



Temporary Series for Structured Decision Making of Train Line 1

Nicomedes Toledo Ito, Kenny Dany Toledo Calla and
Yordan Nicolas Toledo Calla

EasyChair preprints are intended for rapid
dissemination of research results and are
integrated with the rest of EasyChair.

July 16, 2018

TEMPORARY SERIES FOR STRUCTURED DECISION MAKING OF TRAIN LINE 1

LAS SERIES TEMPORALES PARA LA TOMA DE DECISIONES PROGRAMADAS DE LA LÍNEA 1 DEL TRENO.

Toledo Ito, Nicomedes, Mg¹, Toledo Calla, Kenny Dany², Ing-M.Sc.² Toledo Calla, Yordan Nicolas.³, student³

UNIVERSIDAD ANDINA NESTOR CACERES VELASQUEZ, sollata@hotmail.com

UNISERSIDAD NACIONAL DE INGENIERIA, ktoledoc@uni.pe²

UNIVERSIDAD ANDINA NESTOR CACERES VELASQUEZ, toledo.vpr@hotmail.com³

Resumen- En esta investigación se puede apreciar que las Series Temporales se comportan mejor al darnos Coeficiente de Determinación Pearson (R^2) de 0.98 realizando predicciones en estados No lineales de la demanda de pasajeros, que las predicciones realizadas en otros programas lineales como el Excel que nos entrega un Coeficiente de Determinación Pearson (R^2) de 0.557, esta ventaja nos permite tomar mejores [6] Decisiones programadas de dotar con mayores trenes a las tres estaciones del Tren de la Línea 1 con mayor correlación de demanda respecto a las demás estaciones de: 0.94 San Borja (SBS), 0.972 Cabitos (CAB) y 0.956 Grau demanda, para evitar pérdidas futuras por desconocer cuales son las estaciones que más influyen respecto al total, con resultados de 258.33,274.67 y 447 respectivamente lo cual significa que se debe prestar mayor atención a la estación Grau y finalmente a Cabitos para mejorar el Servicio de atención oportuna al cliente.

Palabras Claves—Series Temporales, Toma de decisiones Programadas y no Programadas, Regresión Ridge.

Summary- In this investigation it can be seen that the Temporary Series behave better by giving us Pearson's Coefficient of Determination (R^2) of 0.98 by making predictions in non-linear states of passenger demand, than the predictions made in other linear programs such as Excel that it delivers a Pearson's Determination Coefficient (R^2) of 0.557, this advantage allows us to take better [6] Decisions programmed to provide with greater trains the three stations of the Line 1 Train with the highest correlation of demand with respect to the other stations of: 0.94 San Borja, 0.972 Cabitos and 0.956 Grau demand, to avoid future losses due to not knowing which are the most influential stations with respect to the total, with results of 258.33,274.67 and 447 respectively, which means that more attention must be paid to the Grau station and finally to Cabitos to improve the service of timely attention to the client.

Key Words-Temporary Series, Decision Making Programmed and Unscheduled, Ridge Regression

I. INTRODUCTION (INTRODUCCION)

Los métodos de Serie de Tiempo en la predicción de tráfico comenzó por Ahmed y Cook, enfocados en predicciones de modelos Autoregresivos Integrado Movimiento en Promedio (ARIMA). [1], gracias a este aporte

podemos generar mayores opciones para resolver diferentes situaciones de decisión de la vida en la alta gerencia [2].

A. Entrenamiento de Ecuaciones (Training)

Hoy en día requerimos disminuir nuestras incertidumbres de la vida cuando deseamos tomar alguna decisión también nos hacemos una pregunta: ¿Por qué nos da esto tanto trabajo? Es sencillo, porque no sabemos tomar bien las decisiones. Debo determinar cuáles son las estaciones del Tren con mayor correlación? La única manera de aumentar realmente sus posibilidades de tomar una buena decisión es aprender a aplicar un buen procedimiento para ese fin: el que le dé el mejor resultado con una mínima pérdida de tiempo, energía, dinero y compostura [3]. Así mismo debe estar apoyado en un cálculo numérico que nos ayude a mejorar nuestro punto de vista, a continuación se hizo un cálculo preliminar solo con tres estaciones entre Cabitos, Angamos y Nicolás Arriola del total por la correlación que presenta :

