

## ANÁLISIS MULTIVARIANTE DEL FLUJO TURÍSTICO Y SU IMPACTO ECONÓMICO EN GUAYAQUIL

### MULTIVARIATE ANALYSIS OF TOURIST FLOW AND ITS ECONOMIC IMPACT IN GUAYAQUIL

**Roberto Carlos Chérrez Bahamonde, Mgrtr.** 

Instituto Superior Tecnológico Bolivariano de Tecnologías. Guayaquil, Ecuador.

[rccherrez@itb.edu.ec](mailto:rccherrez@itb.edu.ec)

**Roberto William Cascante Yarlequé, Mgrtr.** 

Instituto Superior Tecnológico Bolivariano de Tecnologías. Guayaquil, Ecuador.

Universidad Estatal de Milagro. Milagro, Ecuador.

[rwascante@itb.edu.ec](mailto:rwascante@itb.edu.ec)

[rcascantey@unemi.edu.ec](mailto:rcascantey@unemi.edu.ec)

## RESUMEN

Este estudio aplica modelos matemáticos avanzados para predecir el flujo turístico en Guayaquil y analizar su impacto económico. Usando series temporales y técnicas de machine learning, se busca mejorar la precisión de las predicciones y entender la influencia del turismo en la economía local. Se recopilaron datos históricos y actuales, incluyendo llegadas de turistas, estadísticas económicas, y datos meteorológicos. El análisis reveló patrones significativos, como correlaciones entre ventas de alimentos y alojamiento, y ciclos económicos de ingresos y egresos en divisas. Los trimestres de 2020 mostraron características distintivas debido a la pandemia, mientras que los recientes indicaron nuevas tendencias. El PCA mostró que los primeros tres ejes principales explican el 67.345% de la varianza total, destacando la relevancia de ciertos períodos y variables. Estos hallazgos proporcionan una base sólida para formular políticas y estrategias que optimicen los beneficios del turismo. Los resultados son cruciales para la toma de decisiones estratégicas basadas en datos históricos, permitiendo ajustar las estrategias para maximizar el rendimiento y la eficiencia en los sectores económicos relevantes.

**Palabras clave:** Modelos matemáticos; Flujo turístico; Impacto económico; Series temporales; Machine learning.



## ABSTRACT

This study applies advanced mathematical models to predict the tourist flow in Guayaquil and analyze its economic impact. Using time series and machine learning techniques, the aim is to improve the accuracy of predictions and understand the influence of tourism on the local economy. Historical and current data were collected, including tourist arrivals, economic statistics, and meteorological data. The analysis revealed significant patterns, such as correlations between food and accommodation sales, and economic cycles of income and expenditure in foreign currencies. The quarters of 2020 showed distinctive characteristics due to the pandemic, while recent quarters indicated new trends. The PCA showed that the first three principal components explain 67.345% of the total variance, highlighting the relevance of certain periods and variables. These findings provide a solid foundation for formulating policies and strategies that optimize the benefits of tourism. The results are crucial for strategic decision-making based on historical data, allowing strategies to be adjusted to maximize performance and efficiency in relevant economic sectors.

**Key words:** Mathematical models; Tourist flow; Economic impact; Time series; Machine learning.

## 1. INTRODUCCIÓN

El turismo es una de las industrias más dinámicas y de rápido crecimiento en la economía global, desempeñando un papel crucial en el desarrollo económico de muchas ciudades y regiones. En este contexto, Guayaquil, la ciudad más grande y el principal puerto de Ecuador, ha experimentado un notable aumento en el flujo turístico en las últimas décadas. Comprender y predecir estos flujos turísticos es esencial para la planificación estratégica y la toma de decisiones en políticas públicas y desarrollo económico.

Los modelos matemáticos se han convertido en herramientas indispensables para la predicción y análisis del flujo turístico. Estos modelos permiten identificar patrones y tendencias, así como prever la demanda futura con un alto grado de precisión. Diversas metodologías, como las series temporales, la regresión múltiple y los modelos de aprendizaje automático, se han aplicado con éxito en distintos contextos turísticos alrededor del mundo (Song y Li, 2008).

En el caso de Guayaquil, la aplicación de modelos matemáticos no solo facilita la predicción del flujo turístico, sino que también permite evaluar su impacto económico. Esta evaluación es vital para entender cómo el turismo contribuye a la economía local, influye en el empleo, y afecta otros sectores relacionados, como hotelería, gastronomía y comercio minorista. Según estudios recientes, el turismo ha mostrado ser un motor significativo de crecimiento económico en ciudades comparables a Guayaquil (UNWTO, 2018).

