compra.

Esta forma de pronóstico de ventas para generar la orden de compra tiene un alto margen de error. En consecuencia se genera un exceso o una falta de stock, y en cualquiera de los dos casos representa pérdida monetaria para la EPS_RP.

Es por ello, que el propósito de esta investigación es la comparación de diferentes modelos de pronósticos y la selección del modelo más efectivo en pronóstico de la demanda.

2. Métodos de predicción

¿Qué es predicción?

Según Villanueva, 2004 la predicción en el contexto científico es una declaración precisa de lo que ocurrirá en determinadas condiciones especificadas. Se puede expresar a través del silogismo: "Si A es cierto, entonces B también será cierto."

2.1 Método Serie de Tiempo

Según Toledo Muñoz, 1994 por serie de tiempo nos referimos a datos estadísticos que se recopilan, observan o registran en intervalos de tiempo regulares (diario, semanal, semestral, anual, entre otros). El término serie de tiempo se aplica a los datos registrados en forma periódica que muestran, por ejemplo, las ventas anuales totales de almacenes.

A. Promedio Móvil Simple: Según Soto, 2010 un promedio móvil simple o aritmético es calculado como la suma de un número predeterminado de valores por un cierto número de períodos de tiempo, dividido por el número de períodos de tiempo.

B. Promedio Móvil Doble: Según Ortiz Van Steenberghe, 2008 el método consiste en calcular un conjunto de promedios móviles y en seguida se calcula un segundo conjunto como promedio móvil

del primero.

C. Suavizamiento Exponencial Simple: Según Arbeleche Grela, 2005 define que esta técnica se basa en la atenuación de los valores de la serie de tiempo, obteniendo el promedio de estos de manera exponencial; es decir, los datos se ponderan dando un mayor peso a las observaciones más recientes y uno menor a las más antiguas.

D. Suavizamiento Exponencial Doble: Según Stair Jr., 2006 este método consiste en realizar dos suavizaciones exponenciales, a partir de las cuales se obtendrá el valor estimado, o pronóstico que buscamos realizar, mediante un cálculo realizado con una expresión sencilla. La primera se aplica a los valores observados en la serie de tiempo y la segunda a la serie atenuada obtenida mediante la primera atenuación.

Holt Winter's Aditivo: Para Arbeleche Grela, 2005 en este método la estacionalidad es aditiva con respecto de la tendencia, en lugar de ser multiplicativa. Los diferentes componentes se combinan sumando donde "a" es la constante, "b" la tendencia y "c" el componente estacional.

E. Estacional Aditivo: Para Sapag Chain, 2007 se emplea cuando la serie de datos disponibles no muestra tendencia pero sí estacionalidad. Resulta una curva repetitiva que representa los promedios con estacionalidad.

F. Estacional Multiplicativo: Según Sapag Chain, 2007 se usa cuando los datos no tienen una tendencia clara, existe estacionalidad y se observa crecimiento. Resulta una curva repetitiva creciente que representa el aumento de los promedios con estacionalidad.

2.2 Método de Regresión Lineal

El término regresión fue introducido por Francis Galton Galton (1889) refiriéndose a la "ley de la regresión universal": Su trabajo se centraba en la descripción de los rasgos físicos de los descendientes (una variable) a partir de los de sus padres (otra variable).

El objetivo, pues, del análisis de regresión es

hallar la función algebraica y la forma geométrica que mejor expresen la relación empírica entre ambas variables, es decir, la pauta y línea de evolución en la realidad de una variable en función de la otra. El análisis de regresión sirve para predecir una medida en función de otra medida (o varias).

Y = Variable dependiente (predicha, explicada).

X = Variable independiente (predictiva, explicativa).

La relación de la función $Y = f(X) + \text{error}$, f es una función de un tipo determinado y error es aleatorio, pequeño, y no depende de X . Su

ecuación de regresión $y = \beta_0 + \beta_1 x + \varepsilon$ permite establecer la relación que existe entre dos

variables en la que Y es Variable Dependiente, β_0 es Constante Beta, β_1 es la Sensibilidad, x

es la variable Independiente y ε es el error.

2.3 Método de Redes Neuronales Artificiales

Para Kröse y van der Smagt, 1993 una red neuronal es un modelo computacional con un conjunto de propiedades específicas, como son la habilidad de adaptarse o aprender, generalizar u organizar la información, todo ello basado en un procesamiento eminentemente paralelo.

La estructura de una red neuronal está compuesta por las dendritas, el cuerpo de la célula osoma, núcleo, y el axón como los principales componentes de una red neuronal.




Figura 1. Estructura de una Red Neuronal.

