



# CTSCAFE PARA CIUDADANOS.....

<http://www.ctscafe.pe>

ISSN 2521-8093



**REVISTA DE INVESTIGACIÓN MULTIDISCIPLINARIA**



<http://www.ctscafe.pe>

Volumen IX- N° 25 Marzo 2025

ISSN 2521-8093

2



## Distribuciones multimodales en el cálculo de las velocidades de camiones mineros: selección de moda para una representación rigurosa

Ing. Luis Flores Maza

Universidad Nacional de Ingeniería

Correo Electrónico: luis.flores.m@uni.pe

Ing. Eder Michel De La Cruz Olivares

Universidad Nacional de Ingeniería

Correo Electrónico: ingederminas2012@gmail.com

Recibido: 15 Noviembre 2024    Aceptado: 03 Marzo 2025



**Resumen:** El objetivo de este trabajo es realizar un análisis exhaustivo de los perfiles de velocidad de los camiones mineros, calculados a partir de datos recopilados por el sistema de despacho de la flota de camiones de una mina ubicada al Sur del Perú. Se busca identificar la causa detrás de la caída del valor de la moda estadística. Esta disminución contrasta con las tendencias de otras medidas (i.e. La media y la mediana). El procedimiento implicó un análisis detallado de las velocidades, clasificadas por el estado de los camiones (i.e. cargado o vacío) y separadas por su gradiente, lo que permitió observar la formación de distribuciones multimodales. La selección de una moda más congruente con otras medidas se llevó a cabo, desarrollando códigos en Python y analizando las gráficas y los resultados a través de Microsoft Excel. Este estudio se centró en el mes de febrero (época de lluvias) y en la condición de los camiones en estado "cargado". El análisis busca desentrañar las razones subyacentes detrás de la caída en la moda y presentar una metodología efectiva para elegir la moda más representativa en un conjunto de datos.

**Palabras claves:** Moda estadística/ Perfil de velocidad/ Flota de camiones/ Minería/ Programación.

**Abstract :** The objective of this work is to carry out an exhaustive analysis of the speed profiles of mining trucks, calculated from data collected by the truck fleet dispatch system of a mine located in southern Peru. It seeks to identify the cause behind the fall in the value of a statistical measure, specifically the mode. This decrease contrasted with the trends of other measures (i.e. the mean and median). The procedure implied a detailed analysis of the speeds, classified by the state of the trucks (i.e. loaded or empty) and separated by their gradient, which allowed observing the formation of multimodal distributions. The selection of a more congruent mode with other measures was carried out, developing codes in Python and analyzing the graphs and results through Microsoft Excel. This study focused on the month of February (rainy season) and on the condition of the trucks in the "Loaded" state. The analysis seeks to unravel the underlying reasons behind the drop in mode and to present an effective methodology for choosing the most representative mode in a complex and varied data set.

**Keywords:** Statistical Mode/ Velocity Profile/ Truck Fleet/ Mining/ Programming.

**Résumé :** L'objectif de ce travail est de réaliser une analyse complète des profils de vitesse des camions miniers, calculés à partir des données collectées par le système de répartition. flotte de camions d'une mine située au sud du Pérou. Il cherche à identifier la cause de la baisse de la valeur du mode statistique. Cette diminution contraste avec les tendances d'autres mesures (c'est-à-dire la moyenne et la médiane). La procédure a impliqué une analyse détaillée des vitesses, classées selon l'état des camions (c'est-à-dire chargés ou vides) et séparées par leur pente, ce qui a permis d'observer la formation de distributions multimodales. La sélection d'un mode plus conforme aux autres mesures a été réalisée en développant des codes en Python et en analysant les graphiques et les résultats via Microsoft Excel. Cette étude s'est concentrée sur le mois de février (saison des pluies) et l'état descamions en statut "Chargé". L'analyse cherche à découvrir les raisons sous-jacentes du déclin de la mode et à présenter une méthodologie efficace pour choisir la mode la plus représentative dans un ensemble de données.

**Mots-clés:** Mode statistique/Profil de vitesse/Flotte de camions/Exploitation minière/Programmation.

## 1. Introducción

En la actualidad, las operaciones mineras buscan optimizar al *máximo los* recursos empleados en la producción. El transporte de materiales es uno de los factores críticos en el ciclo productivo debido a los costos asociados a esta actividad. Por esta razón, es esencial comprender el comportamiento de la flota de camiones mineros a lo largo de su ruta, especialmente en diferentes pendientes y estados (cargados o vacíos). En muchas operaciones mineras, comprender el perfil de velocidades generado por los camiones mineros es de suma importancia. Sin embargo, en algunos casos, se ha observado que la medida de la moda no se alinea adecuadamente con la media y la mediana. Por lo tanto, en este estudio, se busca analizar minuciosamente este fenómeno y encontrar una explicación.

El análisis exhaustivo se centra en las velocidades de los camiones mineros, que se dividen en categorías según sus gradientes en intervalos de -12% a 12%. Estos datos se registran en diferentes archivos para evaluar el comportamiento de las velocidades según el estado de carga. Se ha observado que en todos los casos se generan distribuciones multimodales. Para abordar este desafío, se ha desarrollado un algoritmo en Python que busca determinar una moda más representativa entre las diversas modas identificadas.

## 2. Material y métodos

El algoritmo presentado en este trabajo fue desarrollado en el lenguaje de programación Python 3.0 debido a la facilidad que brinda trabajar en este lenguaje. El entorno de ejecución utilizado fue Google Colaboratory, y el análisis de los resultados se realizó en Microsoft Excel. Las principales bibliotecas utilizadas incluyeron Pandas, Matplotlib, Pyplot, Math y Numpy.

En cuanto al equipo utilizado para ejecutar el algoritmo, este cuenta con las siguientes especificaciones: procesador Intel Core i5 de 8ª generación con una velocidad de 2.90 GHz y una memoria RAM de 8 GB.

El algoritmo desarrollado en el lenguaje Python para calcular velocidades y obtener los resultados deseados demostró una alta eficiencia al manejar grandes volúmenes de datos. No obstante,

es importante señalar que la capacidad de la memoria RAM (8 GB) representa una limitación técnica para analizar el 100% de los datos y obtener los resultados.

A continuación, se detallará la metodología aplicada en la presente investigación.

## 2.1. Cálculo de los perfiles de velocidad

```
from google.colab import drive
```

```
drive.mount('/content/drive')
```

```
import pandas as pd
```

```
def procesar_archivo():
```

```
mes = input("Por favor, introduce el mes: ")
```

```
link = input("Introduce la ruta del archivo: ")
```

```
30 df = pd.read_csv(link, delimiter=';', header=0)
```

```
xcoor = df['xcoor']
```

```
ycoor = df['ycoor']
```

```
tonelaje = df['tonelaje']
```

```
incl_pitch = df['incl_pitch']
```

```
for i, elemento in enumerate(xcoor):
```

```
elemento = elemento.replace("{", "")
```

```
elemento = elemento.replace("}", "")
```

```
xcoor.at[i] = elemento
```

```
for i, elemento in enumerate(ycoor):
```

```
elemento = elemento.replace("{", "")
```

```
elemento = elemento.replace("}", "")
```

```
ycoor.at[i] = elemento
```

```
for i, elemento in enumerate(tonelaje):
```

```
elemento = elemento.replace("{", "")
```

```
elemento = elemento.replace("}", "")
```

```
tonelaje.at[i] = elemento
```

```
for i, elemento in enumerate(incl_pitch):
```

```
    elemento = elemento.replace("{", "")
```

```
    elemento = elemento.replace("}", "")
```

```
    incl_pitch.at[i] = elemento
```

```
elemento=0
```

```
import math
```

```
porc=1
```

```
total=xcoor.shape[0]*porc
```

```
total=math.ceil(total)
```

```
print(total)
```

```
xcoor = xcoor.iloc[0:total]
```

```
ycoor = ycoor.iloc[0:total]
```

```
tonelaje = tonelaje.iloc[0:total]
```

```
incl_pitch = incl_pitch.iloc[0:total]
```

```
xcoor= xcoor.str.split(',', expand=True)
```

```
ycoor= ycoor.str.split(',', expand=True)
```

```
tonelaje = tonelaje.str.split(',', expand=True)
```

```
incl_pitch = incl_pitch.str.split(',', expand=True)
```

```
xcoor=pd.DataFrame(xcoor.values.reshape(xcoor.values.shape[0]*xcoor.values.shape[1],1),-  
columns=['xcoor'])
```

```
ycoor=pd.DataFrame(ycoor.values.reshape(ycoor.values.shape[0]*ycoor.values.shape[1],1),-  
columns=['ycoor'])
```

```
tonelaje=pd.DataFrame(tonelaje.values.reshape(tonelaje.values.shape[0]*tonelaje.values.sha-  
pe[1],1),columns=['tonelaje'])
```

```
incl_pitch=pd.DataFrame(incl_pitch.values.reshape(incl_pitch.values.shape[0]*incl_pitch.va-  
lues.shape[1],1),columns=['incl_pitch'])
```

```
xcoor=pd.to_numeric(xcoor['xcoor'],errors='coerce')
```

```
ycoor=pd.to_numeric(ycoor['ycoor'],errors='coerce')
incl_pitch=pd.to_numeric(incl_pitch['incl_pitch'],errors='coerce')
```

```
xcoor=pd.DataFrame(xcoor,columns=['xcoor'])
ycoor=pd.DataFrame(ycoor,columns=['ycoor'])
incl_pitch=pd.DataFrame(incl_pitch,columns=['incl_pitch'])
```

```
xcoor['xcoor']=xcoor['xcoor']/100
ycoor['ycoor']=ycoor['ycoor']/100
incl_pitch['incl_pitch']=incl_pitch['incl_pitch']/100
```

```
xcoor=xcoor.fillna(-80)
ycoor=ycoor.fillna(-80)
incl_pitch=incl_pitch.fillna(-80)
```