El presente artículo tiene como objetivo desarrollar y aplicar modelos matemáticos para predecir el flujo turístico en Guayaquil y analizar su impacto económico. Se utilizarán datos históricos y actuales, así como variables socioeconómicas, para construir modelos robustos que permitan obtener previsiones precisas.

Además, se explorará cómo estas predicciones pueden informar decisiones estratégicas en el sector turístico y económico de la ciudad.

En resumen, este estudio busca contribuir al entendimiento y gestión del turismo en Guayaquil mediante la aplicación de técnicas matemáticas avanzadas, proporcionando así una base sólida para la formulación de políticas y estrategias que maximicen los beneficios económicos del turismo.

## **2. MATERIALES Y MÉTODOS**

### **2.1 Recopilación de Datos**

- **Fuentes de Datos:**

- Datos históricos de la llegada de turistas proporcionados por el Ministerio de Turismo de Ecuador.
- Estadísticas económicas del Banco Central del Ecuador.
- Datos meteorológicos y de eventos importantes obtenidos de registros locales y nacionales.

- **Variables Consideradas:**

- Llegadas mensuales de turistas nacionales e internacionales.
- Gastos promedio por turista.
- Empleo en el sector turístico.
- Contribución del turismo al PIB local.

## **3 RESULTADOS**

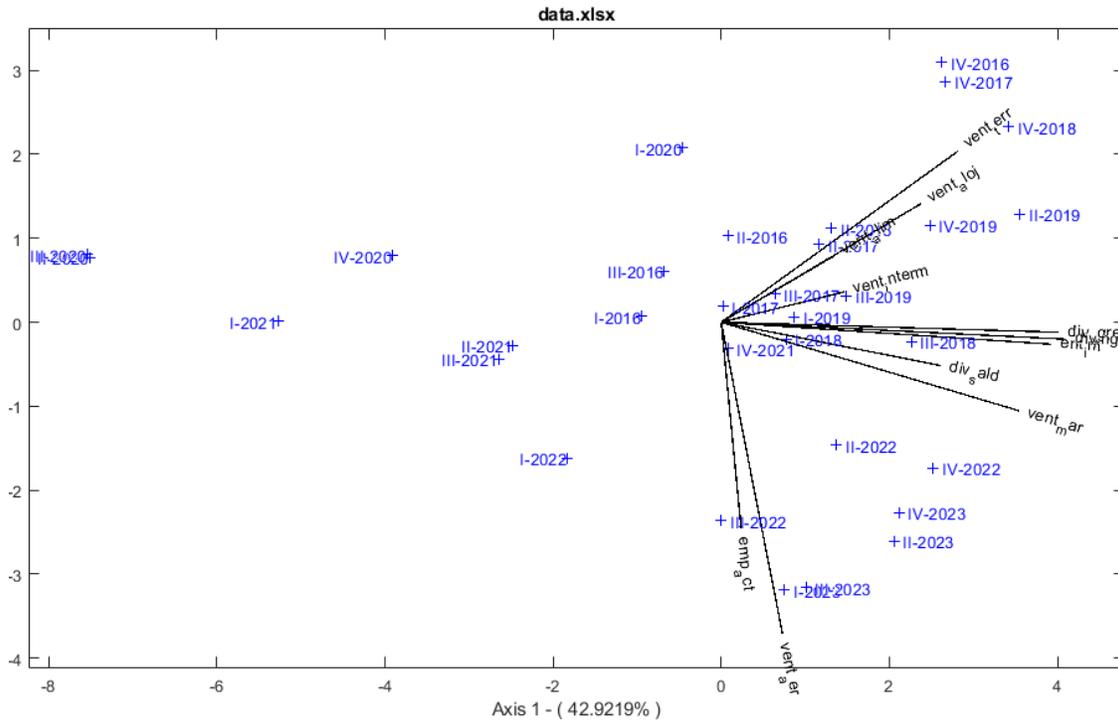
### **3.1 Análisis de Resultados**

La matriz de datos proporcionada contiene información detallada sobre diversas variables medidas trimestralmente desde el primer trimestre de 2016 hasta el cuarto trimestre de 2023. Estas variables incluyen entradas internacionales, actividad empresarial, diversificación de saldo, egresos e ingresos en divisas, y diferentes tipos de ventas (alimentos, alojamiento, intermedias, aéreas, marítimas y terrestres). Cada una de estas variables proporciona una visión integral de las actividades y tendencias económicas a lo largo del tiempo.