2.3.1 Método de Redes Neuronales Artificiales

El modelo de una neurona artificial es una imitación del proceso de una neurona biológica, puede también asemejarse a un sumador hecho con un amplificador operacional.

2.3.2 Red Neuronal Artificial – RNA

Una RNA es un conjunto de nodos ordenados adaptables los cuales, a través de un proceso de aprendizaje mediante ejemplos prototipo, almacenan conocimiento de tipo experimental y lo hacen disponible para su uso. [An Introduction to Neural Computing. Igor Aleksander and Helen Morton, 1990]

Una RNA es un ensamble de elementos procesadores simples y adaptables, cuya funcionalidad está burdamente basada en una neurona. La habilidad de procesamiento de la red está almacenada en la intensidad de las conexiones entre elementos, obtenidos por un proceso de adaptación a un conjunto de patrones de entrenamiento.

En la práctica, las RNAs son frecuentemente implementadas, una vez diseñadas matemáticamente, mediante hardware (equipo electrónico) cuyo comportamiento corresponde al de las funciones de transferencia con los parámetros escogidos.

Entre las aplicaciones de las RNAs más conocidas son:

Agrupamiento/Categorización

Un algoritmo de agrupamiento explora la similitud entre los patrones y coloca los patrones similares en grupos.

Pronósticos

Este tipo de uso de la RNA es altamente pertinente y necesario para la toma de decisiones en la gestión empresarial, la ciencia y la ingeniería.

Optimización

El objetivo de un algoritmo de optimización es encontrar una solución que satisfaga un conjunto de restricciones de tal manera que una función objetivo sea maximizada o minimizada.

Control

En modelos de RNAs adaptativas se desea generar señales de entrada de control que permitan que el comportamiento de la salida del sistema siga determinado patrón de reglas. Según Manzanilla en el 2005.

3. Por qué usar SPSS Clementine y Crystal Ball

Crystal Ball, es un programa que permite realizar cálculos de predicción, lo más acertados posibles, permitiendo el uso de herramientas que permiten optimizar la operación del pronóstico, posibilitando la solución en cualquier escenario.

SPSS Clementine, hace sencillo el trabajo en predicción. Su interfaz gráfica y sencilla hace que la aplicación de la Minería de Datos sea muy simple para los usuarios.

Clementine es una herramienta comúnmente utilizada en minería de datos, la cual ayuda a las organizaciones a comprender el comportamiento de las personas y a predecir qué es lo que harán.

¿Que hace Crystal Ball?

Crystal Ball, se divide en diferentes componentes cada uno con su función respectiva. Entre ellos CB Predictor: este componente permite realizar pronósticos de manera ágil y sencilla, utilizando ocho métodos de series de tiempo; este componente permite visualizar la tendencia de la data, seleccionar si existe estacionalidad, seleccionar los métodos de series de tiempo a usar, ajustar el grado de confiabilidad entre otras opciones.

En cuanto a resultados, genera una serie de informes con los cuales se puede determinar claramente cuál es el modelo que más se ajusta a la data fuente, y todo esto como complemento del software de cálculo MS Office Excel.

3.2 ¿Que hace SPSS Clementine?

El software estadístico SPSS Clementine cuenta con diversas herramientas para realizar análisis y pronósticos de datos en tiempo real. Gracias a la plataforma de minería de datos con la que Clementine puede llevar pronósticos de simulación de datos como las Regresiones Lineales que

permiten llevar una tendencia estadística a través de una data historia y la técnica de Redes Neuronales Artificiales que permiten realizar predicciones de datos a través de un entrenamiento, esto genera información excepcional sobre sus operaciones y sus clientes. Clementine permite a la organización mejorar el rendimiento de diferentes áreas.

4. Descripción de la situación problemática

La entidad privada de salud en estudios atraviesa por un problema que se deriva de su sistema de inventario, el cual deja a excesivo y/o falta el stock de algunos medicamentos ya que no se lleva un control estricto de las entradas y salidas de los productos con mayor demanda. Esto genera que el costo por mantenimiento de inventario sea muy alto para la EPS_RP ya que existen medicamentos que tienen fecha de caducidad y algunos que no se venden.

También se asume una pérdida por cada medicamento que no hay en stock. Se presentan casos donde un paciente requiere de un medicamento "X" y al no tener ese medicamento; representa una pérdida para la entidad.

La pérdida que asume la EPS_RP, algunas veces es mayor a la utilidad generada por el producto. Se calcula que aproximadamente el inventario valorizado, actualmente es de tres millones de soles.