$$y = \beta_0 + \beta_1 CAB + \beta_2 ANG + \beta_3 NAR$$

$$y = 5928.76 + 8.448CAB + 4.575ANG + 14.605NAR$$

Sin embargo la que mejor se comporta con una buena correlación es entre las Estaciones de: 1.32 San Borja, 1.33 Cabitos y 0.96 Grau y así mismo el error es menos respecto a la anterior ecuación.



Fig. 1: Plano clave, Línea 1 del Tren Eléctrico de Lima.

Fuente: Línea 1 del Tren Eléctrico de Lima.

Fechas diarias

Demanda por estaciones Total=lpsa

Tabla 1: Data diaria, empleada desde 04-05-2012 al 11-26-14

II. DESARROLLO DE LA INVESTIGACIÓN.

A. Figuras

En la figura 2 nos muestra el mejor comportamiento con un error estándar residual de 0.00092, Figure 2 muestra la ecuación lineal de predicción.

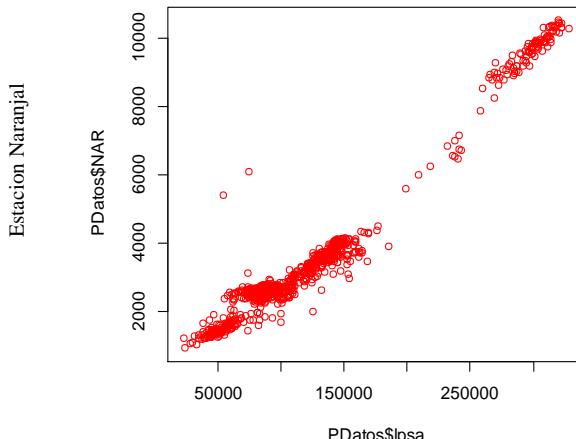


Fig. 2 Total de pasajeros que viajan según los datos de la tabla 1

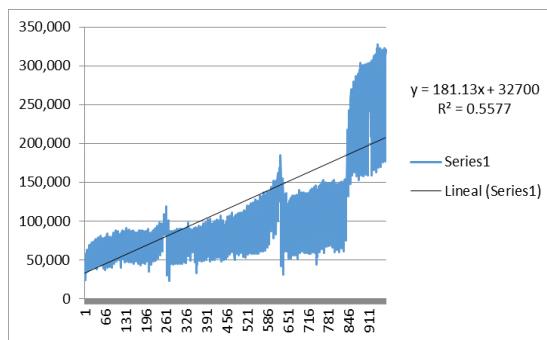


Figura 3 se aprecia que la linealidad no tiene la capacidad de comportarse no linealmente según el Programa Excel, y es menos confiable por darnos un Coeficiente de Determinación de 0.5577.

B. METODOS DE CONTRACCION Y GRAFICOS.

RIDGE REGRESSION: Se realiza la penalización de

$$\lambda \sum_{j=1}^p \beta_j^2$$

$$\hat{\beta}^{ridge} = \beta \left\{ \sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right\}$$

$$\hat{\beta}^{ridge} = \beta \sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2$$

$$Sujeto a \sum_{j=1}^p \beta_j^2 \leq t,$$

Matricialmente es: $\hat{\beta}^{\text{ridge}} = (y - X\beta)^T(y - X\beta) + \lambda\beta^T\beta$

$$\hat{\beta}^{ridge} = (y - X\beta)^T (y - X\beta)$$

Sujeto a $\sum \beta_j^2 \leq s$

Solucion: $\hat{\beta}_\lambda = (X^T X + \lambda I)^{-1} X^T y$

La Fig. 03, ilustra en el eje "x", el log. de Lambda " λ " y en el eje "y" los " β ".

$$\hat{\beta}^{lasso} = \beta \left\{ \frac{1}{2} \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\}$$

METODO LASSO: Elimina las variables que no aportan

$$\hat{\beta}^{lasso} = \beta \left\{ \frac{1}{2} \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\}$$

$$\hat{\beta}^{\text{lasso}} = \beta \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2$$

$$Sujeto a \sum_{j=1}^p |\beta_j| \leq t$$

$$\hat{\beta}^{\text{lasso}} = (y - X\beta)^T (y - X\beta)$$

Sujeto a $\sum_j |\beta_j| \leq t$

En la figura cuatro analizamos todas las estaciones para quedarnos con las que tienen buena correlación.