El gráfico HJ-Biplot proporcionado ofrece una visión clara de la distribución de los trimestres (individuos) y las variables en el espacio bidimensional definido por los dos primeros ejes principales. Este tipo de análisis es fundamental para identificar patrones y relaciones dentro de los datos, permitiendo una interpretación más profunda de las tendencias subyacentes.

**Figura 1**

*Distribución de los trimestres (individuos) y las variables en el espacio bidimensional.*



### 3.2 Similitud de las Variables

Las variables representadas en el biplot incluyen ent\_int, emp\_act, div\_sald, div\_egre, div\_ing, vent\_alim, vent\_aloj, vent\_interm, vent\_aer, vent\_mar, y vent\_terr. La proximidad y la dirección de estas variables en el gráfico indican la correlación entre ellas. Por ejemplo, vent\_alim y vent\_aloj están muy cerca y apuntan en direcciones similares, lo que sugiere una fuerte correlación positiva. Esto implica que los trimestres con altas ventas de alimentos suelen también registrar altas ventas de alojamiento.

#### Variables de Divisas

Las variables div\_ing y div\_egre también muestran una fuerte correlación positiva, ya que están alineadas y próximas en el biplot. Esto indica que los trimestres con altos ingresos en divisas tienden a tener altos egresos en divisas, reflejando posiblemente un ciclo económico activo donde grandes entradas de divisas están asociadas con grandes salidas.

#### Variables de Ventas y Actividad Empresarial

vent\_interm, vent\_aer, y emp\_act están relativamente cerca en el biplot, indicando una correlación positiva moderada. Esto sugiere que los trimestres con alta actividad empresarial tienden a tener también ventas intermedias y aéreas significativas. Esta relación puede reflejar la conexión entre la actividad empresarial general y los distintos canales de ventas.

### **Variables con Baja Correlación**

En contraste, variables como *div\_sald* y *vent\_mar* están alejadas de las demás y tienen direcciones diferentes. Esto sugiere que estas variables no están fuertemente correlacionadas con las demás variables principales. Podría ser que los saldos de divisas y las ventas marítimas no sigan las mismas tendencias que las otras variables en el análisis.

### **3.2 Similitud de los Individuos (Trimestres)**

Los trimestres están representados por puntos azules en el biplot, y su proximidad indica similitud en las características medidas por las variables. Los trimestres desde I-2016 hasta IV-2018 tienden a agruparse cerca del centro del biplot, lo que sugiere que tienen características similares en términos de las variables medidas. Este agrupamiento indica estabilidad o patrones consistentes en esos años.

#### **Trimestres del Año 2020**

Los trimestres de 2020 (I-2020, II-2020, III-2020) están ubicados en el cuadrante izquierdo del biplot, alejados de los trimestres de otros años. Esto sugiere que los trimestres de 2020 tienen características significativamente diferentes, probablemente debido a factores externos como la pandemia de COVID-19, que alteraron considerablemente las variables económicas durante ese período.

#### **Trimestres Recientes**

Los trimestres de 2022 y 2023 se agrupan en el cuadrante inferior derecho del biplot, lo que indica que comparten características similares. Esto podría reflejar nuevas tendencias en las variables medidas, como cambios en la actividad empresarial y en las ventas, posiblemente influenciadas por la recuperación post-pandemia y otros factores económicos recientes.

