

AFD - RESUMEN

Este enfoque conduce a s combinaciones lineales, donde $s = \text{Mín} \{p \text{ (número de variables), } m-1 \text{ (número de grupos menos uno)}\}$.

Encontrar estas combinaciones lineales, no correlacionadas dentro de los grupos, es un problema de valores propios.

- ✓ Se manejaron las **pruebas de significación** para determinar cuántas combinaciones lineales se necesitan para describir las diferencias de grupo. Algunas pruebas que se utilizan comúnmente pueden no proporcionar buenos resultados.
- ✓ Se analizaron los **supuestos del análisis de la función discriminante estándar** (normalidad e igualdad de matrices de covarianza intragrupo).

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

AFD - RESUMEN

- ✓ Se consideraron dos **ejemplos**.
- ✓ Se analizaron **opciones para variar el AFD** (probabilidades a-priori de pertenecer a un grupo, análisis paso a paso, y clasificación de las observaciones denominada "cuchillo de Jack").
- ✓ Extensiones a los métodos que cubre el curso (**modelo cuadrático**)

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

¿Cómo realizar un Análisis Discriminante con XLSTAT?

Datos: 150 flores de la familia Iris, definidas por 4 variables cuantitativas (Longitud-Sépalos, Anchura-Sépalos, Longitud-Pétalos, Anchura-Pétalos) y por su especie [Fisher M. (1936). The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, 7, pp 179 -188]. Tres diferentes especies forman parte de este estudio: setosa, versicolor y virginica.

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT



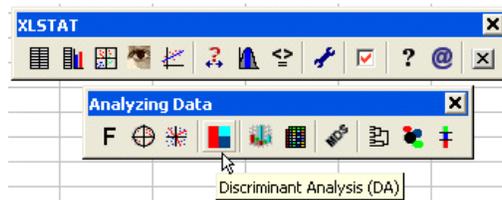
Iris setosa, versicolor y virginica

Objetivo: Probar si las cuatro variables descriptivas permiten identificar las especies, y visualizar los datos en un gráfico con el fin de comprobar que las tres especies pueden diferenciarse correctamente.

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

Inicie XLSTAT y seleccione el comando XLSTAT/Análisis de los datos/Análisis Factorial Discriminante o haga clic en el botón "Análisis Factorial Discriminante" de la barra de herramientas "Análisis de los datos".

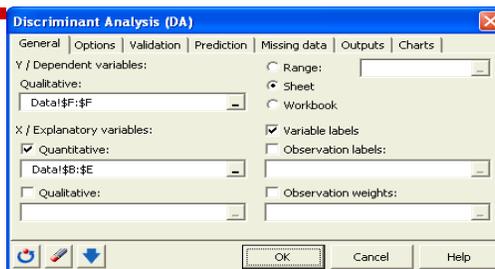


AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

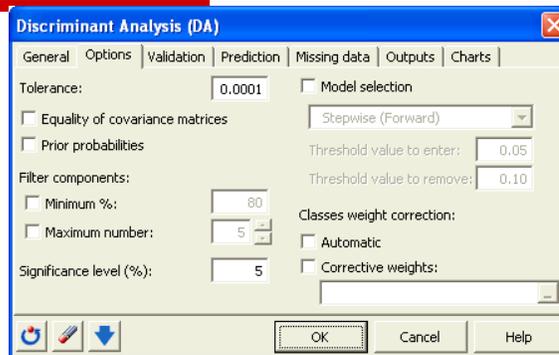
Cuadro de diálogo del AFD

Selección de datos en la hoja Excel: 1) La "Variable dependiente" representa la variable explicada (grupos), que en este caso es la especie de Iris. 2) Las "variables explicativas" son las cuatros variables medidas. La opción "Etiquetas de las columnas" se activa puesto que la primera fila de las columnas incluye el nombre de las variables.



AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT



Opciones: Hemos **deshabilitado** la opción "Igualdad de las matrices de covarianza intra-grupos", ya que como lo veremos más tarde (Prueba de Box), efectuar semejante hipótesis no es correcto.

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

Resultados

XLSTAT visualiza las matrices utilizadas en los cálculos. Las dos pruebas de Box permiten confirmar que no se puede suponer que las matrices de covarianza sean idénticas para las 3 especies.

Box's test (Chi-square asymptotic approximation):	
Chi-square	142.373
Chi-square	31410
DF	20
One-tailed	< 0.0001
Alpha	0.05
Decision:	
At the level of significance Alpha=0.050 the decision is to reject the null hypothesis of equality of the within-groups covariance matrices. In other words, the difference between the within-groups covariance matrices is significant.	
Box's test (Fisher's F asymptotic approximation):	
F (observe)	7.113
F (critical v)	1573
DF 1	20
DF 2	27150
One-tailed	< 0.0001
Alpha	0.05
Decision:	
At the level of significance Alpha=0.050 the decision is to reject the null hypothesis of equality of the within-groups covariance matrices. In other words, the difference between the within-groups covariance matrices is significant.	

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

La prueba "Lambda de Wilk" permite probar si los vectores de las medias para los diferentes grupos son iguales o no [esta prueba se puede percibir como un equivalente multidimensional de la prueba LSD ("menor diferencia significativa") de Fisher o de la prueba HSD ("diferencia honestamente significativa") de Tukey]. Aquí observamos que la diferencia entre los vectores es significativa para un nivel de significancia de 0.05.

Wilks' Lambda test:	
Lambda	0.023
F (observe)	199.145
F (critical v)	1.990
DF 1	8
DF 2	298
One-tailed	< 0.0001
Alpha	0.05
<i>The F-value is computed according to the Rao's approximation</i>	
Decision:	
At the level of significance Alpha=0.050 the decision is to reject the null hypothesis of equality of mean vectors of the 3 groups.	
In other words, the difference between the groups centroids is significant.	

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

En la siguiente tabla se visualizan las **funciones discriminantes**. Cuando se supone que las matrices de covarianza son iguales, estas funciones son lineales. En el caso contrario, son cuadráticas, como es el caso aquí.

Regla básica: se le atribuye una observación al grupo cuya F.D. proporciona el valor más elevado.

Classification functions:			
	Setosa	Versicolor	Virginica
Intercept	-121.826	-76.549	-75.821
SEPAL LENGTH	4.455	1.801	0.737
SEPAL WIDTH	-0.762	1.596	1.325
PETAL LENGTH	3.356	0.327	0.623
PETAL WIDTH	-3.126	-1.471	0.966
SEPAL LENGTH*SEPAL LENGTH	-0.095	-0.048	-0.053
SEPAL LENGTH*SEPAL WIDTH	0.124	0.037	0.035
SEPAL LENGTH*PETAL LENGTH	0.045	0.086	0.100
SEPAL LENGTH*PETAL WIDTH	0.048	-0.065	-0.018
SEPAL WIDTH*SEPAL WIDTH	-0.078	-0.099	-0.079
SEPAL WIDTH*PETAL LENGTH	-0.011	-0.021	-0.011
SEPAL WIDTH*PETAL WIDTH	0.021	0.195	0.085
PETAL LENGTH*PETAL LENGTH	-0.194	-0.099	-0.067
PETAL LENGTH*PETAL WIDTH	0.179	0.269	0.029
PETAL WIDTH*PETAL WIDTH	-0.530	-0.436	-0.097

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

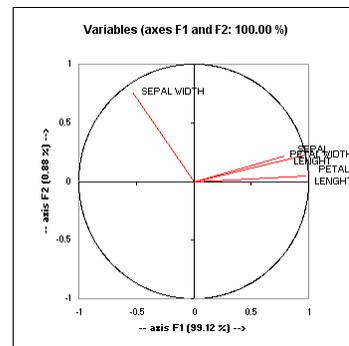
La siguiente tabla proporciona los **valores propios** y el **% de varianza** correspondiente. En este caso, el 99% de la varianza está explicada por el primer factor. Aparecen solamente dos factores: En efecto, el número máximo de factores no nulos es $k-1$, cuando $n > p > k$, donde n = nro. de observaciones, p = nro. de variables explicativas y k = nro. de grupos.

Eigenvalues and percentage of variance:		
	F1	F2
Eigenvalue	32.192	0.285
% variance	99.121	0.879
% cumulat	99.121	100.000

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

El siguiente gráfico muestra que las cuatro primeras variables están correlacionadas con los dos factores obtenidos (este gráfico está construido a partir de la tabla de las coordenadas de las variables). Se puede observar que el factor F1 está correlacionado con Long. Sép., Long. Pét. y Anch. Pét. y que F2 está correlacionado con Anch. Pét.



AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

La siguiente tabla enumera para cada flor, **sus coordenadas factoriales, la probabilidad de asignación a cada grupo, y el cuadrado de las distancias de Mahalanobis respecto al centroide de cada grupo.**

Cada observación es reclasificada en el grupo para el cual la probabilidad es máxima. Las probabilidades son probabilidades a posteriori, que toman en cuenta las probabilidades a priori a través de la fórmula de Bayes.

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

Prior-classification, post-classification, membership probability, observation scores and squared distances to the groups' centroids:

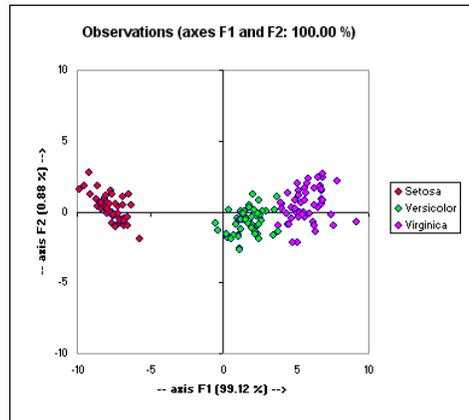
Observatio	Prior	Post	Prob.	Setosob.	Versicob.	Virgini	F1	F2	centroid(Setroid(Versntroid(Virginea))
Obs1	Setosa	Setosa	1.000	0.000	0.000	-1.528	6.528	5.848	108.331	179.145		
Obs2	Virginica	Virginica	0.000	0.000	1.000	2.444	7.244	770.307	42.266	11.244		
Obs3	Versicolor	Versicolor	0.000	0.997	0.003	1.277	6.191	423.336	10.002	21.859		
Obs4	Virginica	Virginica	0.000	0.000	1.000	2.404	8.463	813.456	53.028	11.666		
Obs5	Virginica	Versicolor	0.000	0.505	0.395	1.625	5.720	520.064	12.326	13.778		
Obs6	Setosa	Setosa	1.000	0.000	0.000	-1.402	7.019	8.778	103.550	163.512		
Obs7	Virginica	Virginica	0.000	0.000	1.000	1.979	8.656	683.968	55.639	17.807		
Obs8	Versicolor	Versicolor	0.000	0.813	0.187	1.538	4.378	431.446	20.036	22.976		
Obs9	Versicolor	Virginica	0.000	0.336	0.664	1.598	7.705	468.109	16.061	14.656		
Obs10	Setosa	Setosa	1.000	0.000	0.000	-1.905	7.541	16.389	138.753	205.927		
Obs11	Versicolor	Versicolor	0.000	0.997	0.003	1.207	6.330	391.790	8.841	20.433		
Obs12	Versicolor	Virginica	0.000	0.154	0.846	1.812	5.780	534.065	16.635	12.233		
Obs13	Virginica	Virginica	0.000	0.001	0.999	1.941	7.485	623.539	24.287	10.605		
Obs14	Versicolor	Versicolor	0.000	1.000	0.000	0.877	5.036	252.687	8.955	29.434		
Obs15	Virginica	Virginica	0.000	0.033	0.967	1.968	6.637	652.105	17.382	10.633		

Las observaciones (5,9,12) fueron reclasificadas. Puede haber varias razones: la persona que efectuó las mediciones ha cometido un error cuando medía, o los iris que corresponden a estos datos han tenido un crecimiento anormal por razones desconocidas, o el criterio de clasificación utilizado por el especialista no es correcto, o falta información para diferenciar perfectamente las especies entre sí.

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

El siguiente gráfico representa las observaciones sobre los ejes factoriales. Este gráfico permite confirmar que las observaciones están correctamente discriminadas sobre los ejes factoriales obtenidos a partir de las variables explicativas iniciales.



AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.

APLICACIONES CON XLSTAT

Por último, la **matriz de confusión** resume la información que concierne las reclasificaciones de observaciones, y se puede deducir el **índice de error aparente**, que corresponde a la razón del número de observaciones reclasificadas, sobre el número total de observaciones.

Confusion matrix (learning-sample):				
	to Setosa	to Versicoloto	to Virginica	Sum
from Setos	50 33.33%	0 0.00%	0 0.00%	50 33.33%
from Versi	0 0.00%	48 32.00%	2 1.33%	50 33.33%
from Virgir	0 0.00%	1 0.67%	49 32.67%	50 33.33%
Sum	50 33.33%	49 32.67%	51 34.00%	150 100.00%

Apparent error rate (resubstitution error rate calculated with the learning-sample): 2.00 %

AMARN 2018 - IMFIA.FI.UDELAR -
Ing. Luis Silveira, Ph.D.