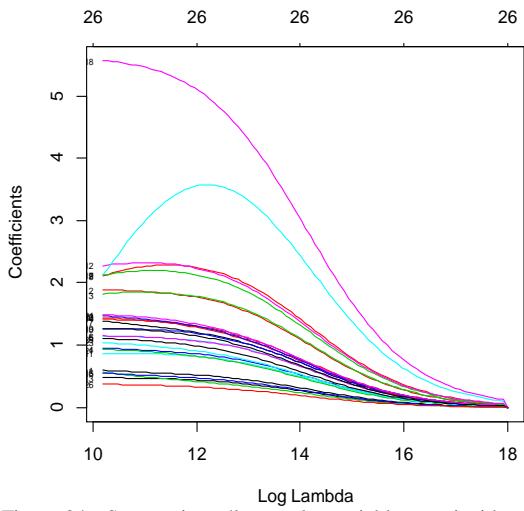


Figura 04 : Se aprecia cuáles son las variables que inciden más para la optimización de los datos de ingreso.se ilustra en el eje "x", el log. de Lambda " λ " y el eje "y" los " β "

II. PREDICCIÓN

Con estos datos de la Tabla 1, procedemos a realizar la predicción en un horizonte futuro, en la Fig. 4 los resultados son comparados entre la Demanda real con la predicción por lo tanto en un futuro cercano se podrá tomar mejores decisiones de planeamiento, con la implementación de estas tecnologías para el control por medio del monitoreo satelital.

Fuente: Línea 1 del Tren Eléctrico de Lima.

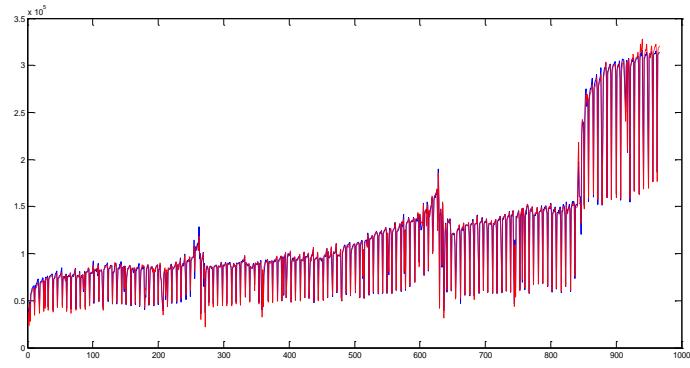


Fig. 05: Comparación entre la Demanda y la Predicción.

Fuente: Programa R

Elaboración: Propia

III. VALOR DEL ERRORES Y CORRELACION

```
> pred<-predict(modelo,NDatos,interval="confidence")
> RSE(pred,NDatos$lpsa)
[1] 0.000918427
> pred<-predict(modelo,NDatos)
> RSE(pred,NDatos$lpsa)
[1] 0.0005110317
> MSE(pred,NDatos$lpsa)
[1] 0.0002512307
> ErrorRelativo(pred,NDatos$lpsa)
[1] 1.941303e-08
> |
```