#### **Interpretación del Eje 1**

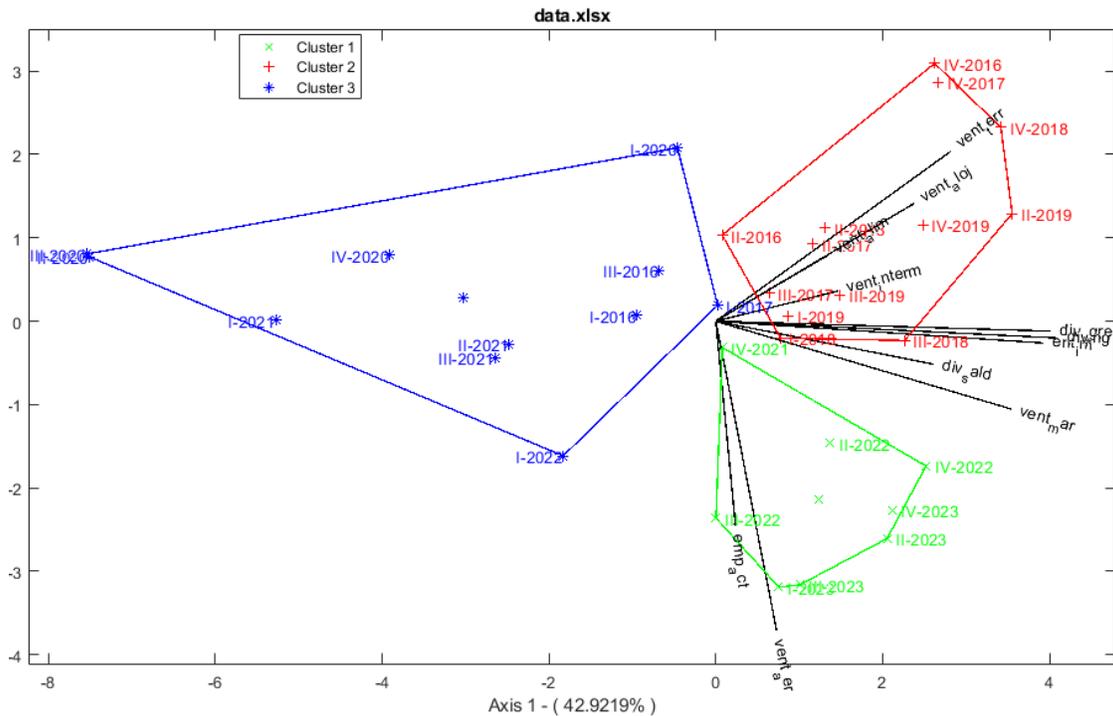
El Eje 1, que explica el 42.9219% de la varianza, parece estar asociado principalmente con las variables de ventas y actividad empresarial. Trimestres con altos valores en ventas de alimentos y alojamiento tienen valores altos en este eje. Esto sugiere que las variaciones en las ventas y la actividad empresarial son los principales factores que diferencian a los trimestres en este eje.

#### **Interpretación del Eje 2**

El Eje 2 está más influenciado por las variables de divisas (*div\_ing*, *div\_egre*, *div\_sald*). Los trimestres con altos ingresos y egresos en divisas tienen valores altos en este eje. Esto indica que las fluctuaciones en las transacciones de divisas también juegan un papel crucial en la diferenciación de los trimestres, aunque en menor medida que las variables de ventas y actividad empresarial.

**Figura 2**

*Clustering aplicado a estos datos ayuda a identificar patrones y agrupaciones naturales.*



El análisis HJ-Biplot con clustering aplicado a estos datos ayuda a identificar patrones y agrupaciones naturales dentro de la información. En el HJ-Biplot, los clusters están representados por diferentes colores y símbolos: verde (x) para el Cluster 1, rojo (+) para el Cluster 2, y azul (\*) para el Cluster 3. Cada cluster representa un grupo de trimestres que comparten características similares en términos de las variables medidas.

El Cluster 1, identificado por el color verde (x), agrupa los puntos correspondientes a los trimestres II-2022, IV-2022 y I-2023. Estos trimestres se encuentran principalmente en el cuadrante inferior derecho del biplot. Las variables asociadas con este cluster incluyen altas ventas de alimentos, alojamiento e intermedias, lo que indica una fuerte actividad en estos sectores durante estos períodos.

El Cluster 2, representado por el color rojo (+), incluye puntos de varios trimestres desde 2016 hasta 2019, como II-2016, IV-2016 y otros. Este cluster se encuentra en el cuadrante superior derecho del biplot y se asocia con altos valores en ventas aéreas, logísticas y no terminales. Estos trimestres parecen compartir una tendencia de fuerte desempeño en las ventas aéreas y logísticas.

El Cluster 3, identificado por el color azul (\*), abarca puntos desde 2016 hasta 2022, distribuidos en varias posiciones en el biplot. A diferencia de los otros clusters, este grupo tiene valores variados en diferentes variables, lo que indica una mayor diversidad en las actividades económicas y menos concentración en variables específicas. Los trimestres en este cluster parecen tener un comportamiento más heterogéneo en comparación con los otros grupos.