Para resolver este problema la EPS_RP recurre a la generación de pronósticos de ventas de medicamento para una mejor toma de decisiones a la hora de hacer una orden de compra. Utilizando el procedimiento anteriormente mencionado.

El propósito de esta investigación es modelar y pronosticar la demanda de los medicamentos en la EPS_RP mediante la implementación de modelos de pronósticos teniendo en cuenta factores de influencia como la estacionalidad y otros.

5. Metodología

La metodología elegida para realizar este proyecto

se describe a continuación: para análisis de series de tiempo según Box-Jenkins se investigan generalmente tres patrones: auto regresión, promedios móviles y tendencias. También pueden existir observaciones erráticas ocasionales, o "disturbios" que deben ser eliminados o corregidos. El procedimiento requiere una secuencia de tres pasos:

- Identificación, en el que se ensayan los diferentes modelos citados.
- Estimación, en el que se registran en una secuencia temporal los valores estimados de los coeficientes.
- Diagnóstico, en el que se verifica la conveniencia del ajuste para ver si es el adecuado y si es insuficiente, el procedimiento se vuelve a comenzar.

6. Resultados

A continuación se presenta el pronóstico de las 66 semanas hasta el 2011, utilizando como data histórica la venta por semanas, desde enero del 2006 a septiembre del 2010, del medicamento OPTIRAY VIA. En la parte superior se puede visualizar cuanto puede variar la ventas en relación al pronostico, empleando las dos herramientas y diferentes métodos. En la parte inferior, podemos ver el error del pronostico en termino de unidades vendidas con respecto a la data histórica.

Tabla 1. Pronóstico de venta de 66 semanas y su intervalo de confianza

MEDICAMENTO	AÑO	SEMANAS	Crystal Ball SERIES DE TIEMPO			SPSS Clementine RNA PODA EXHAUSTIVA		
			N	VENTAS	PRONOSTICO	N	VENTAS	PRONOSTICO
OPTIRAY VIA 320/1 100ML	2006	1	1	8		1	8	7
	2006	2	2	5		2	5	4
	2006	3	3	26		3	26	24
	2006	4	4	8		4	8	7
	2006	5	5	5		5	5	5

	2010	236	236	6	7	236	6	3
	2010	237	237	6	5	237	6	2
	2010	238	238	4	9	238	4	3
	2010	239	239	5	5	239	5	8
	2010	240	240	3	7	240	3	3
	2010	241	241	2	4	241	2	4
	2010	242	242	6	5	242	6	1
	2010	243	243	2	5	243	2	3
	2010	244	244	2	7	244	2	5
	2010	245	245	1	10	245	1	10
	2010	246	246	8	7	246	8	7
	2010	1	1		7	1		7
	2010	2	2		7	2		6
	2010	3	3		3	3		5
	2010	4	4		9	4		1
	2010	5	5		9	5		14
	2010	6	6		7	6		4
	2010	7	7		10	7		3
	2010	8	8		17	8		8
	2010	9	9		11	9		3

	2011	60	60		17	60		4
	2011	61	61		11	61		5
	2011	62	62		7	62		5
	2011	63	63		15	63		6
	2011	64	64		8	64		6
	2011	65	65		4	65		8
	2011	66	66		6	66		6

Análisis Resultados Series de tiempo			Análisis Resultados RNA		
Métodos	RMSE	MAD	Métodos	RMSE	MAD
Holt-Winters' Aditivo	60.623	43.573	RNA Poda Exhaustiva	0.7	0.86
Holt-Winters' Multiplicativo	11.593	76.111			
Estacional Aditivo	60.588	43.537			
Estacional Multiplicativo	75.447	52.652			

En la siguiente figura se puede apreciar la gráfica de la data histórica y la pronosticada.




Figura 2. Gráfica comparativa de la data real en contraste a la data ajustada con su pronóstico

6.1. Evaluación del pronóstico con Series de tiempo en Crystal Ball

Métodos	Rank	RMSE	MAD	MAPE	Durbin-Watson	Theil's U	Alpha	Beta	Gamma
Holt-Winters' Aditivo	2	6.0623	4.3573	90.773	1.56	0.773	0.075	0.001	0.545
Holt-Winters' Multiplicativo	4	11.593	7.6111	137.229	1.294	1.212	0.322	0.48	0.515
Estacional Aditivo	1	6.0588	4.3537	90.735	1.561	0.773	0.075		0.546
Estacional Multiplicativo	3	7.5447	5.2652	116.68	1.415	0.887	0.123		0.603

Tabla 2. Comparación métodos de series de tiempo.