Total=lpsa

Tabla 1: Data diaria, empleada desde 04-05-2012 al 11-26-14

	JAR	POS	SCA	SMA	SRO
VES	0.5646556	0.5736631	0.5745795	0.5707346	0.5723717
PIN	0.5215395	0.5366047	0.5370153	0.5326417	0.5354059
PUM	0.5091290	0.5271953	0.5268901	0.5231202	0.5263593
VMA	0.4979842	0.4922344	0.4927715	0.4892641	0.4911243
MAU	0.5395517	0.5551270	0.5549060	0.5515544	0.5543541
SJU	0.5170502	0.5265950	0.5271465	0.5238271	0.5253017
ATO	0.7081431	0.7162597	0.7170306	0.7139376	0.7150185
JCH	0.5412846	0.5645552	0.5646659	0.56151461	0.5638525
AYA	0.6896246	0.7102928	0.7106006	0.7078130	0.7103768
CAB	0.7807100	0.8052449	0.8048969	0.7994790	0.8046364
ANG	0.8238702	0.8486320	0.8492922	0.8443262	0.8480908
SBS	0.7217963	0.7457890	0.7457541	0.7398720	0.7449431
CULT	0.7837909	0.8051253	0.8058227	0.7994048	0.8042432
NAR	0.9065993	0.9244918	0.9257672	0.9200810	0.9231316
GAM	0.7952982	0.8051554	0.8088566	0.8002336	0.8027547
GRAU	0.7233137	0.7412796	0.7426310	0.7364342	0.7401508
ELA	0.6773424	0.6748579	0.6746095	0.67474939	0.6752363
PRES	0.9918029	0.9852084	0.9861139	0.9849590	0.9839069
CAA	0.9935370	0.9944753	0.9911364	0.9965921	0.9945937
FIR	0.9927735	0.9986375	0.9960812	0.9987622	0.9987051
JAR	1.0000000	0.9949393	0.9948959	0.9957992	0.9941156
POS	0.9949393	1.0000000	0.9985426	0.9988889	0.9996080
SCA	0.9948959	0.9985426	1.0000000	0.9971691	0.9977997
SMA	0.9957992	0.9988889	0.9971691	1.0000000	0.9988699
SRO	0.9941156	0.9996080	0.9977997	0.9988699	1.0000000
BAY	0.9974527	0.9984989	0.9990385	0.9977646	0.9978280
Tasas	-0.2384151	-0.2351135	-0.2335437	-0.2356519	-0.2347903
PBI	-0.2384151	-0.2351135	-0.2335437	-0.2356519	-0.2347903
lneas	0.8817559	0.8936989	0.8942232	0.8950592	0.8926712

En la Figura 05, se puede visualizar gráficamente la verdadera demanda generada por los datos de aforos de la Tabla 1 de las estaciones analizadas, luego el grafico de color azul es la representación de la predicción realizada por el modelo matemático planteado

SMA	SRO	BAY	Tasas	PBI	lpea
0.5707346	0.5723717	0.5702860	-0.5498543	-0.5498543	0.8737948
0.5326417	0.5354059	0.5305142	-0.4841283	-0.4841283	0.8521621
0.5231202	0.5263593	0.5197143	-0.4760669	-0.4760669	0.8446164
0.4892641	0.4911423	0.4873243	-0.5000261	-0.5000261	0.8247879
0.5515344	0.5543541	0.5486584	-0.4778564	-0.4778564	0.8632197
0.5238271	0.5253017	0.5230295	-0.5392593	-0.5392593	0.8429489
0.7139376	0.7150181	0.7136018	-0.4726872	-0.4726872	0.9370579
0.5615461	0.5638525	0.5570166	-0.4606320	-0.4606320	0.8581051
0.7078130	0.7103768	0.7035848	-0.4394340	-0.4394340	0.9409333
0.7994790	0.8046364	0.7961424	-0.3867711	-0.3867711	0.9723071
0.8443262	0.840895	0.8418517	-0.3882610	-0.3882610	0.9705346
0.7398720	0.7449431	0.7364327	-0.3880929	-0.3880929	0.9417711
0.7994048	0.8042432	0.7977638	-0.4296597	-0.4296597	0.9680858
0.9200810	0.9231316	0.9191452	-0.3147713	-0.3147713	0.9784372
0.8002336	0.8027547	0.8039694	-0.3609091	-0.3609091	0.9325825
0.7364342	0.7401503	0.7354494	-0.5249046	-0.5249046	0.9565512
0.6474939	0.6452363	0.6596800	-0.1645068	-0.1645068	0.5485170
0.9849590	0.9839046	0.9894477	-0.2370042	-0.2370042	0.8699797
0.9995921	0.9945937	0.9932546	-0.2353058	-0.2353058	0.8827658
0.9987622	0.9987051	0.9961155	-0.2340295	-0.2340295	0.8922804
0.9957992	0.9941156	0.9974527	-0.2384151	-0.2384151	0.8817559
0.9988889	0.9996080	0.9984989	-0.2351135	-0.2351135	0.89936898
0.9971691	0.9977997	0.9990385	-0.2353427	-0.2353427	0.8942232
1.0000000	0.9988969	0.9977646	-0.2356519	-0.2356519	0.8905982
0.9988969	1.0000000	0.9978280	-0.2347903	-0.2347903	0.8926712
0.9977646	0.9978280	1.0000000	-0.2365419	-0.2365419	0.8901290
-0.2356519	-0.2347903	-0.2365419	1.0000000	1.0000000	-0.4101842
-0.2356519	-0.2347903	-0.2365419	1.0000000	1.0000000	-0.4101842
0.8905982	0.8926712	0.8901290	-0.4101842	-0.4101842	1.0000000

En esta última columna se aprecia, que la mayor correlación se encuentra en la estación Naranjal (Nar) con un valor de 0.978.

Coeficientes:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	9.428e-03	5.348e-02	1.760e-01	0.860
VES	1.000e+00	1.305e-06	7.662e+05	<2e-16
PIN	1.000e+00	3.324e-06	3.008e+05	<2e-16
PUM	1.000e+00	3.194e-06	3.131e+05	<2e-16
VMA	1.000e+00	1.589e-06	6.291e+05	<2e-16
MAU	1.000e+00	1.847e-06	5.414e+05	<2e-16
SJU	1.000e+00	2.557e-06	3.910e+05	<2e-16
ATO	1.000e+00	1.787e-06	5.596e+05	<2e-16
JCH	1.000e+00	4.379e-06	2.284e+05	<2e-16
AYA	1.000e+00	5.285e-06	1.892e+05	<2e-16
CAB	1.000e+00	3.194e-06	3.131e+05	<2e-16
ANG	1.000e+00	1.341e-06	7.458e+05	<2e-16
SBS	1.000e+00	3.765e-06	2.656e+05	<2e-16
CULT	1.000e+00	9.597e-07	1.042e+06	<2e-16
NAR	1.000e+00	2.557e-06	3.911e+05	<2e-16
GAM	1.000e+00	3.523e-07	2.838e+06	<2e-16
GRAU	1.000e+00	8.884e-07	1.126e+06	<2e-16
ELA	1.000e+00	4.566e-06	2.190e+05	<2e-16
PRES	1.000e+00	2.006e-05	4.985e+04	<2e-16
CAA	1.000e+00	4.885e-06	2.047e+05	<2e-16
PIR	1.000e+00	1.018e-05	9.825e+04	<2e-16
JAR	1.000e+00	4.495e-06	2.225e+05	<2e-16

POS	1.000e+00	1.346e-05	7.432e+04	<2e-16
SCA	1.000e+00	6.381e-06	1.567e+05	<2e-16
SMA	1.000e+00	9.687e-06	1.032e+05	<2e-16
SRO	1.000e+00	8.205e-06	1.219e+05	<2e-16
BAY	1.000e+00	2.830e-06	3.534e+05	<2e-16
PBI	-2.918e-03	8.845e-03	-3.300e-01	0.742

Signif. codes: 0 0.001 0.01 0.05 0.1 1

Residual standard error: 0.01609 on 938 degrees of freedom

Multiple R-squared: 1, Adjusted R-squared: 1

F-statistic: 6.326e+14 on 27 and 938 DF, p-value: < 2.2e-16

Estos son los resultados del error

IV. CONSEJOS UTILES.

PARA CONTINUAR CON LA DETERMINACIÓN DE CUÁL ES LA MEJOR ESTACIÓN QUE DEBE SER ATENDIDO CON LA DOTACIÓN DE TRENES ES LA ESTACIÓN GRAU CON UN VALOR DE 447, ESTE RESULTADO, DEBE SER COMPARADO CON LA MATRIZ. REALIZAR ENTRENAMIENTOS NOS PERMITE VISUALIZAR LOS SIGUIENTES DATOS