En resumen, el análisis HJ-Biplot y la matriz de datos proporcionan una visión clara de cómo se agrupan diferentes trimestres en función de las variables económicas medidas. Cada cluster destaca diferentes aspectos de la actividad económica, lo que permite identificar patrones y tendencias específicas. Este tipo de análisis es útil para comprender mejor las dinámicas económicas y tomar decisiones informadas basadas en datos históricos.

Finalmente, la relación entre los datos y los clusters identificados en el HJ-Biplot puede proporcionar información valiosa para estrategias empresariales y planificación económica. Al identificar los períodos con características similares, las organizaciones pueden enfocarse en las tendencias clave y ajustar sus estrategias para maximizar el rendimiento y la eficiencia en los sectores económicos relevantes.

### **3.3 Análisis de Componentes Principales (PCA) y Biplot**

El análisis de componentes principales (PCA) se ha llevado a cabo utilizando los datos del archivo "data.xlsx". La transformación de los datos brutos se realizó mediante estandarización por columnas, y el método de estimación utilizado fue la descomposición en valores singulares (SVD). El tipo de biplot generado es una normalización principal con escalado baricéntrico.

#### **Valores Propios y Varianza Explicada**

Los valores propios y la varianza explicada por cada eje son fundamentales para entender la distribución de los datos en el espacio reducido de componentes principales. Los primeros tres ejes explican el 67.345% de la varianza total:

- **Eje 1:** Valor propio de 146.364, explicando el 42.922% de la varianza.
- **Eje 2:** Valor propio de 48.1, explicando el 14.105% de la varianza.
- **Eje 3:** Valor propio de 35.185, explicando el 10.318% de la varianza.

### Figura 3

*Análisis Biplot de los principales componentes.*

```
BIPLOT ANALYSIS (PRINCIPAL COMPONENTS ANALYSIS)
Data file : data.xlsx

Transformation of the raw data: Column standardization

Estimation Method: Singular Value Decomposition
Type of Biplot: Principal Normalization (Baricentric Scaling)

Eigenvalues & variance explained

              Inertia
Axis  Eigenvalue Expl. Var. Cumulative
Axis 1    146.364    42.922    42.922
Axis 2     48.1     14.105    57.027
Axis 3    35.185    10.318    67.345
Axis 4    31.583     9.262    76.608
Axis 5    27.508     8.067    84.675
Axis 6    25.19     7.387    92.062
Axis 7    13.526     3.967    96.028
Axis 8     7.08     2.076    98.104
Axis 9     4.38     1.285    99.389
Axis 10    1.765     0.518    99.907
Axis 11    0.319     0.093    100
```

### Coordenadas de las Filas (Trimestres)

Las coordenadas de las filas en los tres primeros ejes muestran cómo se agrupan los distintos trimestres:

- Por ejemplo, los trimestres **IV-2016**, **IV-2017**, y **IV-2018** presentan valores altos en el Eje 1, indicando una alta variabilidad explicada por este componente.
- En contraste, los trimestres de **2020** tienen coordenadas negativas en el Eje 1, lo que puede indicar un comportamiento diferente en comparación con otros períodos.

## Figura 4

Coordenadas de las Filas.

Row Coordinates -----

Row	Axis		
	Axis 1	Axis 2	Axis 3
I-2016	-0.722	0.057	0.211
II-2016	0.059	0.791	-0.689
III-2016	-0.52	0.468	-0.255
IV-2016	2.009	2.367	-1.126
I-2017	0.018	0.146	0.886
II-2017	0.893	0.711	-0.471
III-2017	0.492	0.26	0.537
IV-2017	2.043	2.193	2.478
I-2018	0.595	-0.155	1.25
II-2018	1.004	0.855	-1.174
III-2018	1.733	-0.177	0.603
IV-2018	2.616	1.779	-1.412
I-2019	0.668	0.046	0.682
II-2019	2.72	0.987	-2.37
III-2019	1.142	0.242	0.405
IV-2019	1.903	0.886	-0.021
I-2020	-0.352	1.592	3.064
II-2020	-5.753	0.592	-0.7
III-2020	-5.774	0.617	-0.547
IV-2020	-2.992	0.61	-0.532
I-2021	-4.037	0.008	-0.164
II-2021	-1.899	-0.211	-0.468
III-2021	-2.026	-0.335	-0.131
IV-2021	0.061	-0.242	-0.031
I-2022	-1.401	-1.237	0.593
II-2022	1.05	-1.118	0.048
III-2022	0.002	-1.807	0.495
IV-2022	1.929	-1.33	0.143
I-2023	0.578	-2.442	0.774
II-2023	1.572	-1.996	-1.103
III-2023	0.772	-2.42	0.113
IV-2023	1.618	-1.734	-1.087