6.2. Interpretación de los resultados obtenidos con Crystal Ball

En la tabla 2 se observa que el método de estacional aditivo (Seasonal Additive) tiene la menor Desviación Absoluta Media (MAD) y el menor Error Cuadrático Medio (RMSE) frente a los demás métodos, por lo cual se deduce que este método es el que tiene menor error en el pronóstico de ventas.

La Desviación Absoluta Media de de 4.35, viene a ser en cuanto varían las ventas pronosticadas en relación al promedio de ventas, y el Error Cuadrático Medio, de 6.05, refleja el error que presenta el modelo frente a la data histórica.

En la tabla 1 se presenta el pronóstico de ventas para los tres meses faltantes para del 2010 y de las 52 semanas del 2011 con un intervalo de confianza del 95% a nivel superior y un 5% a nivel inferior. Además, se presenta también el residuo para luego comparar con los otros modelos de pronóstico.

6.3 Evaluación del pronóstico con una RNA poda exhaustiva en SPSS Clementine

Para entrenar a la red es necesario inicializar los valores de por defecto como lo establece el software de apoyo SPSS Clementine, para este caso la inicialización de los valores es aleatoria.

El factor de aprendizaje (alfa) será de 0.9 que es el más recomendado por la RNA Poda Exhaustiva.

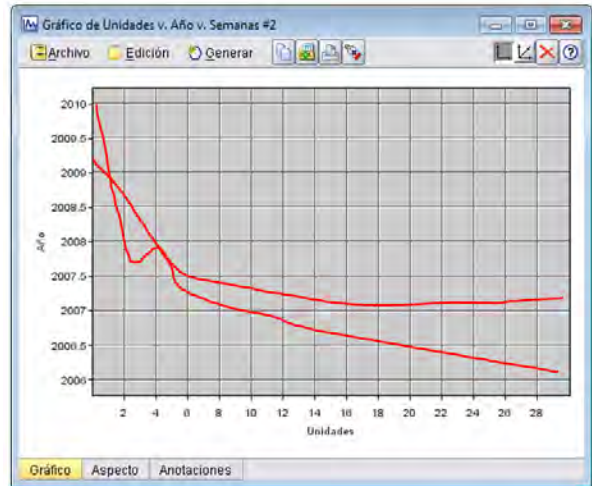


Figura 3. Curva de aprendizaje de la RNA Poda Exhaustiva

En la figura 3 se observa como el error cuadrático medio empieza a decrecer a medida que se va entrenando la red.

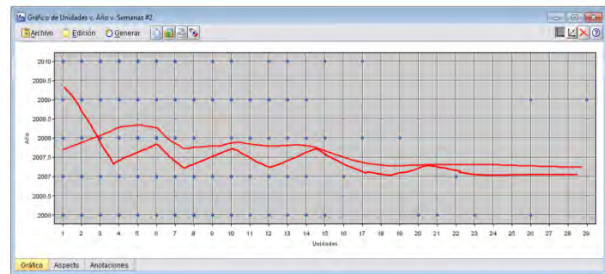


Figura 4. Comparación del ajuste de la RNA Poda Exhaustiva con data real

En la figura anterior (figura 4) se observa que existe poca diferencia entre la data deseada (data real) y la RNA Poda Exhaustiva. En efecto, de acuerdo a los resultados presentados se deduce que la red presenta el grado de validez para realizar los pronósticos de ventas

Desviación Absoluta Media	
MAD =	0.7
Error Cuadrático Medio	
MSE =	0.86

Tabla 3. – Estadísticos de rendimiento del modelo RNA poda exhaustivo.

De la tabla 3 se observa que la Desviación Absoluta Media (MAD) es de 4.575 del cual se deduce que el promedio de las desviaciones del error es aceptable, y que el Error Cuadrático Medio (MSE) es de 0.284, por lo tanto se concluye que la RNA ha logrado un aprendizaje óptimo.

7. Conclusiones

De acuerdo a los resultados obtenidos, se observa que el método de series de tiempo presenta un margen de error promedio de 4.35. Por lo que dicho método no es recomendable para el pronóstico de la demanda de medicamentos.

Tras el análisis también se llegó a la conclusión que el modelo de regresión lineal no se puede utilizar en este caso, ya que las variables independientes año y semana, presenta un nivel de significancia de 0.93 y 0.45 respectivamente mayores a 0.05 (alfa) siendo que estos niveles de significancia deben ser menores que alfa. Además, no se cumple con el parámetro sobre la constante que acompaña a la ecuación lineal (ver tabla 13).

Finalmente, la arquitectura de una RNA poda exhaustiva es la que más se ajusta al comportamiento de la variable de ventas frente a la arquitectura genérica de una RNA poda exhaustiva, con un error promedio de 0.284, siendo el margen de error más bajo entre los modelos de predicción vistos.