(Intercept)	608.3196862	612.9468028	616.6603150	619.4315956	621.2590239
VES	0.8654667	0.8716559	0.8778808	0.8841339	0.8904039
PIN	0.6760407	0.6698569	0.6649846	0.6613415	0.65843479
PUM	0.8921186	0.8774169	0.8632305	0.8495673	0.8364368
VMA	1.1559459	1.1545917	1.1529816	1.1511414	1.1490925
MAU	0.8751694	0.8732016	0.8714590	0.8699259	0.8685893
SJU	1.3441703	1.3435878	1.3425709	1.3411380	1.3393085
ATO	1.0299215	1.027217	1.0159128	1.0094992	1.0034767
JCH	0.5347819	0.5318194	0.5297409	0.5284521	0.5278835
AYA	1.4982632	1.4838947	1.4693202	1.4545779	1.4397032
CAB	1.3423916	1.3396354	1.3365838	1.3332547	1.3296654
ANG	1.0708789	1.0740007	1.0769784	1.0798177	1.0825248
SBS	1.3406696	1.3370452	1.3338223	1.3309482	1.3283755
CULT	0.9135588	0.9194757	0.92050856	0.9304016	0.9354376
NAR	0.7644375	0.7587641	0.7533687	0.7497129	0.7462551
GAM	1.0005804	1.0022248	1.0036944	1.0050177	1.0062158
GRAU	0.9501153	0.9529578	0.9555669	0.9579395	0.9600795
ELA	0.5434665	0.5524947	0.5610867	0.5691255	0.5766192
PRES	3.3673221	3.3331720	3.3005771	3.2694466	3.2396534
CAA	0.6832404	0.6794630	0.6761415	0.6732530	0.6707740
PIR	1.4216348	1.4172809	1.4139041	1.4098981	1.4058156
JAR	1.2608907	1.2672682	1.2734316	1.2793822	1.2851217
POS	1.3724777	1.3653882	1.3584408	1.3516420	1.3449971
SCA	1.2991525	1.3015245	1.3037696	1.3058940	1.3079033
SMA	1.1131433	1.1096174	1.1064040	1.1034838	1.1008386
SRO	1.1327725	1.1320873	1.1313450	1.1305520	1.1297142
BAY	0.4717889	0.4736256	0.4754126	0.4771510	0.4788420