**32**

```
import math
```

```
import numpy as np
```

```
valores = incl_pitch['incl_pitch'].values * (math.pi / 180)
valores = np.tan(valores) * 100
data2 = pd.DataFrame(valores, columns=['incl_pitch_%'])
print(data2)
```

```
xcoor_matriz = xcoor['xcoor'].to_numpy()
ycoor_matriz=ycoor['ycoor'].to_numpy()
tonelaje_matriz = tonelaje['tonelaje'].to_numpy()
incl_pitch_matriz = incl_pitch['incl_pitch'].to_numpy()
incl_pitch_por_matriz = data2['incl_pitch_%'].to_numpy()
```

```
xcoor_matriz=xcoor_matriz.reshape(xcoor.shape[0]//1800,1800)
ycoor_matriz=ycoor_matriz.reshape(ycoor.shape[0]//1800,1800)
tonelaje_matriz=tonelaje_matriz.reshape(tonelaje_matriz.shape[0]//1800,1800)
incl_pitch_matriz=incl_pitch_matriz.reshape(incl_pitch.shape[0]//1800,1800)
```

```
incl_pitch_por_matriz=incl_pitch_por_matriz.reshape(incl_pitch.shape[0]//1800,1800)

long=(xcoor_matriz.shape[1]-1)*xcoor_matriz.shape[0]
velocidades=np.zeros(long)
velocidades=velocidades.reshape(1799,long//1799)
gradientes=np.zeros(long)
gradientes=gradientes.reshape(1799,long//1799)
estado=np.zeros(long)
estado=estado.reshape(1799,long//1799)
m=0
n=xcoor_matriz.shape[1]-1
k=xcoor_matriz.shape[0]

for i in range(m,n):
    d=((xcoor_matriz.T[i]-xcoor_matriz.T[i+1])**2+(ycoor_matriz.T[i]-
    ycoor_matriz.T[i+1])**2)**(0.5)
    v=(d/np.cos(incl_pitch_matriz.T[i]*math.pi/180))*0.5*3.6
    velocidades[i]=v
    ton_bool=tonelaje_matriz.T[i]=="0"
    estado[i]=ton_bool
    incl=np.zeros(k)
    x=incl_pitch_por_matriz.T[i]
    incl_bool=np.ceil(x)-x>=x-np.floor(x)
    for j in range(0,k):
        if incl_bool[j]==True:
            incl[j]=np.floor(x[j])
        else:
            incl[j]=np.ceil(x[j])
    gradientes[i]=incl

velocidades=velocidades.T.reshape(long,1)
gradientes=gradientes.T.reshape(long,1)
```

```

estado=estado.T.reshape(long,1)
df_v=pd.DataFrame(velocidades,columns=['velocidad'])
df_g=pd.DataFrame(gradientes,columns=['gradiente'])
df_e=pd.DataFrame(estado,columns=['estado'])
data=pd.concat([df_v,df_g,df_e],axis=1)
data
    
```

```
print(data)
```

```

data_vacia=data.loc[(data['estado']==True)]
data_cargado=data.loc[(data['estado']==False)]
    
```

**34**

```

lista_gradientes=[]
for i in range(-12,13):
    lista_gradientes.append(i)

v_media=[]
v_moda=[]
v_mediana=[]
for i in lista_gradientes:
    df_g=data_cargado.loc[(data_cargado['gradiente']==i)]
    df_g=df_g.loc[(df_g['velocidad']>=10)]
    df_g=df_g.loc[(df_g['velocidad']<=65)]
    v_media_g=round(df_g['velocidad'].mean(),2)
    v_mediana_g=round(df_g['velocidad'].median(),2)
    v_moda_g=round(df_g['velocidad'].mode()[0],2)
    v_media.append(v_media_g)
    v_mediana.append(v_mediana_g)
    v_moda.append(v_moda_g)

dicc = {
    "gradientes": lista_gradientes,
    
```

```

"v_media": v_media,
"v_moda":v_moda,
"v_mediana":v_mediana
}
df=pd.DataFrame(dicc)
print(df)
df.to_excel(f"{mes}100_v_cargado.xlsx",index=False)
v_media=[]
v_moda=[]
v_mediana=[]
for i in lista_gradientes:
df_g=data_vacia.loc[(data_vacia['gradiente']==i)
df_g=df_g.loc[(df_g['velocidad']>=10]
df_g=df_g.loc[(df_g['velocidad']<=65]
v_media_g=round(df_g['velocidad'].mean(),2)
v_mediana_g=round(df_g['velocidad'].median(),2)
v_moda_g=round(df_g['velocidad'].mode()[0],2)
v_media.append(v_media_g)
v_mediana.append(v_mediana_g)
v_moda.append(v_moda_g)
dicc = {
"gradientes": lista_gradientes,
"v_media": v_media,
"v_moda":v_moda,
"v_mediana":v_mediana
}
df=pd.DataFrame(dicc)
print(df)

df.to_excel(f"{mes}100_v_vacia.xlsx",index=False)

procesar_archivo()

```

**Resultados perfiles de velocidad: Mes febrero**

Para camiones en estado “cargados”

Para camiones en estado vacíos”

**Tabla N° 1:** Camiones cargados.

**Tabla N° 2:** Camiones vacíos

| gradientes | v_media | v_moda | v_mediana |
|------------|---------|--------|-----------|
| -12        | 22.04   | 10.67  | 22.43     |
| -11        | 21.76   | 10.65  | 22.13     |
| -10        | 22.37   | 11.31  | 22.21     |
| -9         | 23.58   | 22.14  | 22.6      |
| -8         | 24.1    | 23.56  | 22.75     |
| -7         | 23.88   | 19.94  | 22.7      |
| -6         | 23.86   | 22.86  | 22.6      |
| -5         | 24.06   | 10.46  | 22.48     |
| -4         | 24.09   | 10.52  | 21.95     |
| -3         | 23.67   | 10.52  | 21.01     |
| -2         | 23.28   | 11.25  | 20.67     |
| -1         | 23.46   | 11.25  | 20.82     |
| 0          | 22.6    | 11.25  | 21.19     |
| 1          | 24.42   | 12.06  | 22.06     |
| 2          | 24.34   | 13.01  | 22.23     |
| 3          | 23.89   | 13.26  | 21.83     |
| 4          | 23.09   | 10.95  | 21        |
| 5          | 22.81   | 11.5   | 20.87     |
| 6          | 22.29   | 11.27  | 20.6      |
| 7          | 21      | 11.28  | 18.72     |
| 8          | 19.44   | 11.29  | 16.65     |
| 9          | 18.77   | 10.85  | 16.12     |
| 10         | 18.82   | 11.31  | 16.26     |
| 11         | 19.31   | 10.14  | 16.5      |
| 12         | 20.09   | 10.06  | 16.73     |

| gradientes | v_media | v_moda | v_mediana |
|------------|---------|--------|-----------|
| -12        | 26.97   | 22.76  | 25.88     |
| -11        | 26.94   | 12.92  | 26.32     |
| -10        | 26.98   | 26.52  | 26.46     |
| -9         | 26.97   | 10.41  | 26.5      |
| -8         | 26.96   | 11.91  | 26.33     |
| -7         | 26.63   | 10.61  | 25.65     |
| -6         | 26.39   | 12.09  | 25.12     |
| -5         | 26.44   | 13.02  | 25.04     |
| -4         | 26.34   | 11.33  | 24.82     |
| -3         | 26.43   | 10.84  | 25.08     |
| -2         | 26.61   | 20.97  | 25.31     |
| -1         | 26.72   | 25.99  | 25.51     |
| 0          | 27.37   | 26.56  | 26.44     |
| 1          | 26.85   | 24.72  | 25.63     |
| 2          | 26.84   | 13.5   | 25.61     |
| 3          | 26.98   | 12.92  | 25.69     |
| 4          | 27.38   | 12.04  | 26.63     |
| 5          | 27.81   | 21.05  | 27.3      |
| 6          | 27.83   | 26.6   | 27.21     |
| 7          | 27.65   | 13.29  | 26.97     |
| 8          | 27.36   | 12.88  | 26.7      |
| 9          | 27.15   | 25.82  | 26.26     |
| 10         | 27.17   | 11.98  | 26.19     |
| 11         | 27.68   | 11.76  | 27.16     |
| 12         | 27.7    | 24.5   | 27.54     |

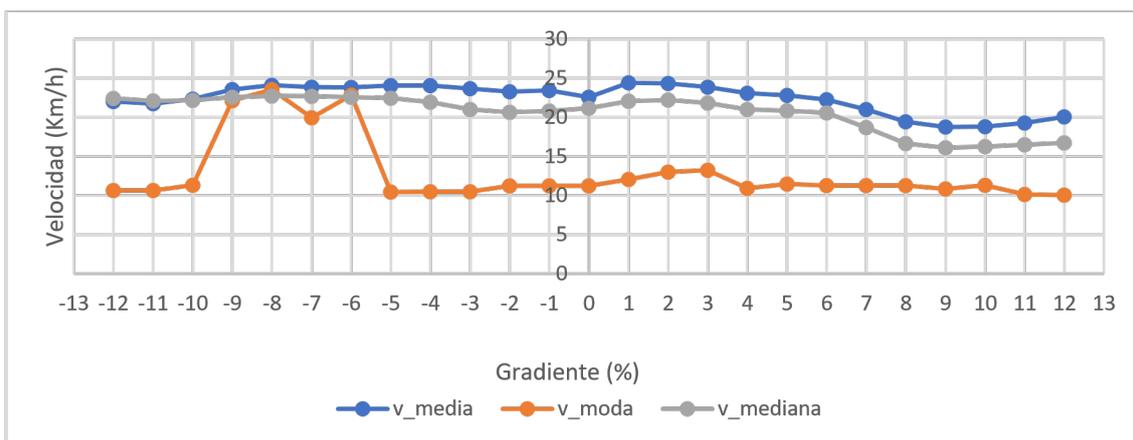
Fuente: Elaboración propia

Fuente: Elaboración propia

Gráficos de los perfiles de velocidad: Mes febrero

Para camiones en estado “cargados”

**Gráfica N° 1: Velocidades de camiones en estado cargado**

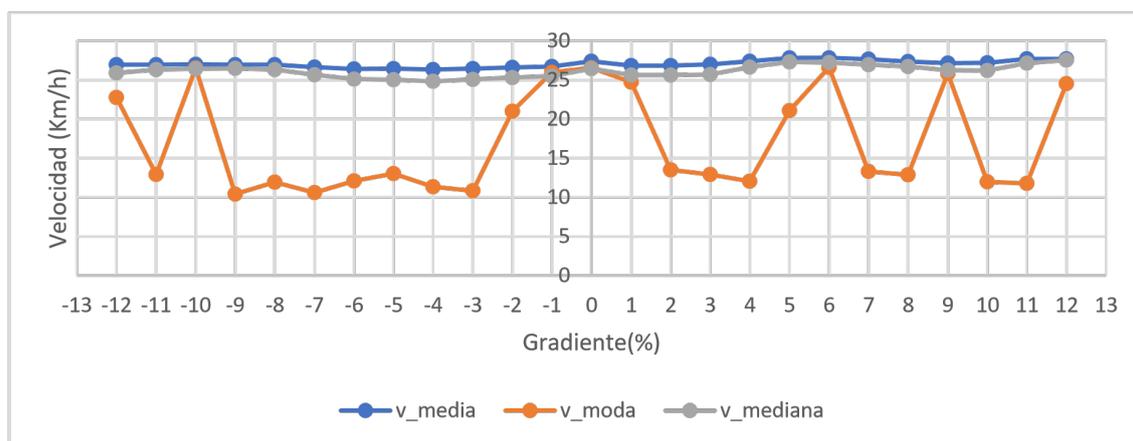


*Grafica 1: Velocidades de camiones en estado cargado*

**Fuente:** Elaboración propia

Para camiones en estado “vacío”

**Gráfica N° 2: Velocidades de camiones en estado vacío**



*Grafica2: Velocidades de camiones en estado vacío*

**Fuente:** Elaboración propia

A través de los gráficos presentados previamente, se puede apreciar que las medidas estadísticas de la Media y la Mediana mantienen un patrón consistente entre sí. Sin embargo, resulta evidente que la medida estadística de la Moda exhibe una variabilidad considerable, lo que nos conduce a realizar un análisis más detallado en relación con esta métrica. La naturaleza irregular de la Moda demanda un enfoque exhaustivo con el fin de identificar las posibles explicaciones subyacentes, y en última instancia, abordar esta variabilidad para obtener un valor que represente a dicha variable.