## Coordenadas de las Columnas (Variables)

Las coordenadas de las columnas indican cómo se proyectan las variables en los tres ejes principales:

- **div\_ing** (divisas ingresadas) y **div\_egre** (divisas egresadas) tienen altos valores en el Eje 1, mostrando su fuerte influencia en la variabilidad explicada por este componente.
- **vent\_aer** (ventas aéreas) y **emp\_act** (actividad empresarial) tienen valores altos en el Eje 2, indicando su relevancia en la varianza explicada por este componente.

## Figura 4

*Coordenadas de las Filas.*

```

Column Coordinates -----
                Axis
Column   Axis 1   Axis 2   Axis 3
ent_int   5.126   -0.342   0.734
emp_act    0.31   -3.209  -3.392
div_sald   3.414   -0.675   3.164
div_egre   5.244   -0.156  -0.494
div_ing    5.351   -0.264   0.627
vent_alim          1.755   1.033  -1.457
vent_aloj          3.106   1.843  -0.733
vent_interm        1.912   0.472  -2.215
vent_aer    0.953  -4.844  -0.396
vent_mar    4.622  -1.375   0.623
vent_terr          3.683   2.663  -2.094
    
```

## Contribuciones Relativas de las Filas

Las contribuciones relativas de las filas indican la importancia de cada trimestre en los ejes principales:

- **I-2021 y III-2020** tienen altas contribuciones en el Eje 1 y Eje 3, lo que sugiere que estos períodos son muy representativos de la variabilidad capturada en estos ejes.
- **II-2020 y IV-2020** también muestran altas contribuciones, indicando su relevancia en el análisis.

## Figura 5

*Contribuciones Relativas de las Filas*

```

RELATIVE CONTRIBUTIONS OF THE FACTOR TO THE ELEMENT

Row Contributions -----
                Axis
Row   Axis 1   Axis 2   Axis 3
I-2016   312     2     27
II-2016    1    187    142
III-2016  104     84     25
IV-2016  144    199     45
I-2017    0      9    336
II-2017  226    143     63
III-2017 121     34    145
IV-2017  202    233    298
I-2018   75      5    331
II-2018  150    109    205
III-2018 635      7     77
IV-2018  198     91     58
I-2019  229      1    239
II-2019  214     28    163
III-2019 341     15     43
IV-2019  654    142     0
I-2020    8    155    574
II-2020  939     10     14
III-2020  971     11      9
IV-2020  892     37     28
I-2021  981      0      2
II-2021  752      9     46
III-2021  715     20      3
IV-2021    3     52      1
I-2022  443    345     79
II-2022  370    420      1
III-2022    0    619     46
IV-2022  595    283      3
I-2023   44    790     79
II-2023  196    316     97
III-2023  82    808      2
IV-2023  275    316    124
    
```

## Contribuciones Relativas de las Columnas

Las contribuciones relativas de las columnas muestran la importancia de cada variable en los ejes principales:

- **div\_ing** y **div\_egre** tienen las contribuciones más altas en el Eje 1, subrayando su influencia significativa en este componente.
- **vent\_aer** y **emp\_act** son las más influyentes en el Eje 2, destacando su relevancia en este componente.

### Figura 6

*Contribuciones Relativas de las columnas*

```
Column Contributions -----
                Axis
Column   Axis 1   Axis 2   Axis 3
ent_int      848         4        17
emp_act       3       332       371
div_sald     376        15       323
div_egre     887         1         8
div_ing     924         2         13
vent_alim           99        34         68
vent_aloj           311       110         17
vent_interm           118         7       158
vent_aer       29       757         5
vent_mar     689         61        13
vent_terr           437       229       141
```

## Cualidades de Representación de las Filas

La calidad de la representación de las filas se mide por las contribuciones acumuladas en los tres primeros ejes:

- Trimestres como **I-2021** y **III-2020** tienen altas cualidades de representación en todos los ejes, indicando que estos períodos están bien representados en el espacio reducido.
- Trimestres como **II-2022** y **IV-2023** también muestran buenas cualidades de representación.