En los siguientes resultados se aprecia los resultados obtenidos de la ecuacion Ridge:

```

> ridge.mod$lambda
[1] 66175605.04 60296746.68 54940149.89 50059418.39 45612277.63 41560208.60
[7] 37868114.21 34504015.32 31438773.69 28645839.69 26101022.24 23782279.36
[13] 21669527.21 19744466.14 17990422.18 16392202.66 14935964.55 13609094.63
[19] 12400100.17 11298509.45 10294781.01 9380221.04 8546908.05 7787624.30
[25] 7095793.22 6465422.51 5891052.19 5367707.35 4890855.02 4456364.94
[31] 4060473.76 3699752.47 3371076.65 3071599.49 2798727.06 2550095.86
[37] 2323552.37 2117134.39 1929054.00 1757682.16 1601534.52 1459258.61
[43] 1329622.10 1211502.13 1103875.62 1005810.36 916456.94 835041.43
[49] 760858.65 693266.06 631678.22 575561.66 524430.35 477841.41
[55] 435391.29 396712.33 361469.50 329357.55 300098.33 273438.42
[61] 249146.90 227013.38 206846.14 188470.50 171727.30 156471.52
[67] 142571.02 129905.40 118364.96 107849.75 98268.67 89538.76
[73] 81584.38 74336.65 67732.78 61715.59 56232.95 51237.37
[79] 46685.58 42538.16 38759.19 35315.93 32178.56 29319.91
[85] 26715.21

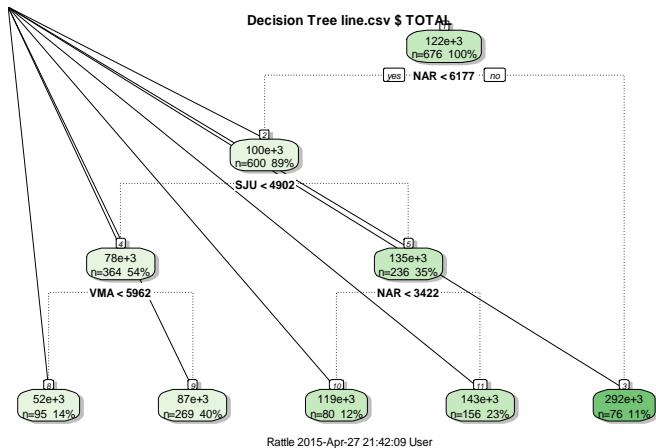
> ridge.mod$lambda[5]
[1] 45612278
>
> coef(ridge.mod)[,5]
(Intercept) VES PIN PUM VMA MAU
1.166418e+05 1.756969e-02 6.099714e-02 6.220596e-02 2.943438e-02 3.702920e-02
SJu ATO JCH AYA CAB ANG
3.687275e-02 3.998231e-02 7.963689e-02 7.360449e-02 4.006470e-02 2.759435e-02
SBS CULT NAR GAM GRAU ELA
7.655387e-02 1.482452e-02 4.338826e-02 1.293740e-02 1.565206e-02 1.369924e-01
PRES CAA PIR JAR POS SCA
1.664132e-01 3.699550e-02 4.128483e-02 2.639461e-02 4.162985e-02 2.897104e-02
SMA SRO BAY
4.292177e-02 3.165323e-02 1.052754e-02
```

A. DETERMINACION DE COEF. PEARSON

Las Series temporales, generan el Coeficiente de Determinación Pearson (R^2) de 0.98 en Figura 01, sin embargo en la Figura 2 se aprecia que la linealidad no tiene la capacidad de comportarse en una variación no lineal, y es menos confiable por darnos un Coeficiente de Determinación de 0.5577.

V. ÁRBOL DE DECISIONES.

AQUÍ NOS ILUSTRA QUE LA ESTACION NARANJAL ES EL QUE MAS PREDOMINA EN EL TRAMO ANALIZADO



VI. DETERMINACION DE LAS MATRICES PARA TOMA DE DECISIONES ESTRUCTURADAS.

Criterios de decisión			
cod	Criterio	Peso	Observación
1	Comprar mas trenes	8	S/. [5,8]
2	Mejorar sentido flujo de los paraderos	8	
3	El tiempo de espera	8	Máx. 40 min
4	Transmitir SIT del tren por Redes Sociales	7	
5	Realizar recargas virtuales	9	
6	Correlacion de estaciones	9	

Alternativas					
Cod	Estaciones del Tren	Requiere trenes	Precio	Tiempo	Transmitir SIT del tren por Redes Sociales
1	San Borja Sur	8	8000000	40	10000
2	Cabitos	7	7000000	35	12000
3	Grau	5	5000000	30	6000

Alternativas	Criterios						Criterios Ponderados					
	Nro	Estacion	Pesos	1	2	3	4	5	6	Totales		
1	San Borja Sur		0.00	8.00	0.00	3.33	10.00	9.00	0.00	64.00	0.00	23.33
2	Cabitos		3.33	8.00	5.00	0.00	9.00	7.00	26.67	64.00	40.00	0.00
3	Grau		10.00	8.00	10.00	10.00	8.00	9.00	80.00	64.00	80.00	70.00
				1	2	3	4	5	6	Totales		
				8	8	8	7	9	9	258.33		

Criterios de decisión	Alternativas			Criterios Ponderados					
	1	2	3	1	2	3			
cod	Criterio	Peso	San Borja Sur	Cabitos	Grau	San Borja Sur	Cabitos	Grau	
1	Comprar mas trenes	8	0.00	3.33	10.00	0.00	26.67	80.00	
2	Mejorar sentido flujo de los paraderos	8	8.00	8.00	8.00	64.00	64.00	64.00	
3	El tiempo de espera	8	0.00	5.00	10.00	0.00	40.00	80.00	
4	Transmitir SIT del tren por Redes Sociales	7	3.33	0.00	10.00	23.33	0.00	70.00	
5	Realizar recargas virtuales	9	10.00	9.00	8.00	90.00	81.00	72.00	
6	Correlacion de estaciones	9	9.00	7.00	9.00	81.00	63.00	81.00	
						Totales	258.33	274.67	447.00

Ecuación Empleada:

En la ecuación I, se aprecia el modelo matemático de predicción:

$$\begin{aligned}
 y = & \beta_0 + \beta_1 VES + \beta_2 PIN + \beta_3 PUM + \beta_4 VMA + \beta_5 MAU + \beta_6 SJU + \beta_7 ATO \\
 & + \beta_8 JCH + \beta_9 AYA + \beta_{10} CAB + \beta_{11} ANG + \beta_{12} SBS + \beta_{13} CULT \\
 & + \beta_{14} NAR + \beta_{15} GAM + \beta_{16} BAY
 \end{aligned} \quad (1)$$

$$f(x_i) = \beta_0 + \sum_{j=1}^p x_{ij} \beta_j \quad (II)$$

Donde :

y = Variable a predecir

x = Tabla de Datos

VII. Conclusiones:

Se concluye de la figura 04, que no es necesaria emplear varios datos de ingreso, lo más importante es tener los de mayor incidencia en la toma de decisiones planeadas.

Los resultados obtenidos en las Series Temporales han permitido tomar mejores criterios a los pesos que se asignan para la Toma de decisiones Estructuradas y no Estructurada.

Las series temporales son más versátiles en no lineal a comparación de las ecuaciones pre determinadas en el programa Excel.

Se debe atender a la Estación Grau con la adquisición de más vagones, mejorando la ubicación de la dirección de los contra flujos que se presentan en paraderos luego se debe de atender a la estación San Borja Sur.

El modelo matemático que ayuda a la predicción es:

$$y = \beta_0 + \beta_1 VES + \beta_2 PIN + \beta_3 PUM + \beta_4 VMA + \beta_5 MAU + \beta_6 SJU + \beta_7 ATO \\ + \beta_8 JCH + \beta_9 AYA + \beta_{10} CAB + \beta_{11} ANG + \beta_{12} SBS + \beta_{13} CULT \\ + \beta_{14} NAR + \beta_{15} GAM + \beta_{16} BAY$$

VIII Otras Recomendaciones

Debe existir Buena correlación entre los datos a emplear

IX. BIBLIOGRAFIA

- [1] Ahmed, M. and Cook, A. (1979) Analysis of Freeway Traffic Time Series Data by Using Box-Jenkins Techniques. *Transportation Research Board*, 722, pp.1-9.
- [2] Castro M. P., 2014 *TOMA DE DECISIONES ASERTIVAS PARA UNA GERENCIA EFECTIVA*, Bogotá D.C., Colombia, 2014.
- [3] Peter, D. Introductory Statistics with R. (2008) Second Edition. Springer Science Business Media, LLC. 2008932040. ISBN: 978-387-79054-1H. Simpson, *Dumb Robots*, 3rd ed., Springfield: UOS Press, 2004, pp.6-9.
- [4] Venables, W. N., Smith. D. M., and the R Development Core Team (2006). An Introducción to R: Notes on R: A Programming Environment for Data Analysis and Graphics. Version 2.4.1 (2006-12-18)
- [5] M. King and B. Zhu, "Gaming strategies," in Path Planning to the West, vol. II, S. Tang and M. King, Eds. Xian: Jiaoda Press, 1998, pp. 158-176.
- [6] Paul E. Moody, Toma de decisions Gerenciales Editorial McGraw –Hill Latinoamerica. S.A