Al comparar el pronóstico de ventas utilizando los métodos de las series de tiempo, regresión lineal y modelo de RNA concurrentes, se concluye que las RNA poda exhaustiva tienen mayor precisión en el pronóstico frente a los modelos de series de tiempo y regresión lineal.

Al aplicar métodos estadísticos de series de tiempo y regresión lineal, tienen diferentes errores las RNA poda exhaustiva por su naturaleza, tienen un error no aceptable; pero a medida que se hacen más iteraciones de entrenamiento, el error va disminuyendo sistemáticamente hasta llegar por debajo del error aceptable.

Referencias Bibliográficas

- Aguirre J. 1998. Introducción al Tratamiento de Series Temporales. Madrid: Edigrafos S.A. Getafe. 425p.
- Akaike H. 1974. A new look at the statistical model identification. Colorado: IEEE AC 19. 116p.
- Alaya F. 1995. Series de tiempo Aplicado. Colorado: Edigrafos S.A. Getafe. 116p.
- Asín T. 1999. Series de Tiempo en los Negocios. Colorado: IEEE AC 19. 116p.
- Arbeleche S. 2005. Pronósticos de Negocios. Mexico: Itam. 520 p.
- Bonini P. 2000. Análisis Cuantitativo para la toma de desiciones. Mexico: Editorial Thompson. 212p.
- Bosch C. 1845. Aformismos y Pronçosticos de Hipócrates. Valencia: Imprenta de D. Benito Monfort. 490p.
- Box. G. 1970. Análisis de Series de Tiempo Forecasting and Control. San Francisco: Holden Day. 441p.
- Friedman J. 1991. Eficiencia de los Modelos de pronósticos. Los Angeles: Ildaes. 330p.
- Garcia J. 2005. Métodos Cuantitativos para Administración. Mexico: Publicaciones Adventure Works. 465p.
- Guerrero V. 1991. Análisis Estadístico de Series de tiempo Económicas. Mexico: Universidad Autónoma Metropolitana. 215p.
- Guisán M, Pérez O. 1997. Introducción de Series de Tiempo Métodos Paramétricos. Medellín: Prentice Hall Iberia. 515p.
- Humerez J. 1995. Modelos de Series de Tiempo para el pronóstico de precios. La Paz: UDAPE Mimeo. 311p.
- Kikut E. 1994. Series de Tiempo Conceptos Básicos. Bogotá: New York: Oxford Univ. Press. 350p.
- Lucas R. 1979. Series de Tiempo economicas aplicadas a la demanda. Buenos Aires: Universidad Católica de Jujuy. 230p.

Manzanilla, Orestes (UMGP). 2005. Métodos multi-superficie para construir clasificadores binarios con optimización matemática. Tesis de [grado de Magister en Ingeniería de Sistemas].Asesor: Ubaldo García Palomares. Facultad de Ingeniería. Universidad Simón Bolívar. 119p. 27 de octubre de 2005.

Martín G.1997. Introducción a la Econometría de Pronósticos. Madrid: Prentice Hall Iberia. 310p.

Morales J, Espejo J. 1994. Los Fármacos y su comercialización en el Perú. Lima: Editorial Beatriz Forero S.A. 211p.

Morales J, Espejo J. 1994. Efectos Macroeconómicos de los precios de Fármacos. Lima: Editorial Beatriz Forero S.A. 211p.

Rodríguez M. 2001. Guía para el uso e interpretación de Modelos de Series de Tiempo. Santiago de Chile: Imprenta de D. Benito Monfort. 215 p.

Spyros M. 1990. Pronósticos Estratégicos y Planificación para el siglo XXI. Madrid: Ediciones Díaz de Santos. 510p.

Stair R. 2006. Métodos Cuantitativos para Negocios. Buenos Aires: Prentice Hall. 220p.

Toledo I. 1994. Estadística aplicada a Series de Tiempo. Mexico: Alhambra Mexicana S.A. 305p.

Villanueva, Ernesto (EVB).2004. Metodología para la generación de pronósticos de venta en un laboratorio farmacéutico. Tesis de [maestría en ciencias con especialidad en ingeniería industrial]. México, D.F 2004. Universidad Pedagógica Nacional. 69p. enero 2004.

Agradecimientos:

A los alumnos que hicieron la modificaciones al artículo :

Espinoza Larios David, Diaz Mori Emiliano, Echavarría Silva Josmell y Ovalle Paulino Cristhian.

Al profesor :Dr. Guillermo Mamani Apaza que brindo su apoyo curso de Tesis I en la facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión