

# Classification of Dried Beans. Analysis from Data Mining

Omar Danilo Castrillón, Ph.D<sup>1</sup>, Jaime Alberto Giraldo, Ph.D<sup>1</sup>, and Jaime Antero Arango, Ph.D<sup>1</sup>

<sup>1</sup>Universidad Nacional de Colombia, Colombia, Facultad de Ingeniería y Arquitectura, Departamento de Ingeniería Industrial, Campus La Nubia Bloque Q piso 2, Manizales – Colombia  
correo-e: odcastrillong@unal.edu.co, jaiagiraldog@unal.edu.co, Jaarangom@unal.edu.co

## Abstract

*The classification of seeds is a fundamental factor in all agricultural processes, especially regarding the obtention of the highest possible profitability of the products once they are ready to be harvested, and to avoid fastidious manual processes. This investigative work performs a data mining analysis, in order to establish the most influential independent variables in the classification of a seed, in this case of a dry bean. The analyzed independent variables are as follows: Area, perimeter, longest axis length, shortest axis length, aspect, eccentricity, convex area, equivalent diameter, extension, solidity, roundness, chromaticity, form factor 1, form factor 2, form factor 3, form factor 4. Likewise, a dependent variable called class is established, which consists of seven states: Barbunya, Bombay, Cali, Dermason, Horoz, Seker and Sira. In this research, the J48 Algorithm of the machine learning and data mining platform called Weka is used, to identify the class to which a seed can belong to, as well as the most influential independent variables in this process. As a result, it was found with an effectiveness greater than 93%, that the most influential variables are: Perimeter, greatest axis length, least axis length.*

**Keyword—Data Mining, J48, Weka, Seed, Bean.**

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).  
**ISSN, ISBN:** (to be inserted by LACCEI).  
**DO NOT REMOVE**

# Clasificación de Frijol Seco. Análisis desde la Minería de Datos

Omar Danilo Castrillón, Ph.D<sup>1</sup>, Jaime Alberto Giraldo, Ph.D<sup>1</sup>, and Jaime Antero Arango, Ph.D<sup>1</sup>

<sup>1</sup>Universidad Nacional de Colombia, Colombia, Facultad de Ingeniería y Arquitectura, Departamento de Ingeniería Industrial, Campus La Nubia Bloque Q piso 2, Manizales – Colombia  
correo-e: odcastrillong@unal.edu.co, jaiagiraldog@unal.edu.co, Jaarangom@unal.edu.co

## Resumen—

La clasificación de las semillas es un factor fundamental en todos los procesos agrícolas, Maxime si se desea obtener la mayor rentabilidad posible de los productos una vez puedan ser cosechadas y evitar engorrosos procesos manuales. En este trabajo investigativo, se parte de un análisis desde la minería de datos, con el fin de establecer las variables independientes más influyentes en la clasificación de una semilla, en este caso frijol seco. Entre las variables independientes objetos de análisis se encuentran: Área, perímetro, mayor longitud de eje, menor longitud de eje, aspecto, excentricidad, área convexa, diámetro equivalente, extensión, solidez, redondez, cromaticidad, factor de forma 1, factor de forma 2, factor de forma 3, factor de forma 4. Igualmente se establece una variable dependiente denominada clase, la cual consta de siete estados: Barbunya, Bombay, Cali, Dermason, Horoz, Seker y Sira. En esta investigación se emplea el Algoritmo J48 de la plataforma de aprendizaje automático y minería de datos denominada Weka, con el fin de identificar la clase a la cual puede pertenecer una semilla y las variables independientes más influyentes en este proceso. Como resultado, se encuentra que con una efectividad superior al 93%, las variables más influyentes son: Perimetro, mayor longitud de eje, menor longitud de eje.

**Palabra Clave—**Minería de datos, J48, Weka, Semilla, Frijol.

## Abstract

The classification of seeds is a fundamental factor in all agricultural processes, especially regarding the obtention of the highest possible profitability of the products once they are ready to be harvested, and to avoid fastidious manual processes. This investigative work performs a data mining analysis, in order to establish the most influential independent variables in the classification of a seed, in this case of a dry bean. The analyzed independent variables are as follows: Area, perimeter, longest axis length, shortest axis length, aspect, eccentricity, convex area, equivalent diameter, extension, solidity, roundness, chromaticity, form factor 1, form factor 2, form factor 3, form factor 4. Likewise, a dependent variable called class is established, which consists of seven states: Barbunya, Bombay, Cali, Dermason, Horoz, Seker and Sira. In this research, the J48 Algorithm of the machine learning and data mining platform called Weka is used, to identify the class to which a seed can belong to, as well as the most influential independent variables in this process. As a result, it was found with an effectiveness greater than 93%, that the most influential variables are: Perimeter, greatest axis length, least axis length.

**Keyword—**Data Mining, J48, Weka, Seed, Bean.

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).