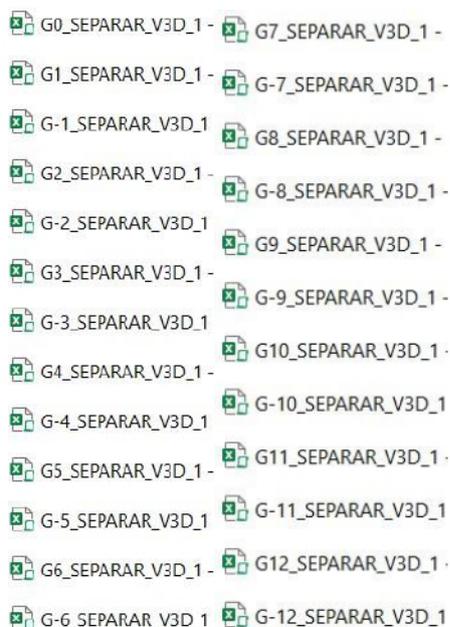
## 2.2. Análisis de las velocidades

### PASO 1

Con el fin de optimizar el análisis del perfil de velocidad presentado anteriormente, se requiere realizar modificaciones y ajustes para obtener una evaluación más precisa de las velocidades involucradas. El objetivo es lograr un enfoque más refinado en el análisis de las velocidades, lo que permitirá obtener resultados más robustos y esclarecedores.

La modificación de la metodología se traducirá en la generación de un archivo Excel que contendrá un exhaustivo registro de todas las velocidades y sus respectivos estados, es decir, si se encontraban cargados o vacíos. Esta transformación en la presentación de los datos servirá para proporcionar una visualización más concisa y detallada de las velocidades en relación con su estado. Así mismo, para un mejor manejo de los datos se separará por gradiente de -12% a 12%.

**Figura N° 1:** Velocidades separadas por gradientes



Fuente: Elaboración propia

### PASO 2

Se inicia el análisis con las velocidades en la gradiente 0%, donde se encontrarán las velocidades sin filtrar.

**Figura N° 2:** Muestras de Velocidades sin filtrar

| Status | Velocity |
|--------|----------|
| Empty  | 6.491    |
| Empty  | 2.664    |
| Empty  | 2.711    |
| Loaded | 13.879   |
| Loaded | 27.893   |
| Loaded | 6.579    |
| Loaded | 1.595    |
| Loaded | 1.476    |
| Loaded | 4.643    |
| Empty  | 16.317   |
| Empty  | 52.74    |
| Empty  | 29.46    |
| Empty  | 29.81    |
| Empty  | 26.94    |
| Empty  | 25.624   |
| Empty  | 24.171   |
| Empty  | 19.133   |
| Empty  | 1.667    |
| Empty  | 1.494    |
| Empty  | 15.301   |
| Empty  | 30.176   |
| Empty  | 45.334   |
| Empty  | 15.391   |
| Empty  | 48.173   |
| Empty  | 16.609   |
| Empty  | 49.392   |
| Empty  | 30.676   |
| Empty  | 34.252   |
| Empty  | 37.738   |
| Empty  | 60.655   |
| Empty  | 21.146   |
| Empty  | 67.35    |
| Empty  | 23.515   |
| Empty  | 71.307   |
| Empty  | 69.59    |
| Empty  | 21.928   |

Fuente: Elaboración propia

### PASO 3

Se desarrolla un código para poder filtrar por estados e indicando una velocidad mínima y máxima que en este caso serán 10 Km/Hr y 65 Km/Hr respectivamente.

```
from google.colab import files
import pandas as pd
uploaded = files.upload()
df = pd.read_excel(next(iter(uploaded)), index_col=None)
empty_df = df[df['Status'] == 'Empty']
empty_df = empty_df[(empty_df['Velocity'] >= 10) & (empty_df['Velocity'] <= 65)]
loaded_df = df[df['Status'] == 'Loaded']
loaded_df = loaded_df[(loaded_df['Velocity'] >= 10) & (loaded_df['Velocity'] <= 65)]
empty_df.to_excel('empty_data_1.xlsx', index=False)
loaded_df.to_excel('loaded_data_1.xlsx', index=False)
files.download('empty_data_1.xlsx')
files.download('loaded_data_1.xlsx')
```

40

Resultados

**Figura N° 3:** Velocidades filtradas por estado Empty, con un máximo y mínimo

| Status | Velocity |
|--------|----------|
| Empty  | 16.317   |
| Empty  | 52.74    |
| Empty  | 29.46    |
| Empty  | 29.81    |
| Empty  | 26.94    |
| Empty  | 25.624   |
| Empty  | 24.171   |
| Empty  | 19.133   |
| Empty  | 14.837   |
| Empty  | 16.578   |
| Empty  | 30.385   |
| Empty  | 10.866   |
| Empty  | 26.44    |
| Empty  | 10.657   |
| Empty  | 12.193   |
| Empty  | 11.305   |
| Empty  | 19.52    |
| Empty  | 17.318   |
| Empty  | 17.292   |

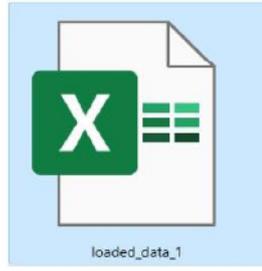


empty\_data\_1

Fuente: Elaboración propia

**Figura N° 4:** Velocidades filtradas por estado Loaded, con un máximo y mínimo

| Status | Velocity |
|--------|----------|
| Loaded | 13.879   |
| Loaded | 27.893   |
| Loaded | 35.777   |
| Loaded | 41.72    |
| Loaded | 35.161   |
| Loaded | 30.429   |
| Loaded | 53.474   |
| Loaded | 33.151   |
| Loaded | 24.702   |
| Loaded | 24.191   |
| Loaded | 30.13    |
| Loaded | 28.916   |
| Loaded | 45.066   |
| Loaded | 11.35    |
| Loaded | 15.603   |
| Loaded | 18.559   |
| Loaded | 19.342   |
| Loaded | 19.423   |
| Loaded | 16.815   |



loaded\_data\_1

Fuente: Elaboración propia

**PASO 4**

Con los resultados de las velocidades separadas por estados en la gradiente 0%. Se realiza una tabla de frecuencia. Donde estarán las cantidades y el porcentaje que representa cada una.

Para los camiones que están en estado “cargado”

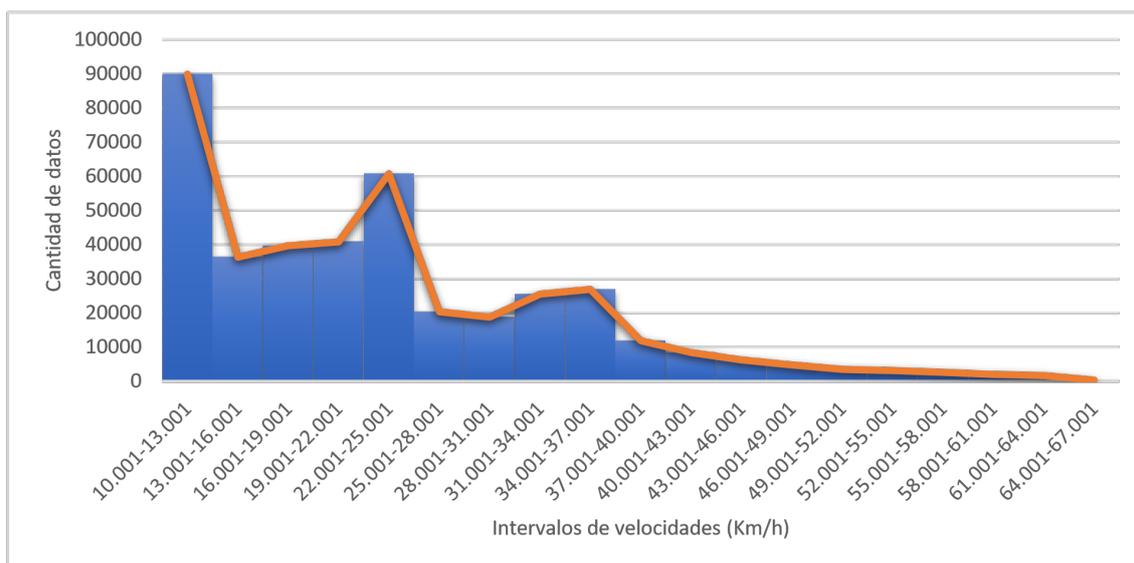
**Tabla 3:** Tabla de frecuencia de velocidades de camiones cargados

Intervalos de velocidades (Km/h)

|                      |               |                |
|----------------------|---------------|----------------|
| 10.001-13.001        | 89885         | 22.30%         |
| 13.001-16.001        | 36291         | 9.00%          |
| 16.001-19.001        | 39682         | 9.84%          |
| 19.001-22.001        | 40818         | 10.13%         |
| 22.001-25.001        | 60725         | 15.07%         |
| 25.001-28.001        | 20319         | 5.04%          |
| 28.001-31.001        | 18732         | 4.65%          |
| 31.001-34.001        | 25496         | 6.33%          |
| 34.001-37.001        | 26848         | 6.66%          |
| 37.001-40.001        | 11836         | 2.94%          |
| 40.001-43.001        | 8342          | 2.07%          |
| 43.001-46.001        | 6189          | 1.54%          |
| 46.001-49.001        | 4738          | 1.18%          |
| 49.001-52.001        | 3489          | 0.87%          |
| 52.001-55.001        | 3118          | 0.77%          |
| 55.001-58.001        | 2615          | 0.65%          |
| 58.001-61.001        | 2020          | 0.50%          |
| 61.001-64.001        | 1621          | 0.40%          |
| 64.001-67.001        | 321           | 0.08%          |
| <b>Total general</b> | <b>403085</b> | <b>100.00%</b> |

**Fuente:** Elaboración propia

**Gráfica N° 3:** Distribución de valores de velocidades de camiones cargados



Fuente: Elaboración propia

Para los camiones que están en estado “vacío”

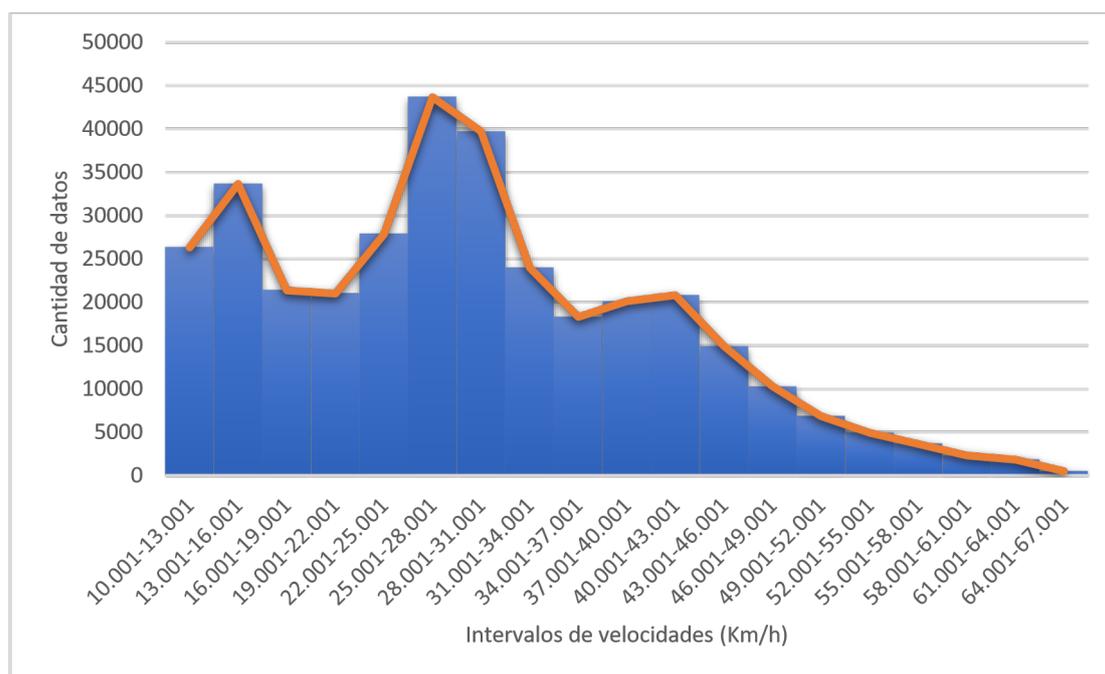
**Tabla N° 4:** Tabla de frecuencia de velocidades de camiones vacío

**Intervalos de Velocidades (Km/h)**

|                      |               |                |
|----------------------|---------------|----------------|
| 10.001-13.001        | 26312         | 7.69%          |
| 13.001-16.001        | 33654         | 9.84%          |
| 16.001-19.001        | 21367         | 6.25%          |
| 19.001-22.001        | 21003         | 6.14%          |
| 22.001-25.001        | 27871         | 8.15%          |
| 25.001-28.001        | 43670         | 12.77%         |
| 28.001-31.001        | 39733         | 11.62%         |
| 31.001-34.001        | 23979         | 7.01%          |
| 34.001-37.001        | 18281         | 5.34%          |
| 37.001-40.001        | 20092         | 5.87%          |
| 40.001-43.001        | 20813         | 6.09%          |
| 43.001-46.001        | 14926         | 4.36%          |
| 46.001-49.001        | 10273         | 3.00%          |
| 49.001-52.001        | 6836          | 2.00%          |
| 52.001-55.001        | 4940          | 1.44%          |
| 55.001-58.001        | 3645          | 1.07%          |
| 58.001-61.001        | 2306          | 0.67%          |
| 61.001-64.001        | 1835          | 0.54%          |
| 64.001-67.001        | 498           | 0.15%          |
| <b>Total general</b> | <b>342034</b> | <b>100.00%</b> |

Fuente: Elaboración propia

**Gráfica N° 4:** Distribución de valores de velocidades de camiones vacíos



Fuente: Elaboración propia

### 2.3. Moda estadística y su enfoque en las multimodas

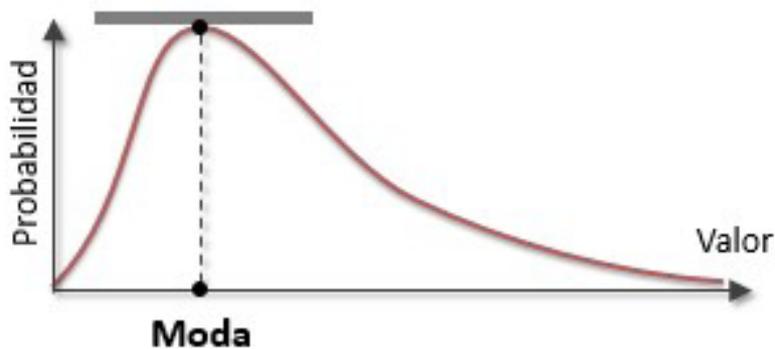
La moda estadística es un concepto fundamental dentro del campo de la estadística

descriptiva, que se centra en identificar el valor o valores que se presentan con mayor frecuencia en un conjunto de datos. A través de esta medida de tendencia central, podemos obtener información valiosa sobre las tendencias y patrones presentes en una distribución de datos.

En situaciones donde un conjunto de datos presenta más de un valor con la misma máxima frecuencia de aparición, se habla de una distribución multimodal. Las multimodas son un fenómeno interesante, ya que indican que un conjunto de datos puede tener múltiples picos o valores que son igualmente frecuentes. En este contexto, cada uno de estos valores recibe el nombre de "modo".

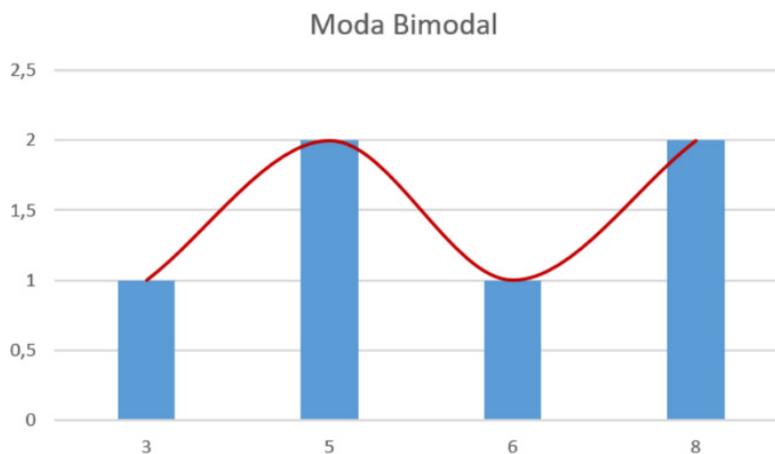
La identificación y comprensión de las multimodas en un conjunto de datos proporciona una visión más completa y detallada de la distribución. Al analizar las diferentes modas y sus respectivas frecuencias, se puede obtener una comprensión más rica de las características subyacentes de los datos. Las multimodas pueden ser indicativas de subgrupos o comportamientos específicos dentro de una población, lo que podría tener implicaciones significativas en diversas áreas, como análisis de mercado, ingeniería, ciencias sociales, medicina y más.

**Figura N° 5: Valores estadísticos**



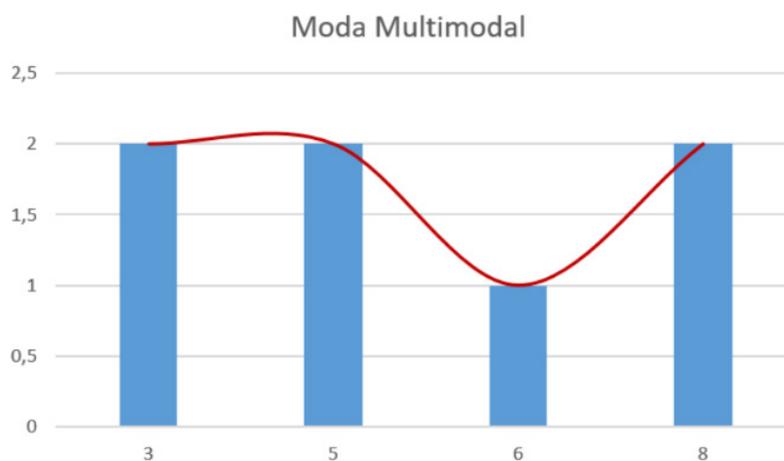
Fuente: <https://www.matematicas10.net/2015/12/ejemplos-de-moda.html>

**Figura N° 6: Moda Bimodal**



Fuente: <https://estadisticamente.com/moda-estadistica/>

**Figura N° 7: Moda Multimodal**



Fuente: <https://estadisticamente.com/moda-estadistica/>

## 2.4. Análisis del problema de la caída de la moda

En las tablas de frecuencia y en la representación gráfica, es evidente que emergen dos o más modas, lo que impulsa la necesidad de abordar la variabilidad inherente en las modas.

Proponemos una solución enfocada en seleccionar una modalidad adicional, más allá del resultado proporcionado por el código inicial empleado para la determinación de los perfiles de velocidad.