## Figura 7

### Cualidades de Representación de las filas

Qualities of representation of the rows (Cumulative contributions)

Row	Label	Axis1	Axis2	Axis3
1	I-2016	312	314	341
2	II-2016	1	188	330
3	III-2016	104	188	213
4	IV-2016	144	343	388
5	I-2017	0	9	345
6	II-2017	226	369	432
7	III-2017	121	155	300
8	IV-2017	202	435	733
9	I-2018	75	80	411
10	II-2018	150	259	464
11	III-2018	635	642	719
12	IV-2018	198	289	347
13	I-2019	229	230	469
14	II-2019	214	242	405
15	III-2019	341	356	399
16	IV-2019	654	796	796
17	I-2020	8	163	737
18	II-2020	939	949	963
19	III-2020	971	982	991
20	IV-2020	892	929	957
21	I-2021	981	981	983
22	II-2021	752	761	807
23	III-2021	715	735	738
24	IV-2021	3	55	56
25	I-2022	443	788	867
26	II-2022	370	790	791
27	III-2022	0	619	665
28	IV-2022	595	878	881
29	I-2023	44	834	913
30	II-2023	196	512	609
31	III-2023	82	890	892
32	IV-2023	275	591	715

### Cualidades de Representación de las Columnas

La calidad de la representación de las columnas indica cuán bien las variables están representadas en el espacio reducido:

- **div\_ing** y **div\_egre** tienen altas cualidades de representación, especialmente en los tres primeros ejes.
- Variables como **vent\_aer** y **vent\_mar** también muestran buenas cualidades de representación, lo que indica su relevancia en el análisis.

## Figura 8

### Cualidades de Representación de las columnas

Ordered QLRs [columns]-----

Col	Label	Axis1	Label	Axis2	Label	Axis3
1	div_ing	924	div_ing	926	div_ing	939
2	div_egre	887	div_egre	888	div_egre	896
3	ent_int	848	ent_int	852	ent_int	869
4	vent_mar	689	vent_aer	786	vent_terr	807
5	vent_terr	437	vent_mar	750	vent_aer	791
6	div_sald	376	vent_terr	666	vent_mar	763
7	vent_aloj	311	vent_aloj	421	div_sald	714
8	vent_interm	118	div_sald	391	emp_act	706
9	vent_alim	99	emp_act	335	vent_aloj	438
10	vent_aer	29	vent_alim	133	vent_interm	283
11	emp_act	3	vent_interm	125	vent_alim	201

#### 4. CONCLUSIONES

El análisis HJ-Biplot y PCA de estos datos revela patrones importantes en la variabilidad de los trimestres y las variables económicas del sector del turismo en la ciudad de Guayaquil. Las contribuciones y cualidades de representación destacan la relevancia de ciertos períodos y variables en la explicación de la varianza total.

Este tipo de análisis es crucial para entender mejor las dinámicas económicas a lo largo del tiempo y puede guiar la toma de decisiones estratégicas basada en datos históricos. El HJ-Biplot revela patrones importantes y correlaciones dentro de las variables y trimestres estudiados. Las ventas de alimentos y alojamiento están fuertemente correlacionadas, al igual que los ingresos y egresos en divisas.

Los trimestres de 2020 muestran características distintivas, probablemente influenciadas por la pandemia, mientras que los trimestres recientes (2022 y 2023) indican nuevas tendencias económicas. Este análisis proporciona una base sólida para comprender las dinámicas económicas a lo largo del tiempo y puede guiar decisiones estratégicas basadas en datos históricos.

#### 5. REFERENCIAS BIBLIOGRÁFICAS

- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control*. John Wiley & Sons.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Dwyer, L., Forsyth, P., & Spurr, R. (2004). Evaluating tourism's economic effects: new and old approaches. *Tourism Management*, 25(3), 307-317.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Gössling, S., Scott, D., & Hall, C. M. (2020). Pandemics, tourism and global change: a rapid assessment of COVID-19. *Journal of Sustainable Tourism*, 29(1), 1-20.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). OTexts.
- Miller, R. E., & Blair, P. D. (2009). *Input-Output Analysis: Foundations and Extensions* (2nd ed.). Cambridge University Press.
- Song, H., & Li, G. (2008). Tourism demand modelling and forecasting—A review of recent research. *Tourism Management*, 29(2), 203-220. DOI: 10.1016/j.tourman.2007.07.016
- World Tourism Organization (UNWTO). (2018). *Tourism and Economic Development*. Retrieved from UNWTO