**ISSN, ISBN:** (to be inserted by LACCEI).

**DO NOT REMOVE**

## I. INTRODUCCION

La clasificación adecuada de las semillas de frijol es un trabajo de gran importancia, el cual influye de manera fundamental en la calidad de las mismas y requiere una gran cantidad de tiempo y paciencia [1]. En este sentido diversos autores [1] han diseñados procesos basados en redes neuronales y máquinas de aprendizaje para lograr la clasificación de semillas de soya. En este proceso, se logra una efectividad superior al 96%. En otros estudios similares [2], se emplean máquinas de soporte vectorial, con el fin de predecir la germinación de las semillas de remolacha, lográndose una efectividad superior al 89%. Igualmente, otros autores [3], han logrado la clasificación de semillas, mediante estudios de tomografía computarizadas basadas en rayos x, lográndose una efectividad del 88.7%. Estudios similares pueden ser encontrados en las siguientes referencias bibliografías[4,5,6].

En este trabajo investigativo, se parte de un análisis desde la minería de datos (Weka), con el fin de establecer las variables independientes más influyentes en la clasificación de una semilla. En este caso el frijol seco. Entre las variables independientes objetos de análisis se encuentran [7]: Área, perímetro, mayor longitud de eje, menor longitud de eje, aspecto, excentricidad, área convexa, diámetro equivalente, extensión, solidez, redondez, cromaticidad, factor de forma 1, factor de forma 2, factor de forma 3, factor de forma 4. Igualmente se establece una variable dependiente denominada clase, la cual consta de siete estados: Barbunya, Bombay, Cali, Dermason, Horoz, Seker y Sira.

En esta investigación se emplea la plataforma de aprendizaje automático y minería de datos denominada Weka [8], con el fin de identificar la clase a la cual puede pertenecer una semilla de frijol seco, con base en la influencia que las variables independientes puedan tener sobre la variable dependiente, en este caso denominada clase.

Los datos obtenidos en este trabajo investigativo muestran que las variables más influyentes en la clasificación del frijol seco son: perímetro, mayor longitud de eje y menor longitud de eje. Esta clasificación se logra con una efectividad superior al 90%, cuando se entrena con el 90% de los datos y se valida con el 10% de los datos. No obstante, cuando se usa todo el conjunto de datos para entrenar y validar, la efectividad en la clasificación es superior al 93%. Con otras técnicas de

clasificación basadas en algoritmos Bayesiano, máquinas de soporte vectorial, IB1, Random Forest Tablas de decisiones se pueden lograr porcentajes de efectividad similares. Se resalta que, si bien algunas técnicas pueden ser ligeramente superiores a la técnica empleada, ninguna permite establecer un árbol de relación de variables como el algoritmo J48 utilizado en esta investigación.

En general, existen muy pocos trabajos realizados en esta área de clasificación de semillas por medio de técnicas de Inteligencia artificial. Específicamente por medio de la metodología basada en árboles de decisión y redes solo se encontró un trabajo en las diferentes revisiones literarias. Aspecto que justifica aún más la realización de este trabajo.

Para una mejor comprensión, este trabajo es organizado de la siguiente forma: Metodología, resultados, discusiones, conclusiones, agradecimientos y referencias.

## II. METODOLOGIA

La metodología propuesta en este trabajo investigativo está basada cinco etapas o fases como se estructuran a continuación:

a) *Estructuración de la base de datos y reducción dimensionalidad.* Con los valores apropiados para cada una de las variables independientes y dependiente, se crea una base de datos inicial. En este proceso, se parte de una base de datos preexistente, en el siguiente vínculo: (<http://archive.ics.uci.edu/ml/datasets/Dry+Bean+Dataset#>) y definida en algunos escritos [7]. A partir de ella, se estructura en una hoja de Excel, todos los registros. Y se realiza un proceso de correlación entre cada una de las variables independientes y la variable dependiente. Se seleccionan aquellas variables con una correlación superior a 0.3 e inferior 0.7. Una correlación menor implica que la variable independiente no tiene una influencia significativa sobre la variable dependiente y una correlación mayor, implica que la variable independiente es prácticamente la misma variable dependiente.

b) *Archivo Arff.* Tomando como base las variables seleccionadas en el paso anterior, se estructurará el respectivo archivo Arff para ser analizado desde la plataforma de aprendizaje automático y minería de datos denominada Weka.

c) *Segunda Selección de variables.* Con el archivo Arff, estructurado en el paso anterior, empleando la plataforma Weka, se realizará una nueva selección de variables, con él método de Ranqueo bajo la prueba Chi Cuadrado. Este proceso permitirá establecer la importancia de cada variable independiente, aspecto que permite realizar un proceso de priorización sobre las mismas, con el fin de seleccionar las variables más importantes.

d) *Predicción de la variable dependiente.* Con las variables seleccionadas en el paso anterior, se reestructura el archivo Arff definido en el paso (b). Posteriormente, se predice el comportamiento de la variable dependiente por medio del algoritmo J48 de la plataforma Weka (algoritmo de comportamiento similar a los bayesianos [9]). Esta clasificación permitirá obtener las respectivas matrices de clasificación, precisión, confusión.

e) *Comparación de resultados.* Los resultados obtenidos son comprados con otras técnicas de clasificación basadas en inteligencia artificial, con el fin de establecer la efectividad de los mismos.

## III RESULTADOS

Como consecuencia de aplicar la metodología en cada uno de los pasos definidos en la sección anterior, se obtienen los siguientes resultados:

a) *Estructuración de la base de datos y reducción dimensionalidad.* Con los datos previamente definidos en (<http://archive.ics.uci.edu/ml/datasets/Dry+Bean+Dataset#>) se obtiene una tabla con 13.611 registros y 16 variables independientes y una variable dependiente. Con este archivo se calcula la correlación en valor absoluto, entre cada una de las variables independientes y la variable dependiente. Como resultado de este proceso de correlación se logran seleccionar 10 variables cuya correlación se encuentra en 0.3 y 0.7. La Tabla I, ilustra este aspecto:

TABLA I  
ANALISIS DE CORRELACION

Nro.	Variable	Correlación	Seleccionada
1	Área	0.47	Si
2	Perímetro	0.5	Si
3	Mayor longitud del eje	0.45	Si
4	Menor longitud del eje	0.45	Si
5	Aspecto	0.11	No
6	Excentricidad	0.2	No
7	Área convexa	0.47	Si
8	Diámetro equivalente	0.48	Si
9	Extensión	0.03	No
10	Solidez	0.32	Si
11	Redondez	0.38	Si
12	Compacticidad	0.15	No
13	Factor de forma 1	0.39	Si
14	Factor de forma 2	0.33	Si
15	Factor de forma 3	0.16	No
16	Factor de forma 4	0.16	No

b) *Archivo Arff.* Como resultado de este proceso, y tomando las variables seleccionadas en el paso anterior, se estructura un archivo Arff el cual será analizado por la plataforma Weka. Las Tablas II y III ilustran el encabezado y un fragmento del detalle de este archivo respectivamente. Para la construcción de esto archivos Arff se reestructura la base de datos encontrada en <http://archive.ics.uci.edu/ml/datasets/Dry+Bean+Dataset#> y definida en [7].

TABLA II  
ENCABEZADO ARCHIVO ARFF

@RELATION	Variables	Tipo
@ATTRIBUTE	Area	real
@ATTRIBUTE	Perímetro	REAL
@ATTRIBUTE	MayorlongitudEje	REAL
@ATTRIBUTE	MenorlongitudEje	REAL
@ATTRIBUTE	Areaconvexa	real
@ATTRIBUTE	Diametroequi	REAL
@ATTRIBUTE	Solidez	REAL
@ATTRIBUTE	redondez	REAL
@ATTRIBUTE	Factorforma1	REAL
@ATTRIBUTE	Factorforma2	REAL
@ATTRIBUTE	Clase	{K, B, Y, C, H, S, D}

TABLA III  
DETALLE ARCHIVO ARFF (FRAGMENTO)

28395,00	610,29	208,18	173,89	28715,00	190,14	0,99	0,96	0,01	0,00	K
28734,00	638,02	200,52	182,73	29172,00	191,27	0,98	0,89	0,01	0,00	K
29380,00	624,11	212,83	175,93	29690,00	193,41	0,99	0,95	0,01	0,00	K
30008,00	645,88	210,56	182,52	30724,00	195,47	0,98	0,90	0,01	0,00	K
30140,00	620,13	201,85	190,28	30417,00	195,90	0,99	0,98	0,01	0,00	K

c) *Segunda Selección de variables.* Tomando como referencia el archivo Arff, se realiza un proceso de selección por medio de la prueba Chi cuadrado y el método de ranqueo, el cual permite priorizar las variables como se ilustra en la Tabla IV.

TABLA IV  
PRIORIZACIÓN DE VARIABLES

Atributo	Ranqueo	%	Acumulado
Perímetro	39986,825	0,15036076	
Areaconvexa	39297,9834	0,14777054	0,2981313
Diametroequi	39160,6165	0,147254	0,4453853
Área	39157,3916	0,14724188	0,59262717
MayorlongitudEje	36913,0944	0,13880274	0,73142991
MenorlongitudEje	35304,3376	0,1327534	0,86418331
redondez	24367,384	0,09162764	0,95581095**
Factorforma1	8222,0585	0,03091706	0,98672801**
Solidez	3529,5428	0,01327199	1***
Factorforma2	0	0	1**
<b>TOTAL</b>	<b>265939,23</b>		

La Tabla 3, muestra que las cuatro últimas variables no tiene un peso significativo en el proceso (variables señaladas con \*), razón por la cual las mismas pueden ser descartadas, aspecto que permite reducir la dimensionalidad del archivo Arff.

d) *Predicción de la variable dependiente.* Por medio del algoritmo J48 y un proceso de clasificación basado en la plataforma Weka, se realiza la predicción de la variable dependiente, lográndose una efectividad superior al 90%. Como resultado de este proceso, se encuentra las respectivas matrices de clasificación, precisión, confusión y el respectivo árbol de clasificación, como se ilustra en las tablas V, VI, VII.

Este proceso se realiza, entrenado con el 90% de los datos y validando con el 10% de los mismos. Cuando se entrena y valida con el 100% de los datos se logra una efectividad superior al 93% como se ilustra en las tablas VIII, IX, X.

TABLA V  
MATRIZ DE CLASIFICACIÓN 90%-10%

Variable	#	%
Correctly Classified Instances	12304	90.3975 %
Incorrectly Classified Instances	1307	9.6025 %
Kappa statistic	0.8838	
Mean absolute error	0.0375	
Root mean squared error	0.1509	
Relative absolute error	15.8628 %	
Root relative squared error	43.9113 %	
Total Number of Instances	13611	

TABLA VI  
MATRIZ DE PRECISIÓN 90%-10%

TP Rate	FP Rate	Precisi on	Recall	F-Measure	ROC Area	Clas
0.925	0.011	0.937	0.925	0.931	0.98	K
0.842	0.01	0.896	0.842	0.868	0.965	B
0.998	0	0.996	0.998	0.997	0.999	Y
0.918	0.016	0.889	0.918	0.903	0.974	C
0.929	0.009	0.946	0.929	0.937	0.979	H
0.842	0.035	0.852	0.842	0.847	0.957	S
0.928	0.037	0.898	0.928	0.912	0.981	D
0.904	0.022	0.904	0.904	0.904	0.974	prom

TABLA VII  
MATRIZ DE CONFUSIÓN 90% - 10%

a	b	c	d	e	f	g	classi
1875	12	0	0	0	78	62	a = K
15	1113	1	143	14	36	0	b = B
0	1	521	0	0	0	0	c = Y
3	84	1	1496	34	12	0	d = C
0	18	0	33	1791	67	19	e = H
53	14	0	11	46	2219	293	f = S
55	0	0	0	9	193	3289	g = D

TABLA VIII  
MATRIZ DE CLASIFICACIÓN 100%-100%

Variable	#	%
Correctly Classified Instances	12739	93.5934 %
Incorrectly Classified Instances	872	6.4066 %
Kappa statistic	0.9225	
Mean absolute error	0.0295	
Root mean squared error	0.1214	
Relative absolute error	12.467 %	
Root relative squared error	35.3089 %	
Total Number of Instances	13611	

TABLA IX  
MATRIZ DE PRECISIÓN 100%-100%

TP Rate	FP Rate	Precisi	Recall	F-Measure	ROC Area	Class
0.958	0.008	0.957	0.958	0.957	0.995	K
0.905	0.005	0.955	0.905	0.93	0.994	B

TP Rate	FP Rate	Precisi	Recall	F-Measure	ROC Area	Class
0.998	0	1	0.998	0.999	1	Y
0.959	0.01	0.931	0.959	0.945	0.996	C
0.958	0.005	0.972	0.958	0.965	0.997	H
0.887	0.025	0.895	0.887	0.891	0.982	S
0.939	0.029	0.921	0.939	0.93	0.99	D
0.936	0.016	0.936	0.936	0.936	0.992	Prom

TABLA X  
MATRIZ DE CONFUSION 100%-100%

a	b	c	d	e	f	g	classi
1942	7	0	0	0	32	46	a = K
10	1197	0	94	5	16	0	b = B
0	1	521	0	0	0	0	c = Y
3	36	0	1563	17	11	0	d = C
0	7	0	19	1847	45	10	e = H
37	5	0	2	22	2339	231	f = S
38	0	0	0	9	169	3330	g = D

d) *Comparación de resultados.* Los resultados obtenidos en el paso anterior se comparan con otras técnicas. Este aspecto ilustrado en la Tabla XI, permite establecer la efectividad de los resultados obtenidos en este proceso.

TABLA XI  
COMPARACION DE RESULTADOS

Técnica	Éxito 80% - 20%	Éxito 90%-10%	Éxito 100%-100%
BayesNet	76.26	76.91	77.83
SMO	89.41	89.38	89.44
IB1	89.34	89.43	100
IBK	88.43	88.34	100
Tablas de decisión	88.02	87.83	89.83
BFTree	89.39	89.35	92.00
FT	91.49	91.58	93.04
J48graf	90.42	90.47	93.59
J48	90.34	90.39	93.59
Random forest	87.93	87.73	100

#### IV DISCUSIONES

En las revisiones literarias realizadas, no se evidencia muchos artículos los cuales permitan la clasificación de semillas de frijol con técnicas de inteligencia artificial. No obstante, en [7] sus autores realizan una clasificación de semillas de frijol con base en diferentes técnicas de inteligencia artificial lográndose porcentajes de éxitos similares a los obtenidos en esta investigación. Sin embargo, aunque ambos trabajos investigativos parten de una misma base de datos, es importante realizar que los procesos de selección de variables llevados a cabo en ambos estudios es diferente, razón por la cual se logran resultados diferentes. En este artículo se identifican 5 características principales (Perímetro, área convexa, diámetro equivalente, área, mayor longitud eje, menor longitud eje), las cuales permiten lograr una clasificación superior al 90%, que incluso según la técnica empleada puede llegar hasta el 100% de efectividad. No obstante, en el trabajo referenciado en [7] se determinan (para

el caso de los árboles de decisión) las siguientes características: Mayor longitud de eje, menor longitud de eje, perímetro, compactidad, factor de forma 1. Encontrándose así que, aunque las metodologías empleadas son diferentes, entre ambos trabajos desarrolladas existen tres características coincidentes: Mayor longitud eje, menor longitud eje y perímetro. Es importante resaltar que cuando se realiza la clasificación empleando el algoritmo J48 de la plataforma Weka, con solo estas tres características comunes entre ambos estudios, se logra una efectividad superior al 90% si se entrena y valida con el 90% y 10% de los datos respectivamente. Cuando se entrena y valida con el 100% de los datos se logra una efectividad del 93%. Como se ilustra a continuación en la Tabla XII

TABLA XII  
CLASIFICACION CON 3 VARIABLES. 100%-100%

Variable	#	%
Correctly Classified Instances	12670	93.0865 %
Incorrectly Classified Instances	941	6.9135 %
Kappa statistic	0.9164	
Mean absolute error	0.0317	
Root mean squared error	0.1258	
Relative absolute error	13.3995 %	
Root relative squared error	36.6057 %	
Total Number of Instances	13611	

El anterior análisis permite concluir que, al combinar adecuadamente, los resultados de las dos metodologías, la que se propone en [7] y la que se propone en este artículo, es posible reducir a tres las variables independientes, con las que se pueden lograr una adecuada clasificación de las semillas de frijol.

#### CONCLUSIONES

En este trabajo investigativo, se describe un proceso de gran trascendencia para clasificar semillas. Siguiendo la metodología propuesta solo es necesario controlar el rendimiento de tres variables (Mayor longitud eje, menor longitud eje y perímetro) para lograr una clasificación de semillas de frijol, en este caso, del 93%. Un proceso el cual puede ser aplicado en otras áreas de la investigación e incluso programado por diversos sistemas de inteligencia artificial. (El anexo I ilustra el respectivo árbol de decisión).

#### AGRADECIMIENTOS

Se agradece la colaboración a la Universidad Nacional de Colombia – Sede Manizales. Igualmente se agradece a: Dua, D. y Graff, C., UCI Machine Learning Repository [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, School of Information and Computer Science, (2019). Igualmente se agradece a: KOKLU, M. and OZKAN, I.A., (2020), “Multiclass Classification of Dry Beans Using Computer Vision and Machine Learning Techniques.”

Computers and Electronics in Agriculture, 174, 105507. DOI: <https://doi.org/10.1016/j.compag.2020.105507>

REFERENCES

[1] Z. Huang, R. Wang, y otros seis autores más, “Deep learning-based soybean seed classification”, *Computers and Electronics in Agriculture*, 202, 107393, pp 1-8, 2022.

[2] S. Zhou, L. Sun, y otros cinco autores más, “Hyperspectral imaging of beet seed germination prediction”, *Infrared Physics & Technology*, 108, 103363, pp 1-7, 2020.

[3] M. Ahmed, J. Yasmin y otros tres autores más, “Classification of pepper seed quality based on internal structure using X-ray CT imaging”, *Computers and Electronics in Agriculture*, 179, 105839, pp 1-8 ,2020

[4] A. Lu, R. Guo, y otros cuatro autores más, “Online sorting of drilled lotus seeds using deep Learning”, *biosystems engineering*, 221, 118- 137, 2022.

[5] F. Wang, Y. Ding, “Design and experimental study of a separating machine for seed and peel of camellia oleifera fruit”, *IFAC Papers Online*, 52-30, 87–91, 2019.

[6] M. Destain, R. Dobrescu y S. Mocanu, “Visual inspection system for automated sorting of seeds”, *POLITEHNICA University of Bucharest*, 2007.

[7] KOKLU, M. and OZKAN, I.A., (2020), “Multiclass Classification of Dry Beans Using Computer Vision and Machine Learning Techniques.” *Computers and Electronics in Agriculture*, 174, 105507. DOI: <https://doi.org/10.1016/j.compag.2020.105507>

[8] I. Witten, E. Frank y otros dos autores, “Data Mining Practical Machine Learning Tools and Techniques”, *Morgan and Kaufman publication (Elsevier)*, ISBN-13: 978-0128042915, Cambridge, USA, 2017.

[9] M. Valencia, J. Correa, y F. Díaz, “Métodos Estadísticos Clásicos y Bayesianos para el Pronóstico de Demanda. Un Análisis Comparativo”, <https://doi.org/10.15446/rev.fac.cienc.v4n1.49775>, *Revista Facultad de Ciencias Universidad Nacional de Colombia*, 4(1), pp. 52 -67, 2015.

ANEXO I ARBOL DE DECISION

```

Malongeje <= 328.843812
| MeLongeje <= 181.383174
| | Perimetro <= 704.877: D (2708.0/55.0)
| | Perimetro > 704.877
| | | Malongeje <= 296.141655
| | | | MeLongeje <= 160.864722
| | | | | Malongeje <= 270.832898: D (8.0)
| | | | | Malongeje > 270.832898: H (20.0/7.0)
| | | | | MeLongeje > 160.864722
| | | | | Perimetro <= 739.802: D (510.0/134.0)
| | | | | Perimetro > 739.802
| | | | | | MeLongeje <= 164.55675: D (6.0/1.0)
| | | | | | MeLongeje > 164.55675: S (228.0/92.0)
| | | | | Malongeje > 296.141655
| | | | | | MeLongeje <= 171.016998: H (98.0/5.0)
| | | | | | MeLongeje > 171.016998
| | | | | | | Perimetro <= 793.537
| | | | | | | Perimetro <= 770.034
| | | | | | | | Malongeje <= 299.743006
| | | | | | | | Perimetro <= 766.442
| | | | | | | | | MeLongeje <= 176.331377: H (2.0/1.0)
| | | | | | | | | MeLongeje > 176.331377: D (2.0)

```

```

| | | | | | Perimetro > 766.442: S (3.0)
| | | | | | | Malongeje > 299.743006: D (4.0)
| | | | | | | Perimetro > 770.034: S (59.0/8.0)
| | | | | | | Perimetro > 793.537
| | | | | | | | MeLongeje <= 172.698586: H (4.0)
| | | | | | | | MeLongeje > 172.698586: S (43.0/12.0)
| | | | | | | | | MeLongeje > 181.383174
| | | | | | | | | | Malongeje <= 277.523871
| | | | | | | | | | | MeLongeje <= 189.499071
| | | | | | | | | | | | Malongeje <= 253.499316
| | | | | | | | | | | | Malongeje <= 237.638341
| | | | | | | | | | | | | MeLongeje <= 182.64152
| | | | | | | | | | | | | | Perimetro <= 665.261: K (9.0/1.0)
| | | | | | | | | | | | | | Perimetro > 665.261: D (2.0)
| | | | | | | | | | | | | | MeLongeje > 182.64152: K (115.0/1.0)
| | | | | | | | | | | | | | | Malongeje > 237.638341
| | | | | | | | | | | | | | | | MeLongeje <= 187.619785
| | | | | | | | | | | | | | | | | Malongeje <= 240.108184: K (8.0/2.0)
| | | | | | | | | | | | | | | | | Malongeje > 240.108184
| | | | | | | | | | | | | | | | | | Perimetro <= 705.861: D (49.0/14.0)
| | | | | | | | | | | | | | | | | | Perimetro > 705.861: K (6.0/2.0)
| | | | | | | | | | | | | | | | | | | MeLongeje > 187.619785
| | | | | | | | | | | | | | | | | | | | Perimetro <= 700.283: K (28.0/1.0)
| | | | | | | | | | | | | | | | | | | | | Perimetro > 700.283
| | | | | | | | | | | | | | | | | | | | | | Perimetro <= 703.908: D (2.0)
| | | | | | | | | | | | | | | | | | | | | | Perimetro > 703.908: K (9.0/2.0)
| | | | | | | | | | | | | | | | | | | | | | | Malongeje > 253.499316
| | | | | | | | | | | | | | | | | | | | | | | | Perimetro <= 745.847: D (282.0/96.0)
| | | | | | | | | | | | | | | | | | | | | | | | Perimetro > 745.847
| | | | | | | | | | | | | | | | | | | | | | | | | Malongeje <= 270.261401
| | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro <= 749.469: S (3.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro > 749.469
| | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje <= 269.1773: D (5.0/1.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje > 269.1773: K (2.0/1.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje > 270.261401: S (45.0/8.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje > 189.499071
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje <= 258.796182: K (1221.0/16.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje > 258.796182
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje <= 199.261078
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje <= 192.22169
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro <= 745.326: D (35.0/16.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro > 745.326: S (26.0/4.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje > 192.22169
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro <= 750.885
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro <= 746.036: K (65.0/21.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro > 746.036
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje <= 193.523791: D (4.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje > 193.523791
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro <= 747.535: D (6.0/2.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro > 747.535: K (5.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro > 750.885
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje <= 193.327787: S (7.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje > 193.327787
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje <= 194.387903
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje <= 193.641169: K (2.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje > 193.641169
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje <= 274.773087: D (5.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje > 274.773087: S (3.0/1.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje > 194.387903
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje <= 272.588625
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje <= 272.171814
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje <= 271.828264: S (10.0/4.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje > 271.828264: K (2.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje > 272.171814: D (2.0)
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Malongeje > 272.588625
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | MeLongeje <= 198.48644
| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | Perimetro <= 760.534

```

Perimetro <= 756.121: K (3.0)	Perimetro <= 860.079: S (5.0/1.0)
Perimetro > 756.121: S (3.0)	Perimetro > 860.079: K (2.0/1.0)
Perimetro > 760.534: K (5.0)	Perimetro > 870.84
MeLongeje > 198.48644: S (4.0)	Perimetro <= 887.573
MeLongeje > 199.261078: K (369.0/12.0)	MeLongeje <= 211.808796
Malongeje > 277.523871	Malongeje <= 324.569677: B (16.0/2.0)
Perimetro <= 870.84	Malongeje > 324.569677
MeLongeje <= 206.305728	Perimetro <= 873.825: B (3.0/1.0)
Perimetro <= 773.165	Perimetro > 873.825: S (7.0)
MeLongeje <= 188.797358	MeLongeje > 211.808796
Perimetro <= 760.195	Perimetro <= 879.376: K (8.0/2.0)
Malongeje <= 284.95803: S (118.0/42.0)	Perimetro > 879.376
Malongeje > 284.95803	MeLongeje <= 215.184493: S (2.0)
Perimetro <= 756.895: D (9.0/3.0)	MeLongeje > 215.184493: B (3.0)
Perimetro > 756.895	Perimetro > 887.573: B (95.0/11.0)
Malongeje <= 287.586063	Malongeje > 328.843812
Malongeje <= 285.257434: D (2.0)	MeLongeje <= 210.457299
Malongeje > 285.257434: S (8.0/1.0)	Malongeje <= 349.029689
Malongeje > 287.586063: D (7.0/1.0)	MeLongeje <= 184.986706
Perimetro > 760.195: S (126.0/21.0)	Malongeje <= 329.999162
MeLongeje > 188.797358	Perimetro <= 839.624: S (4.0/1.0)
Perimetro <= 764.419	Perimetro > 839.624: H (3.0)
MeLongeje <= 194.1598	Malongeje > 329.999162: H (169.0/2.0)
MeLongeje <= 189.956042: S (17.0/1.0)	MeLongeje > 184.986706
MeLongeje > 189.956042	Perimetro <= 897.153
Perimetro <= 753.637: K (3.0/2.0)	MeLongeje <= 190.521424
Perimetro > 753.637	Perimetro <= 859.959: S (18.0/2.0)
MeLongeje <= 191.246135: D (13.0/6.0)	Perimetro > 859.959: H (17.0/6.0)
MeLongeje > 191.246135: S (9.0/1.0)	MeLongeje > 190.521424: S (153.0/21.0)
MeLongeje > 194.1598: K (7.0/1.0)	Perimetro > 897.153
Perimetro > 764.419	Perimetro <= 922.051
MeLongeje <= 196.324913: S (66.0)	MeLongeje <= 205.005038
MeLongeje > 196.324913	Malongeje <= 340.089725: B (3.0)
Perimetro <= 768.648: S (2.0)	Malongeje > 340.089725
Perimetro > 768.648: K (6.0/2.0)	Malongeje <= 347.968868: H (5.0/1.0)
Perimetro > 773.165	Malongeje > 347.968868: S (3.0/1.0)
Perimetro <= 837.928: S (1327.0/48.0)	MeLongeje > 205.005038
Perimetro > 837.928	Malongeje <= 347.444758: C (5.0/1.0)
Malongeje <= 305.961016: B (12.0/5.0)	Malongeje > 347.444758
Malongeje > 305.961016	Perimetro <= 910.152: S (2.0)
MeLongeje <= 190.358233	Perimetro > 910.152: C (2.0)
Malongeje <= 325.844215: H (4.0)	Perimetro > 922.051: B (14.0/1.0)
Malongeje > 325.844215: S (4.0)	Malongeje > 349.029689
MeLongeje > 190.358233: S (184.0/6.0)	MeLongeje <= 195.205335: H (1194.0/9.0)
MeLongeje > 206.305728	MeLongeje > 195.205335
Malongeje <= 302.538278	Perimetro <= 928.865
MeLongeje <= 214.467628	MeLongeje <= 197.91237
Perimetro <= 804.782: K (28.0/1.0)	Perimetro <= 904.977
Perimetro > 804.782	Malongeje <= 350.539258: H (3.0/1.0)
Perimetro <= 846.716	Malongeje > 350.539258: S (3.0)
Perimetro <= 810.566	Perimetro > 904.977: H (15.0/3.0)
Perimetro <= 807.981: S (3.0)	MeLongeje > 197.91237: S (36.0/19.0)
Perimetro > 807.981: B (3.0/1.0)	Perimetro > 928.865
Perimetro > 810.566: K (19.0/9.0)	Malongeje <= 379.72712
Perimetro > 846.716: B (2.0)	MeLongeje <= 203.742599: H (47.0/6.0)
MeLongeje > 214.467628: K (79.0/4.0)	MeLongeje > 203.742599
Malongeje > 302.538278	Malongeje <= 358.558678: B (4.0)
MeLongeje <= 210.693454: S (50.0/3.0)	Malongeje > 358.558678
MeLongeje > 210.693454	Perimetro <= 970.092
Perimetro <= 854.392	Malongeje <= 375.547357: H (22.0/8.0)
Malongeje <= 308.769858	Malongeje > 375.547357: C (4.0)
Perimetro <= 835.676: K (2.0/1.0)	Perimetro > 970.092
Perimetro > 835.676: S (4.0/1.0)	Malongeje <= 375.472172: B (4.0/1.0)
Malongeje > 308.769858: K (4.0)	Malongeje > 375.472172
Perimetro > 854.392	Perimetro <= 978.422: C (2.0)
MeLongeje <= 212.702953: B (2.0)	Perimetro > 978.422: H (2.0)
MeLongeje > 212.702953	Malongeje > 379.72712: H (271.0/11.0)

MeLongeje > 210.457299	Perimetro > 1089.842
MeLongeje <= 303.898305	Malongeje <= 418.872963
Malongeje <= 381.641963	Perimetro <= 1113.526
Perimetro <= 1004.224	Malongeje <= 409.281405
Malongeje <= 363.84369	MeLongeje <= 257.664828: B (48.0)
Perimetro <= 899.204	MeLongeje > 257.664828
MeLongeje <= 212.42636: K (2.0/1.0)	Malongeje <= 400.343978: B (15.0/1.0)
MeLongeje > 212.42636: S (8.0)	Malongeje > 400.343978: C (3.0)
Perimetro > 899.204	Malongeje > 409.281405
Perimetro <= 969.999	MeLongeje <= 249.294179
Malongeje <= 349.560119: B (82.0/14.0)	Malongeje <= 416.110148: B (8.0/1.0)
Malongeje > 349.560119	Malongeje > 416.110148: C (4.0)
Malongeje <= 363.288259	MeLongeje > 249.294179: C (13.0/1.0)
Perimetro <= 941.12: C (21.0/4.0)	Perimetro > 1113.526: B (190.0/1.0)
Perimetro > 941.12	Malongeje > 418.872963
MeLongeje <= 222.530698: B (33.0/11.0)	Perimetro <= 1168.211
MeLongeje > 222.530698: C (36.0/12.0)	MeLongeje <= 224.464239
Malongeje > 363.288259: C (4.0/1.0)	MeLongeje <= 217.492232: H (3.0)
Perimetro > 969.999	MeLongeje > 217.492232: C (3.0/1.0)
Malongeje <= 357.319044: B (82.0)	MeLongeje > 224.464239
Malongeje > 357.319044	Malongeje <= 432.154231
MeLongeje <= 231.757344: B (17.0)	Perimetro <= 1122.763: C (117.0/2.0)
MeLongeje > 231.757344	Perimetro > 1122.763
Perimetro <= 990.057: C (7.0/1.0)	MeLongeje <= 259.223193: B (14.0/2.0)
Perimetro > 990.057: B (6.0/1.0)	MeLongeje > 259.223193
Malongeje > 363.84369	Malongeje <= 421.925431: B (3.0)
Malongeje <= 370.874913	Malongeje > 421.925431: C (9.0)
Perimetro <= 982.432: C (40.0/5.0)	Malongeje > 432.154231: C (244.0/4.0)
Perimetro > 982.432: B (11.0/1.0)	Perimetro > 1168.211
Malongeje > 370.874913: C (108.0/13.0)	Malongeje <= 451.557492
Perimetro > 1004.224: B (466.0/14.0)	Malongeje <= 439.823932: B (32.0)
Malongeje > 381.641963	Malongeje > 439.823932
Perimetro <= 1089.842	Perimetro <= 1192.258: C (7.0/1.0)
MeLongeje <= 219.860232	Perimetro > 1192.258: B (13.0/1.0)
Perimetro <= 1066.901: C (94.0/23.0)	Malongeje > 451.557492
Perimetro > 1066.901	Perimetro <= 1240.715: C (74.0)
Malongeje <= 414.554219: B (5.0/1.0)	Perimetro > 1240.715
Malongeje > 414.554219: H (10.0)	Malongeje <= 483.717365: B (8.0/1.0)
MeLongeje > 219.860232	Malongeje > 483.717365: C (8.0)
Malongeje <= 397.763186	MeLongeje > 303.898305: Y (523.0/1.0)
Perimetro <= 1048.432	
Perimetro <= 1026.183: C (193.0/8.0)	
Perimetro > 1026.183	
Malongeje <= 389.048708	
MeLongeje <= 239.378085: B (16.0/5.0)	
MeLongeje > 239.378085: C (4.0)	
Malongeje > 389.048708: C (55.0/7.0)	
Perimetro > 1048.432	
Perimetro <= 1064.746	
MeLongeje <= 255.473201: B (29.0/4.0)	
MeLongeje > 255.473201: C (3.0)	
Perimetro > 1064.746: B (41.0)	
Malongeje > 397.763186	
Perimetro <= 1081.439	
Malongeje <= 404.970023	
Perimetro <= 1066.901: C (161.0/7.0)	
Perimetro > 1066.901	
Malongeje <= 400.718857: C (3.0/1.0)	
Malongeje > 400.718857: B (7.0)	
Malongeje > 404.970023: C (347.0/4.0)	
Perimetro > 1081.439	
Malongeje <= 408.944886	
Perimetro <= 1087.792	
MeLongeje <= 242.908887: B (3.0)	
MeLongeje > 242.908887: C (2.0)	
Perimetro > 1087.792: H (2.0)	
Malongeje > 408.944886: C (71.0/6.0)	