Para los camiones que están en estado “cargado”

Gradiente 0%

**Tabla N° 5:** Tabla de frecuencia de camiones cargados

Intervalos de velocidades (Km/h)

|                      |               |                |
|----------------------|---------------|----------------|
| 10.001-13.001        | 89885         | 22.30%         |
| 13.001-16.001        | 36291         | 9.00%          |
| 16.001-19.001        | 39682         | 9.84%          |
| 19.001-22.001        | 40818         | 10.13%         |
| 22.001-25.001        | 60725         | 15.07%         |
| 25.001-28.001        | 20319         | 5.04%          |
| 28.001-31.001        | 18732         | 4.65%          |
| 31.001-34.001        | 25496         | 6.33%          |
| 34.001-37.001        | 26848         | 6.66%          |
| 37.001-40.001        | 11836         | 2.94%          |
| 40.001-43.001        | 8342          | 2.07%          |
| 43.001-46.001        | 6189          | 1.54%          |
| 46.001-49.001        | 4738          | 1.18%          |
| 49.001-52.001        | 3489          | 0.87%          |
| 52.001-55.001        | 3118          | 0.77%          |
| 55.001-58.001        | 2615          | 0.65%          |
| 58.001-61.001        | 2020          | 0.50%          |
| 61.001-64.001        | 1621          | 0.40%          |
| 64.001-67.001        | 321           | 0.08%          |
| <b>Total general</b> | <b>403085</b> | <b>100.00%</b> |

En este contexto, es perceptible la existencia de dos intervalos en los que se concentra la mayor cantidad de valores de velocidades, previamente filtrados y segmentados por su estado, junto con su correspondiente gradiente de 0%. En el análisis del perfil de velocidad, el intervalo de la moda en los resultados corresponde al primero. Sin embargo, para fines de análisis, consideraremos ambos intervalos

46

Fuente: Elaboración propia

El mismo análisis se extiende a las 25 gradientes que abarcan desde -12% hasta 12%. En esta instancia, es evidente en su mayoría la presencia de dos modas. En aquellos casos en que pudieran existir más modas, se prescindirá de ellas en aras de una precisión óptima en el cálculo. Así, el enfoque se centrará exclusivamente en trabajar con las modas predominantes.

En los intervalos determinados por las tablas de frecuencia, adoptaremos el punto medio como la moda, que equivale a la semisuma de sus extremos. En el caso particular de la gradiente de 0%, obtendríamos  $(10.001 + 13.001) / 2 = 11.501$ . Esta cifra representa que la moda estará dentro del intervalo.

Para proceder, es esencial aclarar que la MODA 1 se refiere al intervalo con la mayor concentración de valores de velocidades, mientras que la MODA 2 se atribuye al segundo intervalo que alberga una cantidad significativa de valores de velocidades.

**Tabla N° 6:** Intervalos donde se encuentra moda 1 y moda 2

| Gradientes (%) | Moda 1 | Moda 2 |
|----------------|--------|--------|
| -12            | 11.501 | 23.501 |
| -11            | 11.501 | 23.501 |
| -10            | 11.501 | 23.501 |
| -9             | 23.501 | 11.501 |
| -8             | 23.501 | 11.501 |
| -7             | 20.501 | 11.501 |
| -6             | 23.501 | 11.501 |
| -5             | 11.501 | 20.501 |
| -4             | 11.501 | 20.501 |
| -3             | 11.501 | 20.501 |
| -2             | 11.501 | 20.501 |
| -1             | 11.501 | 20.501 |
| 0              | 11.501 | 23.501 |
| 1              | 11.501 | 20.501 |
| 2              | 11.501 | 20.501 |
| 3              | 11.501 | 20.501 |
| 4              | 11.501 | 20.501 |
| 5              | 11.501 | 20.501 |
| 6              | 11.501 | 23.501 |
| 7              | 11.501 | 23.501 |
| 8              | 11.501 | 17.501 |
| 9              | 11.501 | 17.501 |
| 10             | 11.501 | 17.501 |
| 11             | 11.501 | 17.501 |
| 12             | 11.501 | 17.501 |

La tabla proporcionada revela que el valor 11.501 corresponde al punto medio del intervalo 10.001-13.001, lo cual indica que esta es la ubicación de la moda. De manera similar, esta metodología se aplica a los demás intervalos, donde los valores representan los puntos medios de sus respectivos intervalos.

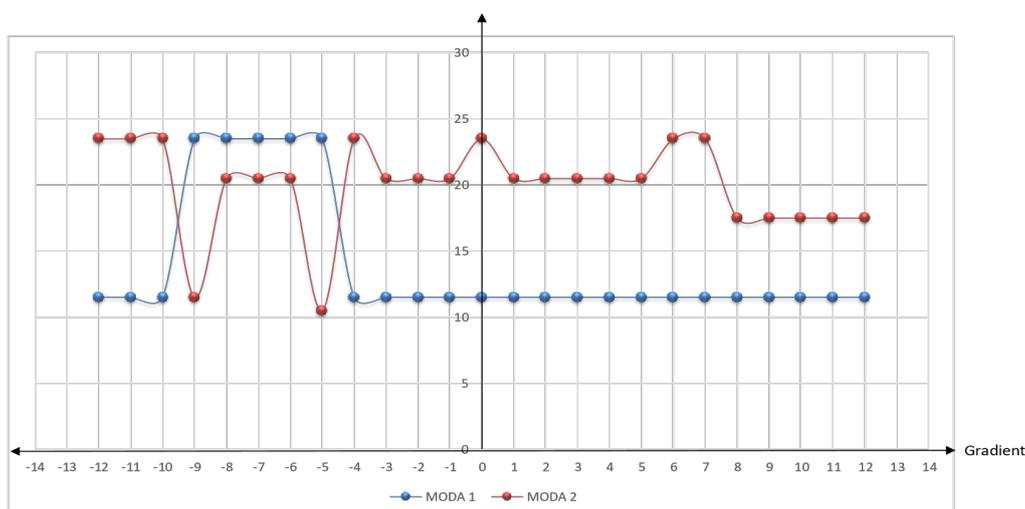
**Fuente:** Elaboración propia

Realizamos una comparación entre la tabla previamente analizada, donde se identificaron los intervalos correspondientes, y los datos obtenidos a través del análisis del perfil de velocidad.

Se observa que las modas halladas se encuentran dentro de los intervalos analizados.

Analizamos gráficamente las tendencias de las modas

**Gráfica N° 5:** Gráfica donde se encuentra moda 1 y moda 2



Fuente: Elaboración propia

48

La observación detallada de los datos presentados en el cuadro revela patrones significativos en relación con la relación entre los gradientes (pendientes) y las velocidades del camión minero. En primer lugar, se puede apreciar que, en casi todos los casos, existen dos modas claramente identificadas en los resultados. La Moda 1 generalmente se encuentra en torno al valor de 11.501, mientras que la Moda 2 varía entre 17.501 y 23.501.

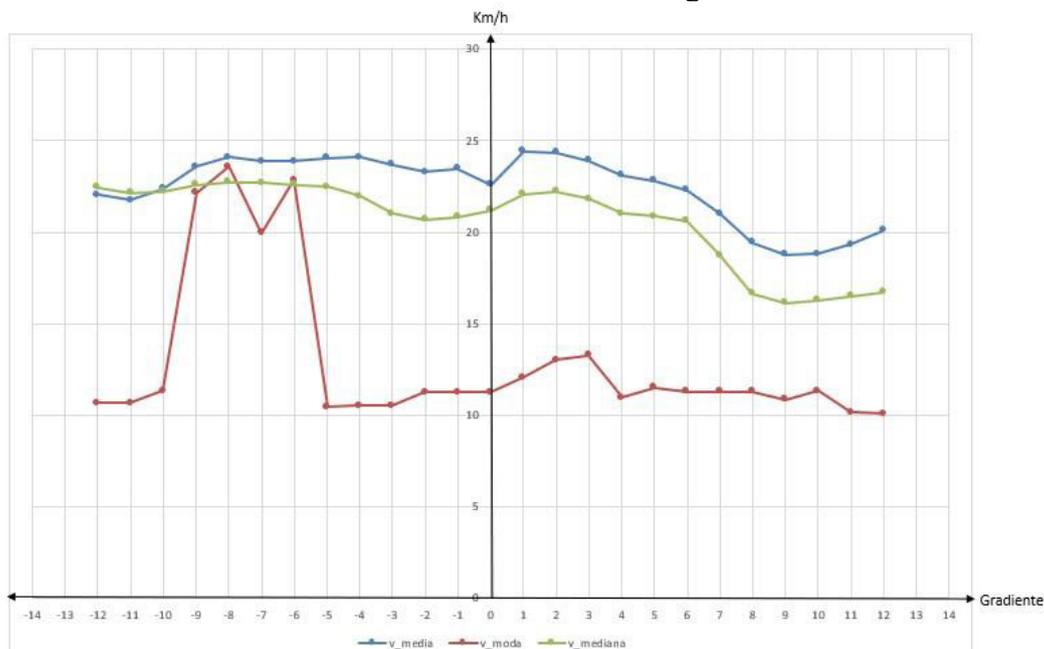
Estos patrones indican una marcada dualidad en el comportamiento de la velocidad del camión minero en función de las pendientes.

Estas tendencias pueden atribuirse a las condiciones del terreno y la influencia de la gravedad en la velocidad del camión y a la aceleración ejecutada por cada operador del camión. La Moda 1 en pendientes descendentes podría relacionarse con la influencia gravitatoria que impulsa el descenso, mientras que la Moda 2 en pendientes ascendentes podría indicar un mayor esfuerzo requerido para mantener la velocidad en terrenos más empinados.

En resumen, este análisis resalta las dinámicas distintivas de la velocidad del camión minero en diferentes gradientes. La presencia constante de dos modas sugiere una respuesta característica del vehículo en función del terreno. Estos hallazgos son valiosos para entender el comportamiento de los camiones mineros en distintas condiciones y podrían tener implicaciones en la seguridad de la operación, la eficiencia operativa y la toma de decisiones en la industria minera.

## 2.5. Análisis del problema de la caída de la moda y su solución

**Grafica N° 6:** Perfil de velocidad de camiones cargados en el mes de febrero



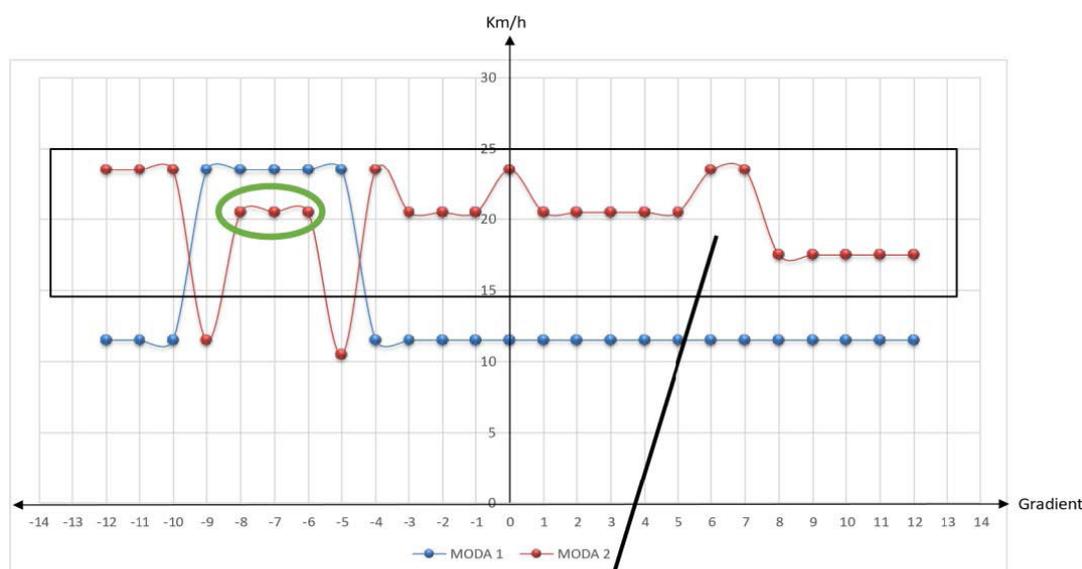
Fuente: Elaboración propia

La observación de los datos revela que la moda no sigue necesariamente el comportamiento de la media y la mediana. En este sentido, podemos abordar el problema de la caída de la moda. Al revisar el análisis previo de la moda para el mismo mes de febrero, es evidente que la moda se asemeja al comportamiento de la Moda 1 que ya se había estudiado. Por tanto, podemos concluir que el análisis realizado es correcto.

Dado que también se identifica la Moda 2 como una representación modal en los datos, existe la posibilidad de encontrar una relación entre ambas modas para obtener una Moda que presente valores coherentes y siga el comportamiento de la media y la mediana.

En base a las tablas y gráficos previamente analizados, surge un patrón claro: las modas tienden a ubicarse mayormente en dos intervalos específicos de velocidades, es decir, de 10 a 13 y de 17 a 23. Si establecemos un valor mínimo inferior donde no se consideren los valores modales menores a  $X$ , se puede generar una nueva Moda.

Esta conclusión implica que, al considerar estas relaciones entre las modas, es posible obtener una representación modal más coherente con el comportamiento general de los datos y su relación con la media y la mediana. Esta aproximación refinada y ajustada permitirá una comprensión más precisa de los patrones de velocidad en diferentes condiciones y gradientes, lo cual es esencial en el análisis de los camiones mineros y su desempeño en el terreno.

**Gráfica N° 7:** Gráfica donde se encuentra moda 1 y moda 2

Gráfica 7: Gráfica donde se encuentra moda 1 y moda 2

Fuente: Elaboración propia

50

La representación gráfica ofrece una visión más esclarecedora del comportamiento de los datos. Se destaca que la Moda 1 exhibe una tendencia inferior en comparación con la Moda 2. La Moda 2, por su parte, parece mostrar una mayor coherencia con la media y la mediana, aunque también presenta caídas en algunos gradientes. Además, se observa que cuando la Moda 2 disminuye, la Moda 1 experimenta un aumento correspondiente.

Este patrón nos lleva a considerar la identificación del valor "X", que representa el punto medio entre la disminución de una moda y el aumento de la otra. La detección de este punto intermedio puede ser fundamental para comprender las transiciones entre las modas y sus variaciones en diferentes gradientes. Esto nos brinda una perspectiva más completa de cómo las dos modas interactúan y cambian en función de las condiciones del terreno.

La identificación de este valor "X" entre las modas podría contribuir a un análisis más profundo y detallado de las relaciones entre las modas y cómo se ajustan al comportamiento general de los datos. Esta aproximación refinada permitirá una comprensión más precisa de los patrones de velocidad y las relaciones entre las modas en diversas condiciones, lo cual tiene implicaciones significativas en el análisis de los camiones mineros en terrenos variados.

Para determinar el valor "X" que se sitúe entre las modas representativas, se realizará un análisis en los intervalos que se encuentren en un punto intermedio entre la Moda 1 y la Moda 2. Se desarrollará un código específico para llevar a cabo los cálculos, donde variaremos el valor de "X" iterativamente hasta lograr el resultado deseado que exhiba una concordancia entre la media, la mediana y nos permita comprender por qué se presenta la caída en la moda.

Esta metodología permitirá un enfoque sistemático y preciso para identificar el valor "X" que mejor se adapte a las tendencias y relaciones estadísticas presentes en los datos. Al ajustar "X" de esta manera, buscamos encontrar una moda que no solo sea representativa en sí misma, sino que también esté en armonía con otras medidas estadísticas clave, lo que contribuirá a una interpretación más completa y coherente del fenómeno de la caída en la moda.

La aplicación de este enfoque analítico nos brindará una visión más profunda de la relación entre las modas, la media y la mediana, y nos permitirá desentrañar las razones subyacentes detrás de la caída en la moda observada en los datos.

Del código para hallar las curvas de velocidad haremos una adaptación para solo hallar moda y variar el rango mínimo. Para tener que identificar una moda que sea representativa.

Para datos en estado “cargados”

```
v_moda=[]

for i in lista_gradientes:
    df_g=data_cargado.loc[(data_cargado['gradiente']==i)
    df_g=df_g.loc[(df_g['velocidad']>=X)
    df_g=df_g.loc[(df_g['velocidad']<=60)
    v_moda_g=round(df_g['velocidad'].mode()[0],2)
    v_moda.append(v_moda_g)

dicc = {
    "gradientes": lista_gradientes,
    "v_moda":v_moda,
}

df=pd.DataFrame(dicc)
print(df)

df.to_excel(f"{mes}100_v3_cargado.xlsx",index=False)
```

Se buscará el valor “X” que mejor represente a las modas y sea concordante con la

51

Igualmente se hará para los camiones en estao “Vacio”.

### 3. Resultados

El proceso de variar los valores de "X" a lo largo de los intervalos que previamente se identificaron implica encontrar la moda más representativa dentro del conjunto de datos. Se busca específicamente el intervalo de valores de velocidad donde la moda está en concordancia con la media y la mediana. Este enfoque se adopta en base a la observación previa de que en cada punto se forman múltiples modas. Sin embargo, una observación más detallada revela que hay tres intervalos que se repiten con mayor frecuencia.

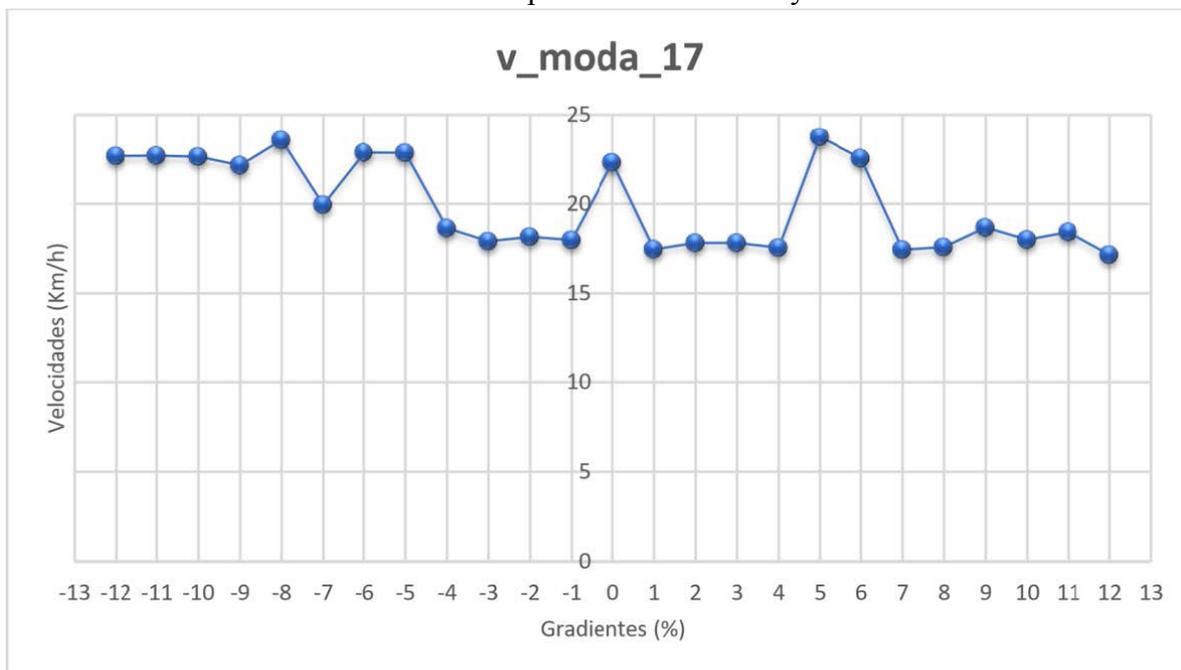
Por tanto, se realizará un análisis detallado utilizando estos tres intervalos. El objetivo es identificar el valor de "X" que resulte en una moda que se ajuste tanto a la media como a la mediana, lo cual proporciona una representación más precisa y confiable del fenómeno en cuestión. Al concentrar el análisis en los intervalos más repetidos, se espera obtener una visión más clara de las relaciones estadísticas subyacentes y de las tendencias de velocidad en función de los gradientes.

Este enfoque detallado asegurará que la moda seleccionada no solo sea representativa, sino que también esté en armonía con las demás medidas estadísticas clave. En última instancia, permitirá una comprensión más completa y precisa de cómo los valores de velocidad se relacionan con diferentes gradientes y cómo se puede explicar la formación de las modas observadas en

los datos.

Si se tiene el primer intervalos  $X=17$  km/h

**Gráfica N° 8:** Moda para velocidades mayor a 17 km/h

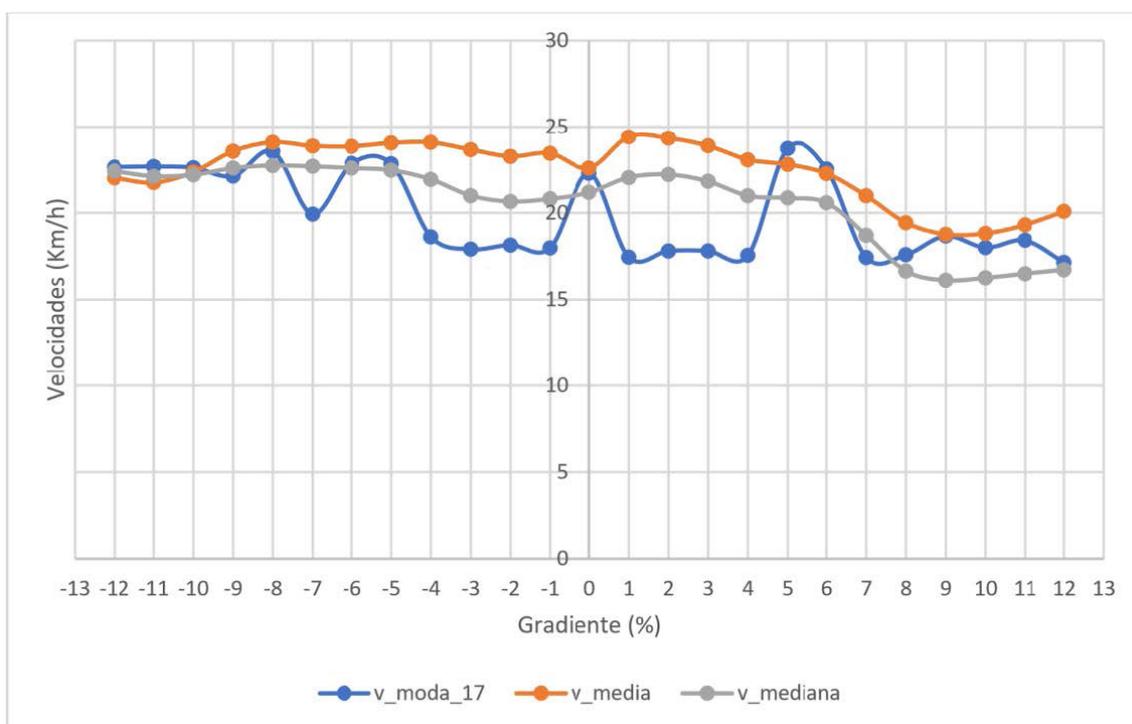


52

Gráfica 8: Moda para velocidades mayor a 17 km/h

Fuente: Elaboración propia

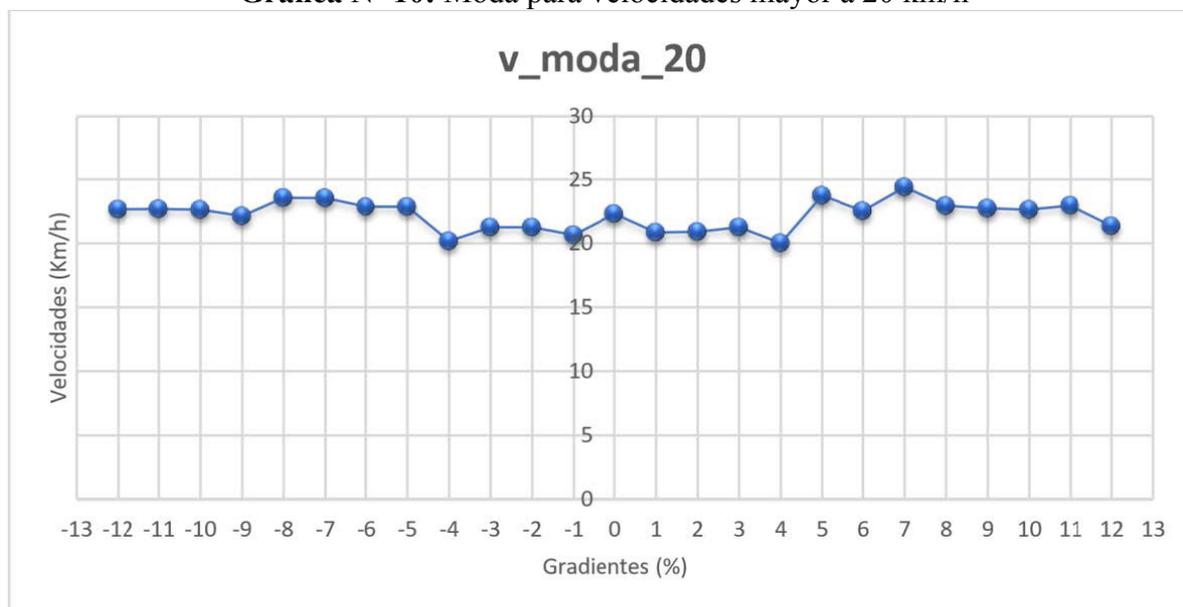
**Gráfica N° 9:** Perfil de velocidad con velocidades mayores a 17 km/h



Fuente: Elaboración propia

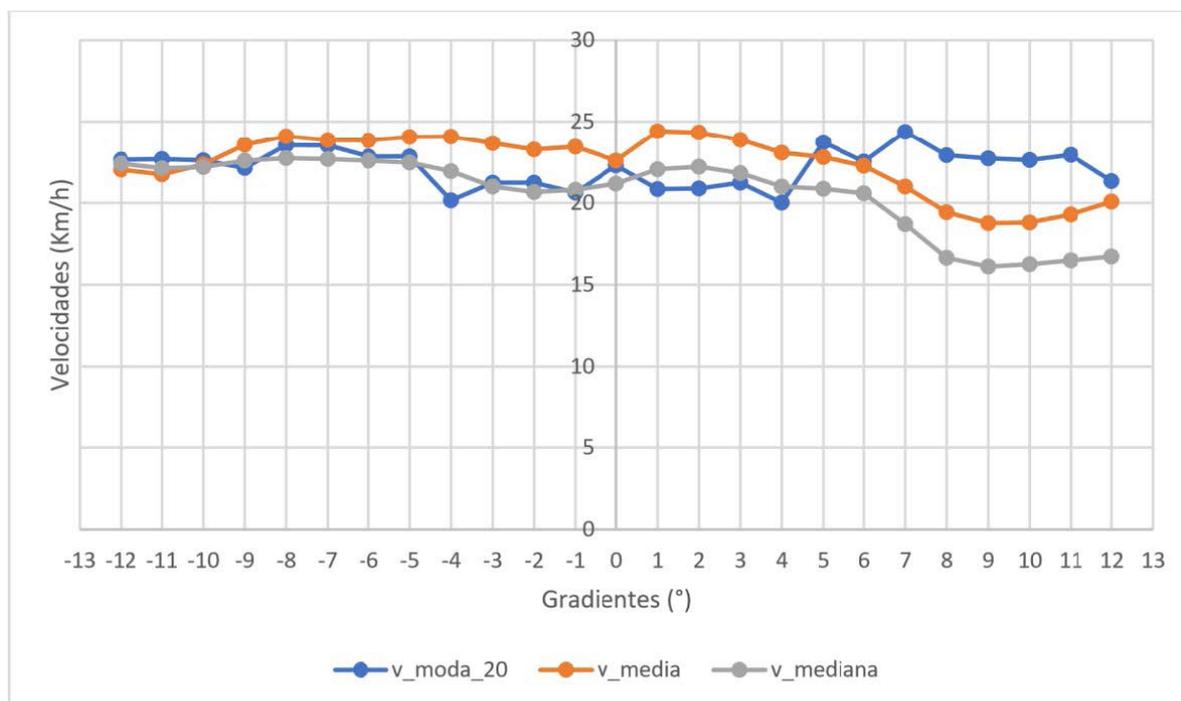
Si se tiene el segundo intervalos  $X=20$  km/h

**Gráfica N° 10: Moda para velocidades mayor a 20 km/h**



*Grafica 10: Moda para velocidades mayor a 20 km/h*  
**Fuente:** Elaboración propia

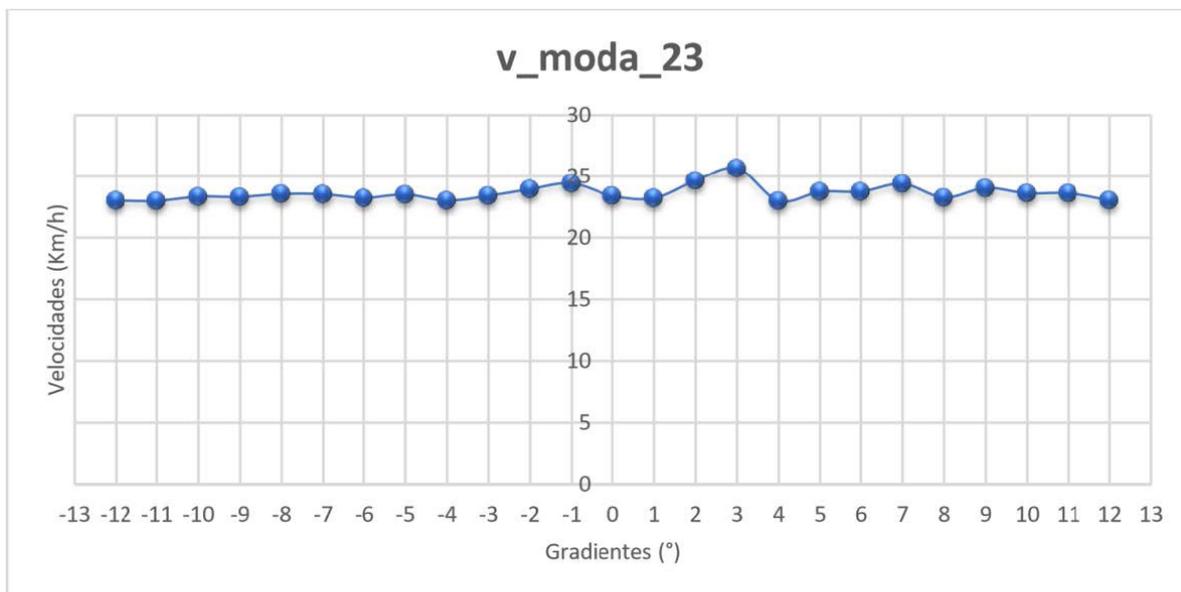
**Gráfica N° 11: Perfil de velocidad con velocidades mayores a 20 km/h**



*Grafica 11: Perfil de velocidad con velocidades mayores a 20 km/h*  
**Fuente:** Elaboración propia

Si se tiene el segundo intervalo  $X = 23$  km/h

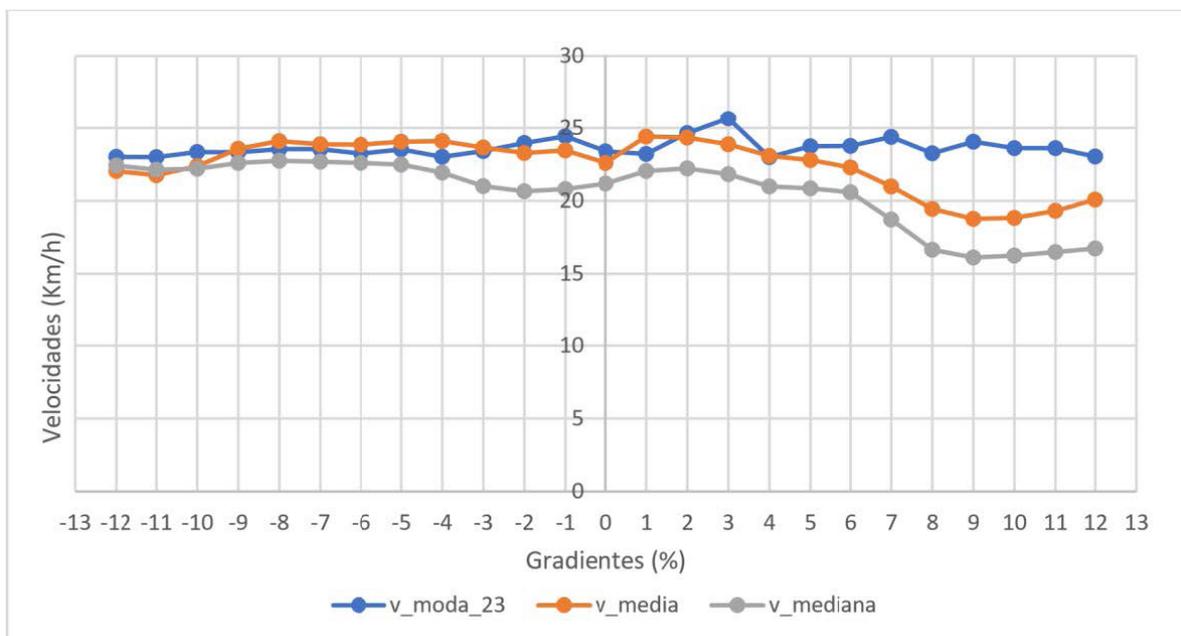
**Gráfica N° 12:** Moda para velocidades mayor a 23 km/h



*Gráfica 12: Moda para velocidades mayor a 23 km/h*

Fuente: Elaboración propia

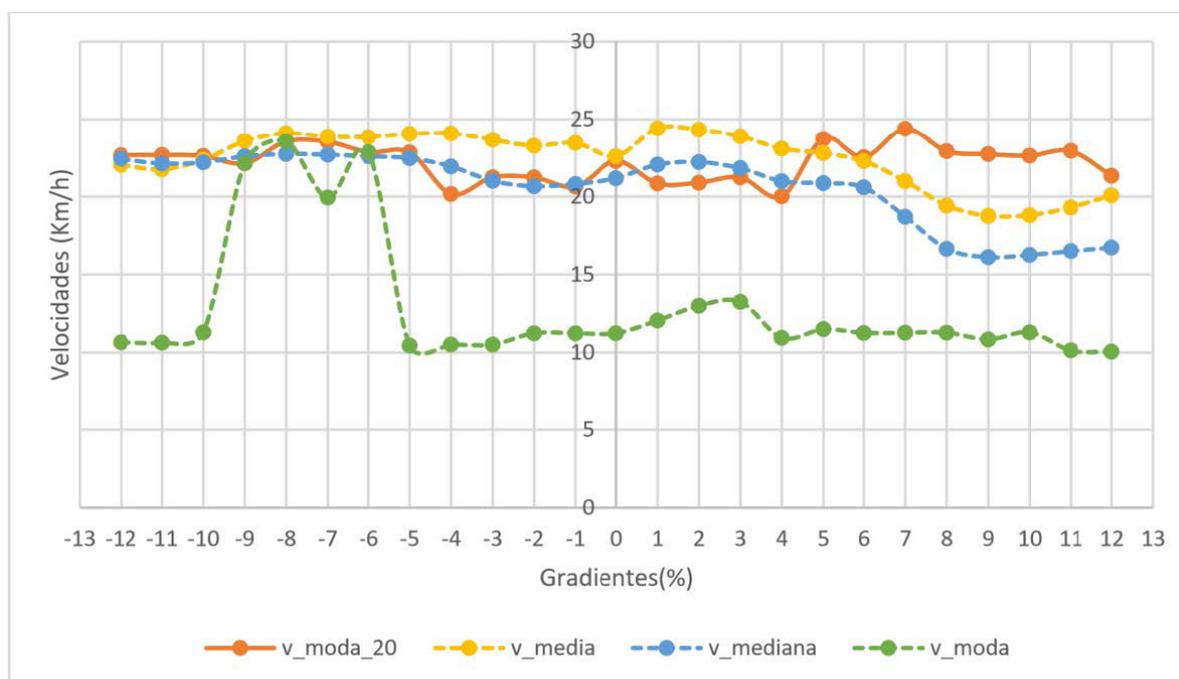
**Gráfica N° 13:** Perfil de velocidad con velocidades mayores a 23km/h



Fuente: Elaboración propia

Basándonos en los resultados de los tres intervalos donde se concentra el mayor número de modas, podemos concluir que la gráfica "v\_moda\_20" muestra un patrón distintivo cuando se elige un valor de 20 km/h como el mínimo para la selección de la moda.

**Gráfica N° 14:** Perfil de velocidad con la moda recomendada



Grafica 14: Perfil de velocidad con la moda recomendada

Fuente: Elaboración propia

Se observa que la moda ya no presenta una caída abrupta, sino que mantiene una concordancia consistente con la media y la mediana.

#### 4. Discusión

A partir de los resultados obtenidos, es evidente que, debido a la considerable cantidad de datos presentes, que puede llegar a abarcar gigabytes de información, concretamente 22,923,000 velocidades en el mes de febrero, se generan múltiples modas por gradiente que representan el conjunto de datos. Sin embargo, es claro que la primera moda carece de concordancia con otras medidas como la media y la mediana. Por lo tanto, al profundizar en un análisis más detallado de las velocidades registradas, es posible identificar diversas modas, algunas de las cuales se destacan de manera notoria, mientras que otras resultan más sutiles en su manifestación.

Este descubrimiento de varias modas nos conduce a aplicar un filtro selectivo para elegir la moda que mejor se ajuste a la tendencia de las demás medidas estadísticas. Este proceso asegura que la moda seleccionada no solo esté en armonía con otras medidas, como la media y la mediana, sino que también brinde una representación más precisa de las velocidades de los camiones en diferentes estados.

En resumen, el análisis detallado y la selección cuidadosa de la moda entre las diversas modas identificadas son esenciales para garantizar que la interpretación de las velocidades de los camiones mineros refleje de manera precisa las tendencias y los patrones presentes en los datos. Esta aproximación refinada y ajustada proporciona información confiable y valiosa para la comprensión del comportamiento de los camiones en diversos entornos y condiciones que se presentan en la unidad minera.

## 5. Conclusiones

El cálculo del perfil de velocidades de camiones mineros en función de la gradiente comprende una caída en la moda estadística, esta caída corresponde a la mezcla de varias modas que resultan de la naturaleza de la operación de los camiones.

Es posible realizar un análisis más detallado para caracterizar a las dos modas predominantes en cada distribución de velocidades correspondiente a cada gradiente del terreno y al estado del camión (i.e. cargado y vacío) para obtener su valor preciso.

El algoritmo desarrollado en este trabajo e implementado en Python permite mejorar el análisis de los datos que nos proporciona el dispatch en la operación minera al reportar un valor de tendencia central congruente con la operación de los camiones.

## 6. Literatura citada

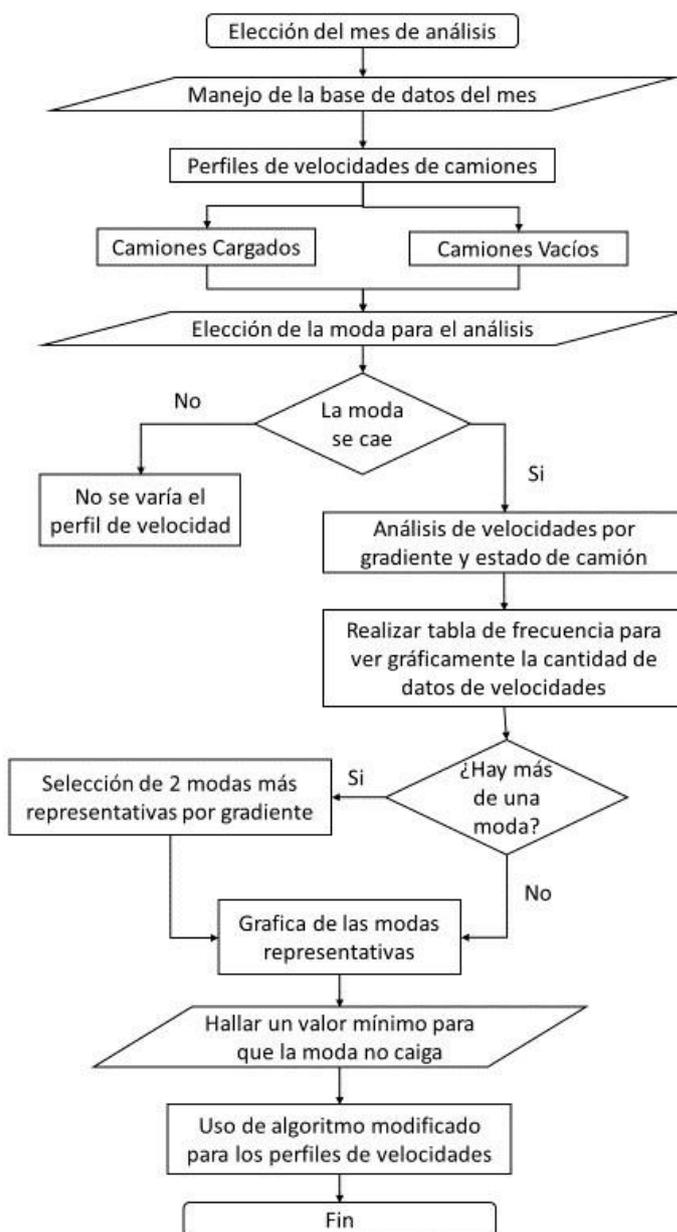
**De La Cruz, Eder; Aróstegui, Nelson; Huarcaya, Julio** (2020). Perfil de velocidades de camiones cargados y vacíos en minería superficial.

**56** **Marín Alfredo Ph.D.** (2013). Manual del Curso Taller GPSS: Aplicación de la simulación de transporte con GPSS al planeamiento de minado

**Anthony Arrasco, Luis Flores, Emanuel Poma** (2022). Análisis de confiabilidad del procedimiento de cálculo de perfiles de velocidad en camiones mineros.

### ANEXO

Diagrama de flujo del proceso de análisis de la moda en los perfiles de velocidades de camiones mineros.



**REVISTA DE INVESTIGACIÓN MULTIDISCIPLINARIA**



<http://www.ctscafe.pe>

Volumen IX- N° 25 Marzo 2025

210

Contáctenos en nuestro correo electrónico

**[revistactscafe@ctscafe.pe](mailto:revistactscafe@ctscafe.pe)**

Página Web:

**<http://ctscafe.pe>**

