



**UNIVERSIDAD NACIONAL AUTÓNOMA
DE MÉXICO**

FACULTAD DE CIENCIAS

**Aplicación de componentes independientes a la base de
datos E.coli**

T E S I S

QUE PARA OBTENER EL TÍTULO DE:

MATEMÁTICA

P R E S E N T A:

ARIADNA ARIZAGA GONZÁLEZ



DIRECTORA DE TESIS:

MAT. MARGARITA ELVIRA CHÁVEZ CANO

CIUDAD UNIVERSITARIA, CD.MX., 2022



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Índice

Introducción	4
Capítulo 1	5
1.1 Análisis de Componentes Principales (PCA)	5
1.1.1 Descripción del método de PCA	6
1.1.2 Cálculo de las componentes principales	6
1.1.3 Porcentajes de variabilidad	9
1.1.4 Componentes principales muestrales	11
1.1.5 Componentes principales a partir de la matriz de correlación	13
1.1.6 Decidir cuántas componentes retener	13
1.1.7 Correlación entre las variables originales y las componentes principales	14
1.2 Análisis de Componentes Independientes (ICA)	15
El efecto cocktail party (motivación)	15
1.2.1 Descripción del método de ICA	17
1.2.2 Condiciones en el modelo de ICA	18
1.2.3 Blanqueamiento (también llamado esfericidad)	21
1.2.4 Normalidad e independencia	23
1.3 Comparación del PCA y el ICA	25
Capítulo 2	26
Introducción	26
Descripción de la base	27
2.1 Análisis exploratorio de datos	28
2.1.1 Descripción de los datos	28
2.1.2 Análisis de la correlación de los datos	29
2.1.3 Matriz de dispersión de datos Iris	30
2.1.4 Curvas de Andrews para datos Iris	31
2.1.5 Diagrama de Caja	32

2.2 Análisis de componentes principales	33
2.2.1 Aplicación	33
2.2.2 Componentes principales	35
2.3 Análisis de componentes independientes (FastICA)	38
2.3.1 Calculando las cuatro componentes independientes	38
2.3.2 Calculando las dos primeras componentes independientes	39
2.3.3 Gráfica de mezclas con proceso previo	40
2.3.4 Gráficas de las componentes independientes	41
Comparación del modelo PCA contra el modelo ICA	43
Capítulo 3	45
Aplicación a la base de datos E.coli	45
Introducción	45
Descripción de la base de datos E.coli	47
3.1 Análisis exploratorio de datos	49
3.1.1 Descripción de los datos	49
3.1.2 Análisis de la correlación de los datos E.coli	51
3.1.3 Matriz de dispersión para los datos E.coli	53
3.1.4 Curvas de Andrews para datos E.coli	54
3.1.5 Diagrama de caja	55
3.2 Análisis de componentes principales	56
3.2.1 Aplicación	56
3.2.2 Componentes principales	58
3.2.3 Biplot	63
3.3 Análisis de componentes independientes (FastICA)	64
3.3.1 Calculando las 7 componentes independientes	64
3.3.2 Calculando las 3 primeras componentes independientes	65
3.3.3 Gráfica de mezclas con blanqueamiento	66
3.3.4 Gráficas de las componentes independientes	68

Conclusiones	71
Referencias	75
Código en R	76
Anexo A	80
Anexo B	84
Anexo C	88
Anexo D	104
Bases de datos	112
Glosario	124

Introducción

Las proteínas determinan la forma y la estructura de las células y dirigen casi todos los procesos vitales. Las funciones de las proteínas son específicas para cada una y permiten a las células defenderse de agentes externos, reparar daños, controlar y regular funciones. Por ello en la rama médica es importante localizar el tipo de proteína en las células para así poder extraerla, separar partes de su estructura molecular, o simplemente entender cómo funciona en toda su complejidad y con ello diseñar antibióticos para luchar contra distintas infecciones.

Para la parte experimental tomaremos una base de datos de la bacteria *E.coli* recopilados en un estudio de localización de la proteína en las células.

De *Escherichia coli* se conoce extensamente la genómica hay decenas de cepas secuenciadas, desde algunas patológicas a otras que no lo son y la proteómica de complejos (mapa de los complejos de proteínas). Además, es el organismo modelo donde se han hecho más estudios de metabolómica (el mapa de los ciclos metabólicos).

La mayoría de los tipos de *E.coli* son inofensivos y además son parte importante de un intestino sano en los seres humanos. Sin embargo algunos tipos de *E.coli* pueden causar distintas infecciones.

El estudio de la bacteria *E.coli* es de gran importancia para diagnosticar enfermedades infecciosas y reducir el riesgo de infección a causa de esta bacteria que se encuentra presente en el medio ambiente, los alimentos y los intestinos de personas y animales. Además de ser la bacteria más usada en biotecnología para producir grandes cantidades de material químico, como la artemisina para tratar la malaria o la insulina para la diabetes.

En esta tesis se realiza un estudio mediante el análisis de componentes independientes (ICA) y el análisis de componentes principales (PCA) con el fin de comparar los resultados de ambos análisis, para determinar si existe alguna relación entre la separación de señales independientes y las agrupaciones no correlacionadas.

Es importante destacar que la bacteria *E.coli* es un buen organismo modelo y las conclusiones son extrapolables a muchas otras bacterias como por ejemplo: *Helicobacter pylori*, *Vibrio cholera*, *Haemophilus influenzae*, *Neisseria meningitidis* y *Yersinia pestis*.

Capítulo 1

1.1 Análisis de Componentes Principales (PCA)

El análisis de componentes surgió en un trabajo de Karl Pearson en 1901 y no fue sino hasta 1933 que Harold Hotelling la desarrolló con todo el rigor matemático, se trata de una técnica descriptiva por lo que no requiere usar un método estadístico subyacente para explicar la estructura del error. En particular no se hace ninguna suposición acerca de la distribución de probabilidad de las variables originales, aunque se puede dar más significado a las componentes en el caso donde las observaciones se supone que provienen de una normal multivariada.

El análisis de componentes principales tiene como objetivo transformar un conjunto de n variables, a las que se les denomina originales, en un nuevo conjunto de m variables denominados componentes principales. Estas últimas se caracterizan por estar no correlacionadas entre sí.

Se buscan $m < n$ variables que sean combinaciones lineales de las n variables originales que no están correlacionadas, las cuales se van eligiendo con respecto a la cantidad de información que proveen de la muestra. Para medir la cantidad de información que contiene cada componente principal se utiliza la varianza. Cuanto mayor sea su varianza mayor es la cantidad de información que contiene dicha componente. Por esta razón se selecciona por primera componente aquella que tenga mayor varianza, mientras que la última componente es la de menor varianza.

La diferencia entre ambos conjuntos de variables consiste en que las componentes principales se calculan de tal forma que no estén correlacionadas entre sí, mientras que las variables originales están muy correlacionadas entre sí. Cuando las variables originales están muy correlacionadas entre sí, la mayor parte de variabilidad se puede explicar con muy pocas componentes principales. Pero si las variables originales no están correlacionadas entre sí, el análisis de componentes principales carecería por completo de interés, ya que en ese caso las componentes principales coincidirían con las variables originales.

El análisis de componentes principales es considerado como un método para reducir la dimensión de un conjunto de datos. Por lo tanto es necesario seleccionar la menor cantidad de componentes principales con las que se pueda representar la mayor proporción de variabilidad de los datos.

1.1.1 Descripción del método de PCA

Se considera un vector de variables aleatorias $\mathbf{X}^T = (X_1, X_2, \dots, X_p)$ sobre un grupo de objetos o individuos y se trata de calcular, a partir de estas, un nuevo conjunto de variables $\mathbf{Y} = (Y_1, Y_2, \dots, Y_p)$, no correlacionadas, cuyas varianzas vayan decreciendo progresivamente.

Otro de los propósitos de este análisis además de la reducción de dimensionalidad es encontrar grupos en los datos, graficando los scores o puntajes que a su vez ayudará a asociar características a los datos.

1.1.2 Cálculo de las componentes principales

Suponemos, como siempre lo haremos, que se tiene un vector de variables aleatorias \mathbf{X} con características distribucionales desconocidas, sin embargo, podemos suponer que:

$$E(\mathbf{X}) = \mu, \quad Var(\mathbf{X}) = \Sigma$$

donde Σ contiene la estructura de dependencia y varianza de las variables originales.

La primera componente será una combinación lineal de las variables originales de tal forma que esta nueva variable tenga la máxima varianza posible.

Sea Y_1 la primera combinación:

$$Y_1 = a_1^T \mathbf{X}$$

donde $a_1^T = (a_{11}, a_{21}, \dots, a_{p1})$ y $\mathbf{X}^T = (X_1, X_2, \dots, X_p)$, de esta forma

$$Var(Y_1) = Var(a_1^T \mathbf{X}) = a_1^T \Sigma a_1$$

el problema se plantea como

$$Max[a_1^T \Sigma a_1]$$

sujeto a $a_1^T a_1 = 1$. La restricción se plantea con el propósito de tener unicidad en la solución del problema. Entonces se construye la función φ :

$$\varphi = a_1^T \Sigma a_1 - \lambda(a_1^T a_1 - 1)$$

buscamos el máximo, derivando e igualando a cero

$$\frac{\partial \varphi}{\partial a_1} = 2\Sigma a_1 - 2\lambda a_1 = 0$$

y $\frac{\partial \varphi}{\partial \lambda} = 0$ lleva a la condición inicial $a_1^T a_1 = 1$, entonces

$$2\Sigma a_1 - 2\lambda a_1 = 0 \iff \Sigma a_1 - \lambda a_1 = 0 \iff (\Sigma - \lambda \mathbf{I})a_1 = 0$$

la última igualdad tiene solución no trivial solamente si $(\Sigma - \lambda \mathbf{I})$ es una matriz singular y por lo tanto su determinante es igual a cero:

$$|\Sigma - \lambda \mathbf{I}| = 0,$$

éste es conocido como el polinomio característico de Σ y su grado depende del orden de Σ que suponemos que es p . De las igualdades anteriores podemos ver que:

$$\Sigma a_1 - \lambda a_1 = 0 \iff \Sigma a_1 = \lambda a_1$$

lo que significa que, la solución del problema se reduce a obtener los valores y vectores propios de Σ , en este caso debemos escoger el valor propio más grande ya que:

$$Var(a_1^T \mathbf{X}) = Var(Y_1) = a_1^T \Sigma a_1 = \lambda$$

ya que:

$$\Sigma a_1 - \lambda a_1 = 0 \iff \Sigma a_1 = \lambda a_1 \iff a_1^T \Sigma a_1 = \lambda a_1^T \mathbf{I} a_1 \iff a_1^T \Sigma a_1 = \lambda a_1^T a_1 = \lambda$$

Esto significa que el primer valor propio de Σ es la varianza de la primera componente principal. Por lo que, la solución es, elegir el valor propio más grande λ_1 y calcular su correspondiente vector propio a_1 , de esta forma tendremos la primera componente $Y_1 = a_1^T X$.

Para obtener la segunda componente principal Y_2 , tenemos

$$Var(Y_2) = Var(a_2^T \mathbf{X}) = a_2^T \Sigma a_2$$

debe ser maximizada sujeta ahora a dos condiciones: $a_2^T a_2 = 1$ y $Cov(Y_1, Y_2) = 0$, la restricción de la covarianza se puede escribir como:

$$\begin{aligned}
Cov(Y_1, Y_2) &= E[(a_2^T \mathbf{X} - a_2^T \mu)(a_1^T \mathbf{X} - a_1^T \mu)^T] \\
&= E[a_2^T (\mathbf{X} - \mu)(\mathbf{X} - \mu)^T a_1] \\
&= a_2^T E[(\mathbf{X} - \mu)(\mathbf{X} - \mu)^T] a_1 \\
&= a_2^T Var(\mathbf{X}) a_1 \\
&= a_2^T \Sigma a_1
\end{aligned}$$

Por lo tanto $Cov(Y_1, Y_2) = 0$ es equivalente a $Cov(Y_1, Y_2) = a_2^T \Sigma a_1 = 0$ pero del desarrollo de la primera componente tenemos $\Sigma a_1 - \lambda a_1 = 0$ y multiplicando por a_2^T por la izquierda tenemos:

$$a_2^T \Sigma a_1 - \lambda a_2^T a_1 = 0$$

por lo tanto $a_2^T \Sigma a_1 = 0 \iff a_2^T a_1 = 0$, esto significa que a_2 y a_1 deben ser ortogonales. Ahora, construimos la siguiente función

$$\varphi = a_2^T \Sigma a_2 - \lambda(a_2^T a_2 - 1) - \gamma(a_2^T a_1)$$

de nuevo buscamos su máximo derivando con respecto a_2 e igualando a cero.

$$\frac{\partial \varphi}{\partial a_2} = 2\Sigma a_2 - 2\lambda a_2 - \gamma a_1 = 0$$

así, $\frac{\partial \varphi}{\partial \lambda} = 0$ y $\frac{\partial \varphi}{\partial \gamma} = 0$ llevan a las condiciones originales.

Ahora multiplicando por a_1^T por la izquierda, tenemos

$$2a_1^T \Sigma a_2 - 2\lambda a_1^T a_2 - \gamma a_1^T a_1 = 0$$

donde $a_1^T a_1 = 1$ y $a_1^T a_2 = 0$ pero, también $a_1^T \Sigma a_2 = 0$, por lo que $\gamma = 0$, regresando a la derivada anterior nos queda

$$2\Sigma a_2 - 2\lambda a_2 = 0 \iff (\Sigma - \lambda \mathbf{I})a_2 = 0$$

Así vemos que ahora hay que escoger a λ_2 como el segundo valor propio más grande de Σ , y a_2 el correspondiente vector propio. Continuando con este argumento, la j -ésima componente principal es el vector propio asociado con el j -ésimo valor propio más grande, de esta forma:

$$\lambda_1 \geq \lambda_2 \geq \dots \lambda_p$$

son los valores propios, donde además sabemos que $Var(Y_j) = \lambda_j$. Se extiende el argumento al caso en donde algunos valores propios de Σ son iguales. En este caso, no hay una forma única de elegir a los vectores propios correspondientes, pero como los vectores propios asociados con raíces múltiples se eligen de manera que sean ortogonales, el argumento es válido.

Sea \mathbf{A} la matriz de $p \times p$ de vectores propios, donde $\mathbf{A} = (a_1, a_2, \dots, a_p)$ y el vector \mathbf{Y} de $p \times 1$ de componentes principales. Entonces:

$$\mathbf{Y} = \mathbf{A}^T \mathbf{X}$$

$$\begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_p \end{pmatrix} = \begin{pmatrix} a_{11} & a_{21} & \cdots & a_{n1} \\ a_{12} & a_{22} & \cdots & a_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1p} & a_{2p} & \cdots & a_{np} \end{pmatrix}^T \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_p \end{pmatrix}$$

$$Y_j = a_{1j}X_1 + a_{2j}X_2 + \dots + a_{pj}X_p = a_j^T X$$

cada Y_j (donde $j = 1, \dots, p$) es una combinación lineal de las X_1, X_2, \dots, X_p variables originales y $a_j^T = (a_{1j}, a_{2j}, \dots, a_{pj})$ un vector propio. Por construcción, la matriz \mathbf{A} es una matriz ortogonal, es decir $\mathbf{A}^T \mathbf{A} = \mathbf{I}$

1.1.3 Porcentajes de variabilidad

La varianza de cada componente principal es el correspondiente valor propio asociado a dicha componente:

$$\begin{aligned} Var(Y_1) &= \lambda_1 \\ Var(Y_2) &= \lambda_2 \\ &\vdots \\ Var(Y_p) &= \lambda_p \end{aligned}$$

la matriz de covarianzas de \mathbf{Y} sera denotada por $\mathbf{\Lambda}$, que por construcción es una matriz diagonal dada por:

$$\mathbf{\Lambda} = \begin{pmatrix} \lambda_1 & 0 & 0 & \cdots & 0 \\ 0 & \lambda_2 & 0 & \cdots & 0 \\ 0 & 0 & \lambda_3 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & \lambda_p \end{pmatrix}$$

la matriz es diagonal ya que las componentes han sido construidas no correlacionadas. Por otro lado tenemos que:

$$\mathbf{\Lambda} = \text{Var}(\mathbf{Y}) = \text{Var}(\mathbf{A}^T \mathbf{X}) = \mathbf{A}^T \mathbf{\Sigma} \mathbf{A}$$

Así $\mathbf{\Lambda} = \mathbf{A}^T \mathbf{\Sigma} \mathbf{A}$ da la importante relación entre la matriz de varianzas y covarianzas de \mathbf{X} y las correspondientes componentes principales. Note que la ecuación anterior se puede reescribir como:

$$\begin{aligned} \mathbf{\Lambda} &= \mathbf{A}^T \mathbf{\Sigma} \mathbf{A} \\ \mathbf{A} \mathbf{\Lambda} &= \mathbf{A} \mathbf{A}^T \mathbf{\Sigma} \mathbf{A} \\ \mathbf{A} \mathbf{\Lambda} &= \mathbf{\Sigma} \mathbf{A} \\ \mathbf{A} \mathbf{\Lambda} \mathbf{A}^T &= \mathbf{\Sigma} \end{aligned}$$

Hemos visto que los valores propios pueden ser interpretados como las varianzas respectivas de las diferentes componentes. Ahora, la suma de estas varianzas esta dada por:

$$\sum_{i=1}^p \text{Var}(Y_i) = \sum_{i=1}^p \lambda_i = \text{tr}(\mathbf{\Lambda})$$

donde:

$$\begin{aligned} \text{tr}(\mathbf{\Lambda}) &= \text{tr}(\mathbf{A}^T \mathbf{\Sigma} \mathbf{A}) \\ &= \text{tr}(\mathbf{A} \mathbf{\Sigma} \mathbf{A}^T) \\ &= \text{tr}(\mathbf{\Sigma}) \\ &= \sum_{i=1}^p \text{Var}(X_i) \end{aligned}$$

Así tenemos el importante resultado, de que la suma de las varianzas de las variables originales y la de sus componentes principales son la misma. Por lo tanto la i -ésima componente principal aporta una proporción de variación total en los datos originales de:

$$\frac{\lambda_i}{\sum_{i=1}^p \lambda_i}$$

Así, también se podrá expresar el porcentaje de variabilidad total proporcionado por las primeras m componentes:

$$\frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^p \lambda_i}$$

1.1.4 Componentes principales muestrales

La derivación de las componentes principales de \mathbf{X} supone que Σ es conocida. Generalmente este no es el caso, así que Σ es reemplazada por \mathbf{S} , la matriz de varianzas y covarianzas muestral, donde el elemento (i, j) queda definido como:

$$s_{i,j} = \sum_{r=1}^n (x_{ri} - \bar{x}_i)(x_{rj} - \bar{x}_j) / (n - 1)$$

el denominador $(n - 1)$ es elegido usualmente de tal forma que s_{ij} sea un estimador de la correspondiente covarianza poblacional, denotada por σ_{ij} . La matriz \mathbf{S} tiene entonces la expresión siguiente:

$$\mathbf{S} = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1p} \\ s_{21} & s_{22} & \cdots & s_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ s_{p1} & s_{p2} & \cdots & s_{pp} \end{pmatrix}$$

Como s_{ij} es un estimador insesgado para σ_{ij} , decimos que \mathbf{S} es un estimador insesgado para la matriz de varianzas y covarianzas Σ . \mathbf{S} es simétrica y sus elementos sobre la diagonal son las varianzas muestrales de las variables. Las desviaciones estándar están dadas por $s_i = \sqrt{s_{ii}}$. Los términos fuera de la diagonal de \mathbf{S} , dependen de las escalas utilizadas para medir a las variables y generalmente son difíciles de interpretar como una medida de asociación entre una pareja dada de variables. Por lo que usualmente son utilizados en el cálculo de los coeficientes de correlación muestral:

$$r_{ij} = \frac{s_{ij}}{s_i s_j}$$

Estos coeficientes pueden ser pensados como covarianzas muestrales normalizadas, las cuales toman valores entre -1 y 1 .

La matriz de varianzas y covarianzas muestral puede ser expresada en términos de los vectores de observación:

$$\begin{aligned}\mathbf{S} &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \\ &= \frac{1}{n-1} \left(\sum_{i=1}^n X_i X_i^T - n \bar{X} \bar{X}^T \right)\end{aligned}$$

ya que $(X_i - \bar{X})^T = (x_{i1} - \bar{x}_1, x_{i2} - \bar{x}_2, \dots, x_{ip} - \bar{x}_p)$, el elemento en la posición $(1, 1)$ de $(X_i - \bar{X})(X_i - \bar{X})^T$ es $(x_{i1} - \bar{x}_1)(x_{i1} - \bar{x}_1)$, y cuando es sumado sobre i el resultado es el numerador de s_{11} . Similarmente, el elemento $(1, 2)$ es $(x_{i1} - \bar{x}_1)(x_{i2} - \bar{x}_2)$, el cual sumado sobre i da el numerador de s_{12} y así sucesivamente para los demás elementos.

Podemos también obtener \mathbf{S} directamente de la matriz de datos \mathbf{X} :

$$\mathbf{X} = \begin{pmatrix} X_1^T \\ X_2^T \\ \vdots \\ X_i^T \\ \vdots \\ X_n^T \end{pmatrix} = \begin{pmatrix} X_{11} & X_{12} & \cdots & X_{1p} \\ X_{21} & X_{22} & \cdots & X_{2p} \\ \vdots & \vdots & & \vdots \\ X_{i1} & X_{i2} & \cdots & X_{ip} \\ \vdots & \vdots & & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{np} \end{pmatrix}$$

donde puede apreciarse que las variables están dadas por columnas y las observaciones por renglón, esto es, tenemos p variables por lo tanto p columnas y n observaciones por lo tanto n renglones.

De esta forma:

$$\mathbf{S} = \frac{1}{n-1} (\mathbf{X} - \mathbf{1} \bar{\mathbf{X}}^T) (\mathbf{X} - \mathbf{1} \bar{\mathbf{X}}^T)$$

$$\text{donde } \mathbf{1} = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}, \quad \bar{\mathbf{X}}^T = (\bar{X}_1, \bar{X}_2, \dots, \bar{X}_p)$$

La derivación de las componentes principales de \mathbf{X} usando varianzas y covarianzas muestrales es exactamente como antes. Las componentes principales quedan en términos de los vectores propios de \mathbf{S} , la matriz de varianzas y covarianzas muestral. Sin pérdida de generalidad podemos seguir denotando a los valores propios, ahora de \mathbf{S} , como $\lambda_1, \lambda_2, \dots, \lambda_p$ y los correspondientes vectores propios a_1, a_2, \dots, a_p . Ya que \mathbf{S} es definida semipositiva, los valores propios son todos no negativos y representan las varianzas estimadas de las diferentes componentes.

1.1.5 Componentes principales a partir de la matriz de correlación

Es común calcular las componentes principales de un conjunto de variables después de que han sido estandarizadas para tener varianza unitaria. Esto significa que estamos encontrando las componentes principales de la matriz de correlaciones P . La derivación matemática es la misma, de tal forma que las componentes resultan ser combinaciones lineales de los vectores propios de P . Sin embargo, no son las misma que Σ . Cuando se elige analizar P en lugar de Σ resulta una decisión arbitraria para hacer a las variables igualmente importantes.

1.1.6 Decidir cuántas componentes retener

En toda aplicación, se debe tomar una decisión sobre cuántas componentes principales deberían ser retenidas con el objetivo de resumir los datos.

1. Retener suficientes componentes que aporten un 80% de la varianza total.
2. Excluir las componentes cuyos valores propios sean menores que el promedio de los valores propios, $\sum_{i=1}^p \lambda_i / p$. Para una matriz de correlación este promedio es 1.
3. Use una gráfica que compare los valores propios λ_i contra i . Esto nos ayuda a encontrar un codo natural entre los valores propios “grandes” y los “pequeños”.

1.1.7 Correlación entre las variables originales y las componentes principales

Para interpretar las componentes principales, es preciso relacionarlas con las variables originales. Para establecer esta relación es necesario calcular la correlación entre ellas. La correlación permite identificar cuales variables originales tienen mayor influencia sobre cada componente principal.

Los loadings o cargas son los coeficientes de la combinación lineal de las variables originales a partir de las cuales se construyeron las componentes principales. Se pueden interpretar como la importancia que tiene cada variable original sobre cada componente principal y por lo tanto, ayudan a conocer qué tipo de información recoge cada una de las componentes principales. Cuando la carga es positiva indica que la variable original y la componente principal tienen una correlación positiva, si la carga es negativa indica que la variable original y la componente principal tienen una correlación negativa. En el caso de que el valor de la carga sea cercano a cero indica que esa variable original tiene una débil influencia sobre la componente principal

1.2 Análisis de Componentes Independientes (ICA)

El Análisis de Componentes Independientes fue formulado por Jeanny Herault y Christian Jutten a principios de 1986 como un método de análisis para resolver el problema de separación ciega de fuentes originales que las componen (se denomina separación ciega porque las señales que observamos en el “mundo real” aparecen mezcladas o distorsionadas por otras señales desconocidas, lo que dificulta la tarea de poder obtener las señales originales), basado en la independencia estadística de dichas fuentes.

En 1994, Comon definió formalmente el término ICA; utilizó para la separación de señales el algoritmo de minimización de la información mutua; este algoritmo consiste en calcular los valores que minimizan la dependencia estadística.

El ICA es una técnica muy eficiente para solucionar el problema de la separación ciega de fuentes, pudiendo reducir la dimensión de las variables en un conjunto de datos multidimensionales.

En el caso de la Teledetección, las medidas que obtenemos al realizar una observación están distorsionadas por factores de diferente índole, en el caso de las imágenes de satélite estas distorsiones se deben a los movimientos orbitales, los errores sistemáticos del sensor, factores meteorológicos, etc., al aplicar el análisis de componentes independientes se eliminan en la medida de lo posible dichas distorsiones.

El efecto cocktail party (motivación)

Nos encontramos en una reunión, hay música y mucha gente hablando al mismo tiempo pero esto no te impide continuar tu conversación, es el efecto “Cocktail Party”. El cerebro nunca es pasivo respecto a nuestra capacidad de oír y escuchar, envía estímulos nerviosos al oído interno y hace una selección de la información auditiva.

El efecto “Cocktail Party” se refiere a la capacidad de focalizar solamente una fuente de sonido aún en medio de otros estímulos auditivos, este término fue propuesto por Collin Cherry en 1953 y ha sido de gran interés en diversas áreas de estudio.

Imaginemos la siguiente situación, hay dos personas hablando al mismo tiempo dentro de un cuarto, se generan dos señales acústicas s_1 y s_2 . En el cuarto se encuentran colocados dos micrófonos en diferentes lugares, grabando el sonido que se genera cerca de ellos, los micrófonos no reciben independientes las señales s_1 y s_2 , en lugar de eso reciben una mezcla de las dos señales que denotaremos por x_1 y x_2 .

$$x_1 = a_{11}s_1 + a_{12}s_2$$

$$x_2 = a_{21}s_1 + a_{22}s_2$$

El método de ICA permite recuperar las dos variables originales s_1 y s_2 de las señales mezcladas x_1 y x_2 .

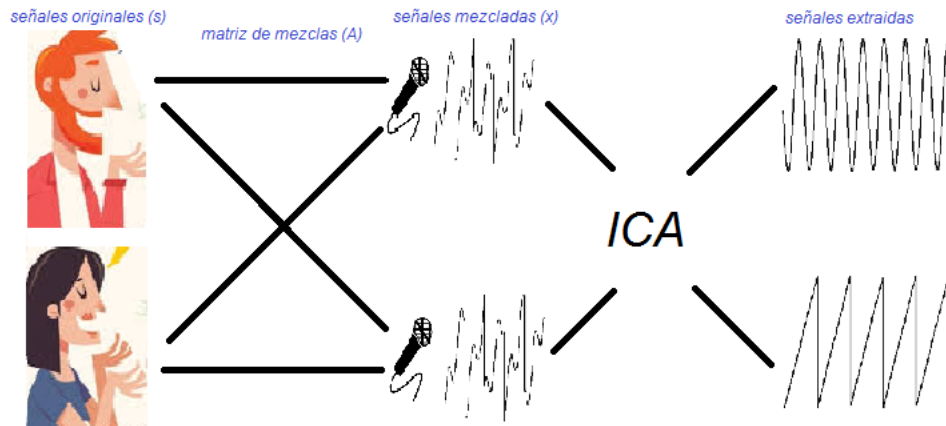


Figura 1: Efecto Cocktail Party

Es importante mencionar que el método no garantiza la recuperación exacta de las señales originales

1.2.1 Descripción del método de ICA

Ahora hemos visto que el problema de la separación ciega de fuentes se reduce a encontrar una transformación lineal en la que las componentes son estadísticamente independientes. En situaciones prácticas, en general no podemos encontrar una representación en la que las componentes sean realmente independientes, pero al menos podemos encontrar componentes que sean lo más independientes posible.

Esto nos lleva a la siguiente construcción de componentes independientes. Sea \mathbf{x} un vector aleatorio de las mezclas x_1, \dots, x_n , de igual forma \mathbf{s} es un vector aleatorio con elementos s_1, \dots, s_n , denotamos a la matriz desconocida de elementos a_{ij} como \mathbf{A} (se utilizarán a las letras minúsculas en negritas para denotar a vectores y mayúsculas en negritas para matrices), usando esta notación el modelo de mezclas se escribe como:

$$\mathbf{x} = \mathbf{A}\mathbf{s}$$

$$\begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{pmatrix} \begin{pmatrix} s_1 \\ s_2 \\ \vdots \\ s_n \end{pmatrix}$$

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n, \quad i = 1, 2, \dots, n$$

El análisis de componentes independientes ahora consiste en estimar tanto a la matriz \mathbf{A} como a \mathbf{s} cuando sólo observamos a \mathbf{x} , que suponemos aquí que el número de componentes independientes es igual al número de variables observadas; esta es una suposición que no es completamente necesaria. Este es el modelo ICA básico. Igualmente, en muchos casos, el producto de las componentes independientes y las mezclas observadas no son iguales, y la mezcla puede no ser lineal.

El modelo de ICA es un modelo generador, lo que significa que describe cómo los datos observados son generados por un proceso de mezclas de las componentes de \mathbf{s} . Las componentes independientes son variables latentes, lo que significa que no pueden ser observadas directamente. Todo lo que se observa es el vector aleatorio \mathbf{x} y se debe estimar \mathbf{A} y \mathbf{s} usando este vector. Esto debe hacerse bajo condiciones tan generales como sea posible.

1.2.2 Condiciones en el modelo de ICA

Para asegurarnos que nuestro modelo básico ICA se pueda estimar debemos considerar las siguientes suposiciones y restricciones.

1. Las componentes independientes s_i deben ser estadísticamente independientes

Este es el principio en el que se basa el modelo ICA. Ya que es necesario para asegurarnos de que el modelo se puede estimar, porque se desea encontrar aquellas señales que sean más independientes respecto a las demás.

Para que las variables aleatorias $Y_1, Y_2, Y_3, \dots, Y_n$ sean independientes el valor de la variable Y_i no interfiere con el valor de la variable Y_j para $i \neq j$. De manera formal se define la independencia como sigue: Denotemos por $f(y_1, y_2, \dots, y_n)$ a la función de densidad de probabilidad conjunta de Y_1, Y_2, \dots, Y_n , mientras que si $f_i(y_i)$ es la función de densidad marginal de Y_i . Entonces decimos que Y_1, Y_2, \dots, Y_n son independiente si y solo si:

$$f(y_1, y_2, y_3, \dots, y_n) = f_1(y_1)f_2(y_2) \dots f_n(y_n)$$

A continuación se muestran la distribución conjunta de señales independientes y la distribución de las señales mezcladas.




Figura 2: Distribución conjunta de señales independientes con f.d.p. uniforme.




Figura 3: Distribución conjunta de señales mezcladas.

2. Los datos están centrados

Sin pérdida de generalidad, podemos suponer que tanto las mezclas \mathbf{x} como las componentes independientes s_i tienen media cero. Esta suposición simplifica de manera significativa la teoría y los algoritmos. Si no se tiene la condición anterior, es necesario hacer un proceso de blanqueamiento, que explicaremos más adelante.

3. Las componentes independientes no deben tener distribuciones normales

Es imposible aplicar el modelo de ICA cuando las variables observadas siguen una distribución normal.

Veamos de manera más clara este hecho. Supongamos que la distribución conjunta de dos componentes independientes s_1, s_2 es normal. Esto quiere decir que la f.d.p conjunta es:

$$P(s_1, s_2) = \frac{1}{2\pi} e^{-\frac{s_1^2 + s_2^2}{2}} = \frac{1}{2\pi} e^{-\frac{\|\mathbf{s}\|^2}{2}},$$

ahora supongamos que la matriz de mezclas \mathbf{A} es ortogonal (se puede suponer porque los datos deben estar blanqueados¹), sabemos que en este caso $\mathbf{A}^{-1} = \mathbf{A}^T$. Esto implica que la densidad conjunta de las dos mezclas x_1 y x_2 está dada por

$$P(x_1, x_2) = \frac{1}{2\pi} e^{-\frac{\|\mathbf{A}^T \mathbf{x}\|^2}{2}} |\det \mathbf{A}^T|$$

por la ortogonalidad de \mathbf{A} , tenemos que $\|\mathbf{A}^T \mathbf{x}\|^2 = \|\mathbf{x}\|^2$ (Si los valores propios de una matriz ortogonal son reales, entonces los valores propios son siempre ± 1) y el $|\det \mathbf{A}| = 1$, entonces tenemos

¹Este concepto se verá en la sección 1.2.3.

$$P(x_1, x_2) = \frac{1}{2\pi} e^{-\frac{\|x\|^2}{2}}$$

podemos observar que la matriz de mezclas ortogonales no cambia a la f.d.p. Por lo tanto no hay manera de inferir a la matriz de mezclas de las mezclas. Este problema se relaciona con la propiedad de las variables normales no correlacionadas que son necesariamente independientes.

Podemos observar este fenómeno graficando la distribución de las mezclas ortogonales, que es lo mismo que la distribución de las componentes independientes. Esta distribución se ilustra en la figura 4.




Figura 4: Distribución multivariada de dos variables normales independientes

4. La matriz \mathbf{A} es cuadrada

En otras palabras, el número de las componentes independientes es igual al número observado de las mezclas. Esta suposición puede ser flexible en ciertos casos que se explicarán más adelante. Lo hacemos de esta forma porque simplifica mucho la estimación. Después de estimar a la matriz \mathbf{A} , podemos obtener a la matriz inversa que la denotaremos como \mathbf{A}^{-1} , y así obtendremos las componentes independientes de la siguiente manera:

$$\mathbf{s} = \mathbf{A}^{-1}\mathbf{x}$$

se supone que \mathbf{A} es invertible. Si este no es el caso, nos encontraremos de nuevo con el caso donde el número de mezclas no es igual al número de componentes independientes.

1.2.3 Blanqueamiento (también llamado esfericidad)

El modelo ICA se simplifica de manera significativa si al vector de mezclas observadas se le realiza un proceso previo o blanqueamiento, que consiste en centrar los datos y eliminar la correlación entre las mezclas observadas. En esta sección discutiremos la relación del modelo ICA y los métodos para eliminar la correlación. Se verá que el blanqueamiento es una técnica de proceso previo útil para el modelo ICA.

Como se menciona en las condiciones del modelo ICA, se centran los datos, sustrayendo la media del vector $m = E[\mathbf{x}]$. A continuación obtenemos el vector de mezclas centrado \mathbf{x}_c :

$$\mathbf{x}_c = \mathbf{x} - E[\mathbf{x}]$$

Por lo tanto las componentes independientes tienen media cero también, ya que después de centrar los datos, se elimina la correlación entre cada una de las mezclas observadas.

El proceso de blanqueamiento consiste en aplicar una transformación lineal W a las observaciones \mathbf{x} de tal forma que obtengamos un nuevo vector de variables \mathbf{z} que está blanqueado

$$\mathbf{z} = W\mathbf{x}$$

cuyas componentes están no correlacionadas entre sí y además tengan varianza unitaria. En otras palabras, $E[\mathbf{z}\mathbf{z}^T] = \mathbf{I}$, donde \mathbf{I} es la matriz identidad. Sin pérdida de generalidad se supone al vector \mathbf{s} blanqueado, es decir, $E[\mathbf{s}\mathbf{s}^T] = \mathbf{I}$.

Una forma de obtener esta matriz de blanqueado W es a partir de la descomposición en valores propios y vectores propios de la matriz de covarianzas de \mathbf{x} :

$$E[\mathbf{x}\mathbf{x}^T] = \mathbf{V}\mathbf{D}\mathbf{V}^T$$

donde \mathbf{V} es la matriz de vectores propios ortogonales de $E[\mathbf{x}\mathbf{x}^T]$ (lo que quiere decir que $\mathbf{V}\mathbf{V}^T = \mathbf{V}^T\mathbf{V} = \mathbf{I}$, donde \mathbf{I} es la matriz identidad) y $\mathbf{D} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ es la matriz diagonal de valores propios. Así podemos obtener una matriz de blanqueado mediante el producto:

$$W = \mathbf{V} \mathbf{D}^{-\frac{1}{2}} \mathbf{V}^T$$

donde $\mathbf{D}^{-1/2} = \text{diag}(\lambda_1^{-1/2}, \lambda_2^{-1/2}, \dots, \lambda_n^{-1/2})$.

El blanqueamiento transforma a la matriz de mezclas \mathbf{x} en una nueva matriz ortogonal

$$\begin{aligned}
 \mathbf{z} &= W\mathbf{x} \\
 &= \mathbf{V}\mathbf{D}^{-1/2}\mathbf{V}^T\mathbf{x} \\
 &= \mathbf{V}\mathbf{D}^{-1/2}\mathbf{V}^T\mathbf{A}\mathbf{s} \\
 &= \tilde{\mathbf{A}}\mathbf{s}
 \end{aligned}$$

Para ver si la matriz W es una matriz de blanqueado, basta con probar que la matriz de covarianzas de z es igual a la identidad.

Esto es:

$$\begin{aligned}
 E[\mathbf{z}\mathbf{z}^T] &= \mathbf{V}\mathbf{D}^{-1/2}\mathbf{V}^T\mathbf{A}E[\mathbf{s}\mathbf{s}^T][\mathbf{V}\mathbf{D}^{-1/2}\mathbf{V}^T\mathbf{A}]^T \\
 &= \mathbf{V}\mathbf{D}^{-1/2}\mathbf{V}^T\mathbf{A}E[\mathbf{s}\mathbf{s}^T]\mathbf{A}^T\mathbf{V}[\mathbf{D}^{-1/2}]^T\mathbf{V}^T \\
 &= \mathbf{V}\mathbf{D}^{-1/2}\mathbf{V}^T\mathbf{A}\mathbf{I}\mathbf{A}^T\mathbf{V}[\mathbf{D}^{-1/2}]^T\mathbf{V}^T \\
 &= \mathbf{V}\mathbf{D}^{-1/2}\mathbf{V}^T\mathbf{A}\mathbf{A}^T\mathbf{V}[\mathbf{D}^{-1/2}]^T\mathbf{V}^T \\
 &= I
 \end{aligned}$$

La matriz de blanqueado dada por W no es la única posible. Para cualquier matriz ortogonal, U , se puede comprobar que la matriz dada por UW también es una matriz de blanqueado.

Para $\mathbf{z} = UW\mathbf{x}$ y $\mathbf{z}^T = U^TW^T\mathbf{x}$ entonces $\mathbf{z}\mathbf{z}^T = UW\mathbf{x}\mathbf{x}^TW^TU^T$, ahora solo probamos que su matriz de covarianza es la identidad:

$$\begin{aligned}
 E[\mathbf{z}\mathbf{z}^T] &= UWE[\mathbf{x}\mathbf{x}^T]W^TU^T \\
 &= UWIW^TU^T \\
 &= UWW^TU^T \\
 &= UIU^T \\
 &= UU^T \\
 &= I
 \end{aligned}$$

Otra alternativa para realizar el proceso de blanqueamiento, es usando el análisis de componente principales (PCA) haciendo los ajustes necesarios. En la figura 5 se ilustra una distribución uniforme blanqueada.




Figura 5: Distribución de los datos blanqueados de una distribución uniforme con componentes independientes

1.2.4 Normalidad e independencia

La normalidad es un principio esencialmente importante en el modelo de análisis de componentes independientes. De acuerdo con el teorema del límite central, la distribución de la suma de señales independientes con distribución arbitraria tiende a una distribución normal, bajo ciertas condiciones.

Una señal de mezclas con distribución normal, se puede considerar como una combinación lineal de señales independientes. Entonces el método para separar las señales independientes consiste, en aplicar una transformación a las señales mezcladas para minimizar la normalidad entre ellas (entre menor sea la normalidad mayor será la independencia).

Se utilizará a la entropía como una medida de la normalidad en las señales pero antes es necesario definir este término. La entropía es considerada una medida de aleatoriedad, si la entropía es pequeña quiere decir que su distribución se concentra en ciertos valores, es decir, la f.d.p. de la variable esta agrupada.

Se define a la entropía H para una variable aleatoria discreta S como:

$$H(S) = - \sum_i P(S = a_i) \log P(S = a_i)$$

Por otro lado, para una variable aleatoria continua, la entropía es llamada entropía diferencial y se define como la integral de la función de densidad por el logaritmo de la función de densidad.

$$H(S) = - \int f(S) \log f(S) dS$$

Se define a la entropía negativa $J(S)$ como la diferencia entre la entropía diferencial de la variable S y la entropía diferencial de una variable normal S_{normal} con la misma matriz de varianzas y covarianzas de S .

$$J(S) = H(S_{normal}) - H(S)$$

La entropía negativa es siempre no negativa y vale cero si y solo si S tiene distribución normal, es decir, a mayor entropía negativa menor normalidad. El objetivo es maximizar la entropía negativa $J(S)$. Como la expresión anterior es computacionalmente muy costosa porque se tendría que estimar la función de densidad, se utilizará la siguiente aproximación:

$$J(S) \approx (E[G(S)] - E[G(S_{normal})])^2$$

donde G no es una función cuadrática. En particular, G debe ser elegida como una función que no crezca muy rápido. Las dos elecciones más conocidas para G son:

$$G(S) = \frac{1}{a} \log \cosh(aS)$$

$$G(S) = -e^{-S^2/2}$$

donde $1 \leq a \leq 2$ es una constante adecuada, que a menudo toma el valor de 1. Las cuales podemos observar en la figura 6.




Figura 6: Las funciones para G , dadas por la línea continua y la línea discontinua respectivamente.

1.3 Comparación del PCA y el ICA

El análisis de componentes principales y el análisis de componentes independientes están relacionados entre sí, pero tiene diferentes objetivos; el objetivo del PCA es encontrar un conjunto de variables no correlacionadas e identificar un número reducido y significativo de estas variables, mientras que el ICA tiene como objetivo encontrar un conjunto de variables estadísticamente independientes a partir de una mezcla de estas.

Aunque ambos métodos tienen diferentes objetivos y se basan en distintas propiedades, no son excluyentes. Algunos cálculos del PCA pueden usarse para blanquear los datos antes de aplicar el ICA, y también para fijar el número de componentes independientes que se calcularán.

Sin embargo, obtener variables no correlacionadas no implica independencia, por lo tanto podemos concluir que la independencia que se obtiene en el ICA es más fuerte que la no correlación del PCA.




Figura 7: Un ejemplo de la diferencia entre el modelo ICA y el modelo PCA. El modelo ICA toma el vector de color azul como la primera componente independiente porque maximiza la no normalidad mientras que el modelo PCA tomaría el vector color rojo como primera componente principal porque se maximiza la varianza.

Capítulo 2

Introducción

Iris es un género de plantas rizomatosas de la familia Iridaceae con vistosas flores, cuyo nombre deriva del latín arco iris, refiriéndose a la extensa variedad de colores florales que poseen sus muchas especies. Son plantas herbáceas perennes que crecen de rizomas rastreros (iris rizomatosos) o, en climas más secos, de bulbos (iris bulbosos). Poseen largos y erectos tallos florales, que pueden ser simples o ramificados, macizos o huecos. Estos tallos pueden ser aplanados o con secciones circulares transversales. Las hojas, en número de 3 a 10, en forma de espada forman una densa masa en la parte basal de la planta.

Las inflorescencias surgen en forma de abanico y contienen una o más flores de seis lóbulos simétricos y ligeramente fragantes. Los tres sépalos se abren o se inclinan hacia abajo, expandiéndose desde la estrecha base hacia afuera, a menudo están adornados con líneas o puntos. Los tres, en ocasiones reducidos, pétalos se yerguen, parcialmente detrás de los sépalos basales. Algunas pequeñas especies tienen los seis lóbulos apuntando directamente hacia afuera. Los sépalos y pétalos difieren el uno del otro. Están unidos en la base al tubo floral situado sobre el ovario. Los estilos se dividen hacia el ápice convirtiéndose en ramificaciones petaloides. Ver figura 7

Descripción de la base

Iris, clásica base de datos conocida como “Fisher Iris Data” sin embargo fue recolectada por el Dr. Edgar Anderson, y publicada en 1936 por el biólogo y estadístico inglés R. A. Fisher para demostrar el uso de una función discriminante.

Conformada por las medidas de la longitud y el ancho del sépalo así como la longitud y el ancho del pétalo en centímetros de 50 plantas de cada una de las tres diferentes especies de Iris; *Iris setosa*, *Iris versicolor* e *Iris virginica*. Para cada una de las flores se miden cinco variables:

Longitud del sépalo: Variable de tipo numérica que toma valores desde 4.3 hasta 7.9 cm.

Ancho del sépalo: Variable de tipo numérica que toma valores desde 2 hasta 4.4 cm.

Longitud del pétalo: Variable de tipo numérica que toma valores desde 1 hasta 6.9 cm.

Ancho del pétalo: Variable de tipo numérica que toma valores desde 0.1 hasta 2.5 cm.

Especie: Variable de tipo nominal con tres categorías: setosa, versicolor y virginica.

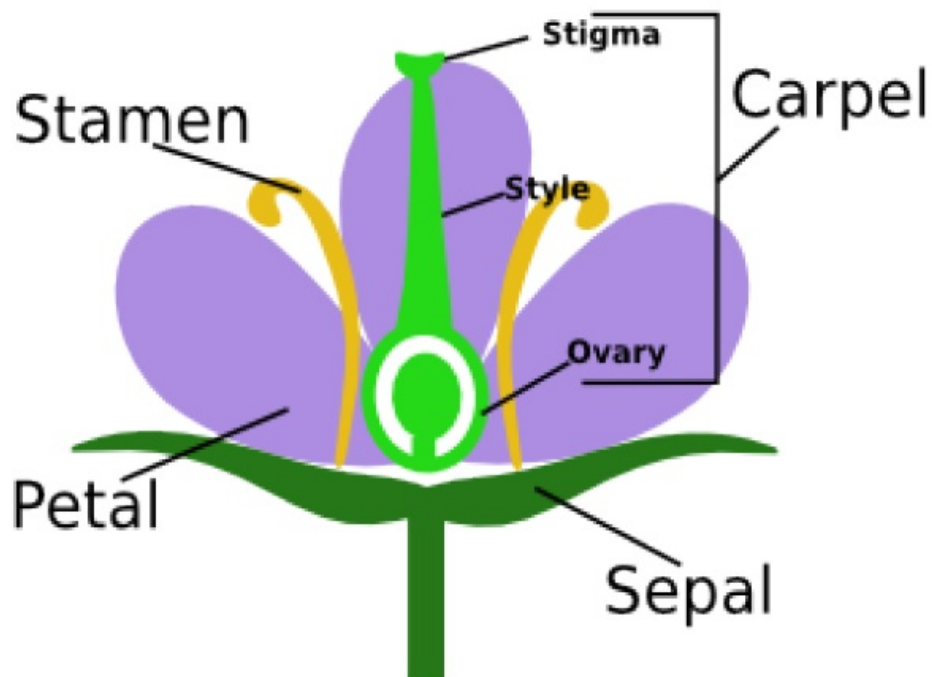


Figura 8: Las partes del lirio

2.1 Análisis exploratorio de datos

Primero se obtiene un resumen de la base de datos Iris, donde se muestran las medidas (como el mínimo, la mediana, la media, el máximo y la frecuencia) de cada una de las variables continuas que se presentan.

2.1.1 Descripción de los datos

Sepal.Length	Sepal.Width	Petal.Length	Petal.Width
Min. :4.300	Min. :2.000	Min. :1.000	Min. :0.100
1st Qu.:5.100	1st Qu.:2.800	1st Qu.:1.600	1st Qu.:0.300
Median :5.800	Median :3.000	Median :4.350	Median :1.300
Mean :5.843	Mean :3.057	Mean :3.758	Mean :1.199
3rd Qu.:6.400	3rd Qu.:3.300	3rd Qu.:5.100	3rd Qu.:1.800
Max. :7.900	Max. :4.400	Max. :6.900	Max. :2.500

Species

setosa	:50
versicolor	:50
virginica	:50

Es importante saber si se deben estandarizar los datos, ya que sabemos que se recomienda cuando se tienen diferentes escalas o los resultados se encuentran disparados unos de otros. Así que calcularemos las varianzas de las variables para verificar si es necesario estandarizar los datos.

	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width
Sepal.Length	0.6856935	-0.0424340	1.2743154	0.5162707
Sepal.Width	-0.0424340	0.1899794	-0.3296564	-0.1216394
Petal.Length	1.2743154	-0.3296564	3.1162779	1.2956094
Petal.Width	0.5162707	-0.1216394	1.2956094	0.5810063

La varianza es una medida de dispersión, que representa la variabilidad de los datos respecto a su media. Mientras más pequeña sea la varianza menor será la dispersión de los datos, de forma contraria mientras más grande sea la varianza mayor será la dispersión de los datos.

En efecto, las varianzas son todas pequeñas y el valor de ninguna sobresale por encima de las otras por lo que no se deben estandarizar.

2.1.2 Análisis de la correlación de los datos

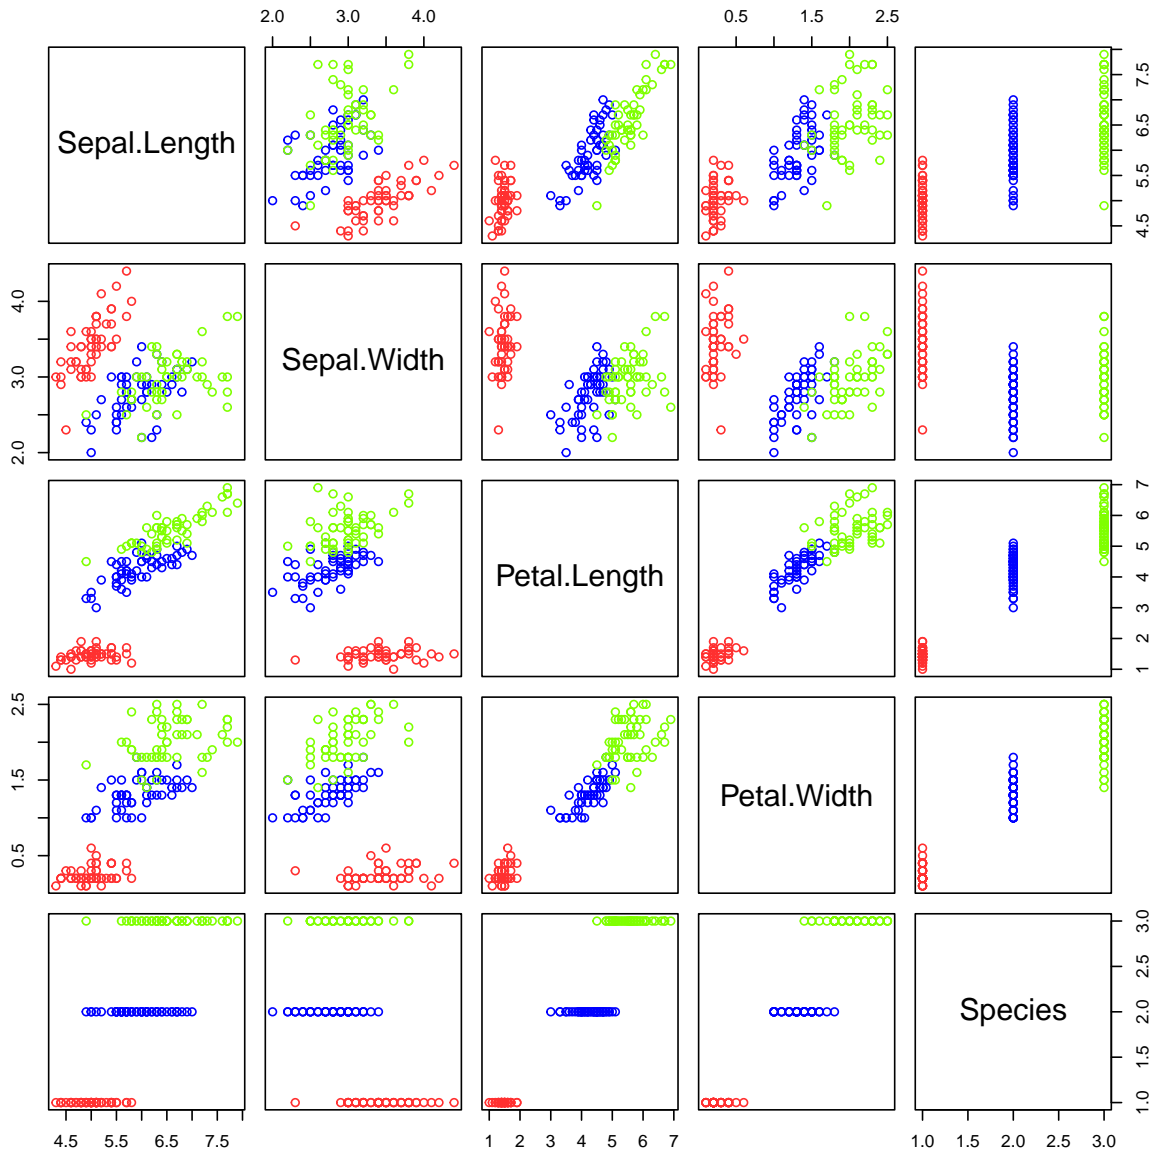
Calculamos la matriz de correlación para compararla con la matriz de varianzas y covarianzas que calculamos anteriormente, y así elegir la matriz adecuada para realizar el análisis de componentes principales.

	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width
Sepal.Length	1.0000000	-0.1175698	0.8717538	0.8179411
Sepal.Width	-0.1175698	1.0000000	-0.4284401	-0.3661259
Petal.Length	0.8717538	-0.4284401	1.0000000	0.9628654
Petal.Width	0.8179411	-0.3661259	0.9628654	1.0000000




Vemos que existe una correlación altamente positiva entre el ancho y largo del pétalo, entre el largo del pétalo y el largo del sépalo, así como el largo del sépalo y el ancho del pétalo. Por otra parte, se tiene una relación más o menos negativa entre el largo del pétalo y el ancho del sépalo, al igual que el ancho del pétalo y del sépalo, mientras que el largo y el ancho del sépalo no presentan una correlación significativa. El tamaño de los círculos esta asociado al valor absoluto de la correlación.

2.1.3 Matriz de dispersión de datos Iris

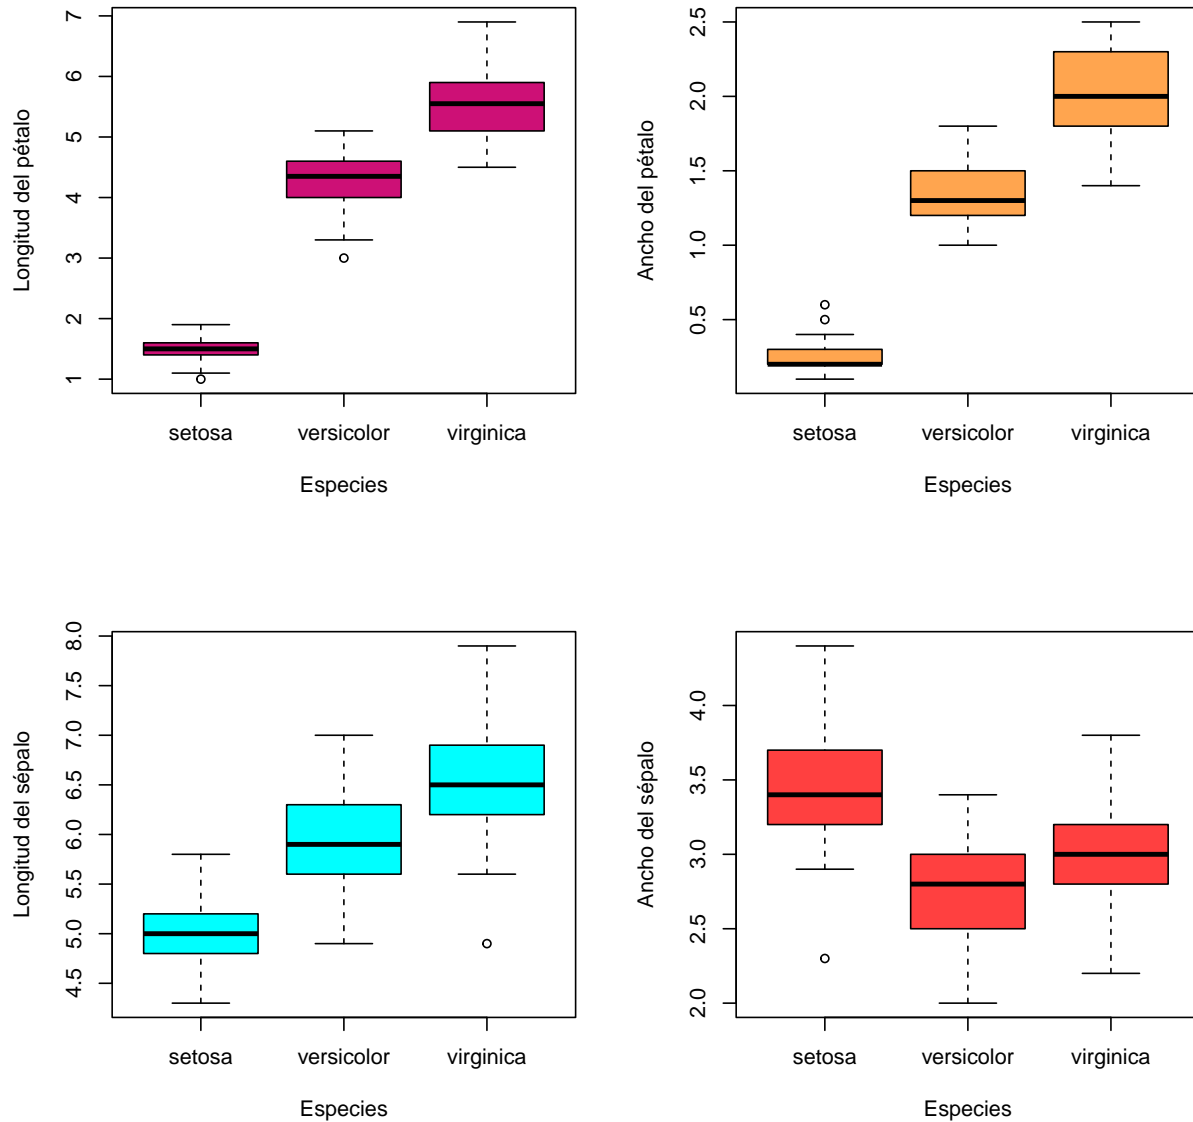


2.1.4 Curvas de Andrews para datos Iris



En las gráficas anteriores se ilustran los cuatro tipos de curvas de Andrews. Las cuales nos muestran, claramente, la división de los datos en tres grupos, y estos tres grupos presentan una amplitud y periodicidad de curvas muy similar. Cabe destacar que el grupo rojo se comporta ligeramente diferente a los otros dos grupos (azul, verde).

2.1.5 Diagrama de Caja




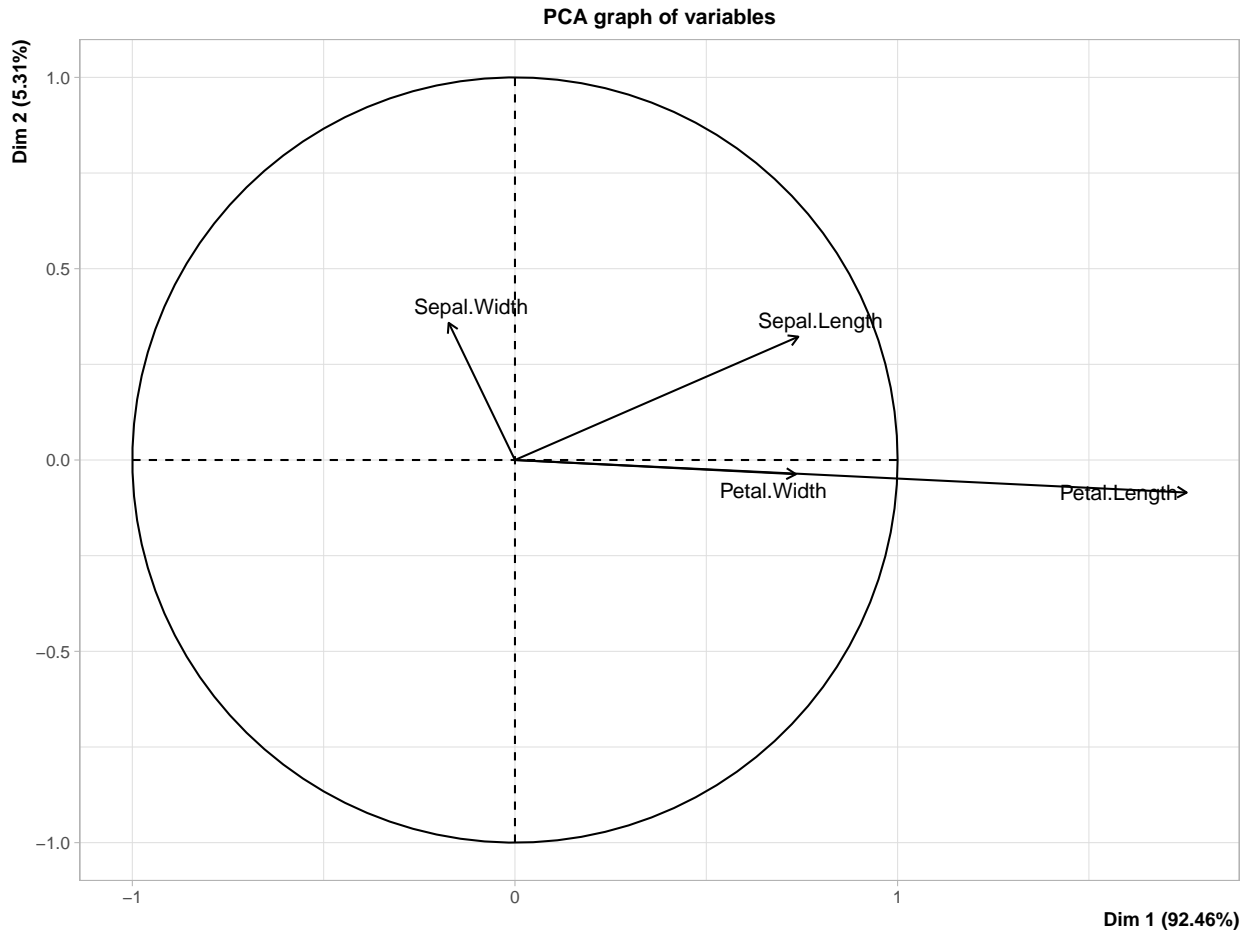
En estos diagramas de caja se puede observar la variación de los datos a través de la información de sus cuartiles, así como, la existencia de datos atípicos. Se observan dos datos atípicos en las variables longitud y ancho del pétalo respectivamente, mientras que las otras variables que son longitud y ancho del sépalo solo presentan un dato atípico. En cuanto a la longitud del pétalo, la longitud del sépalo y el ancho del pétalo, las medidas por especie se presentan en orden ascendente: primero tenemos a la especie setosa, seguida de la especie versicolor y finalmente la especie virginica. El ancho del sépalo difiere en este orden, las medidas más grandes las tiene la especie setosa mientras que las otras dos especies tienen medidas similares.

2.2 Análisis de componentes principales

2.2.1 Aplicación

El siguiente paso se calculan los valores y vectores propios de la matriz de varianzas y covarianzas o de la matriz de coeficientes de correlación que se obtiene a partir de la matriz de datos. La elección de una u otra matriz para realizar el modelo PCA depende de cómo se comportan los datos. En este caso se utilizará la matriz de varianzas y covarianzas porque los datos no presentan diferentes escalas.



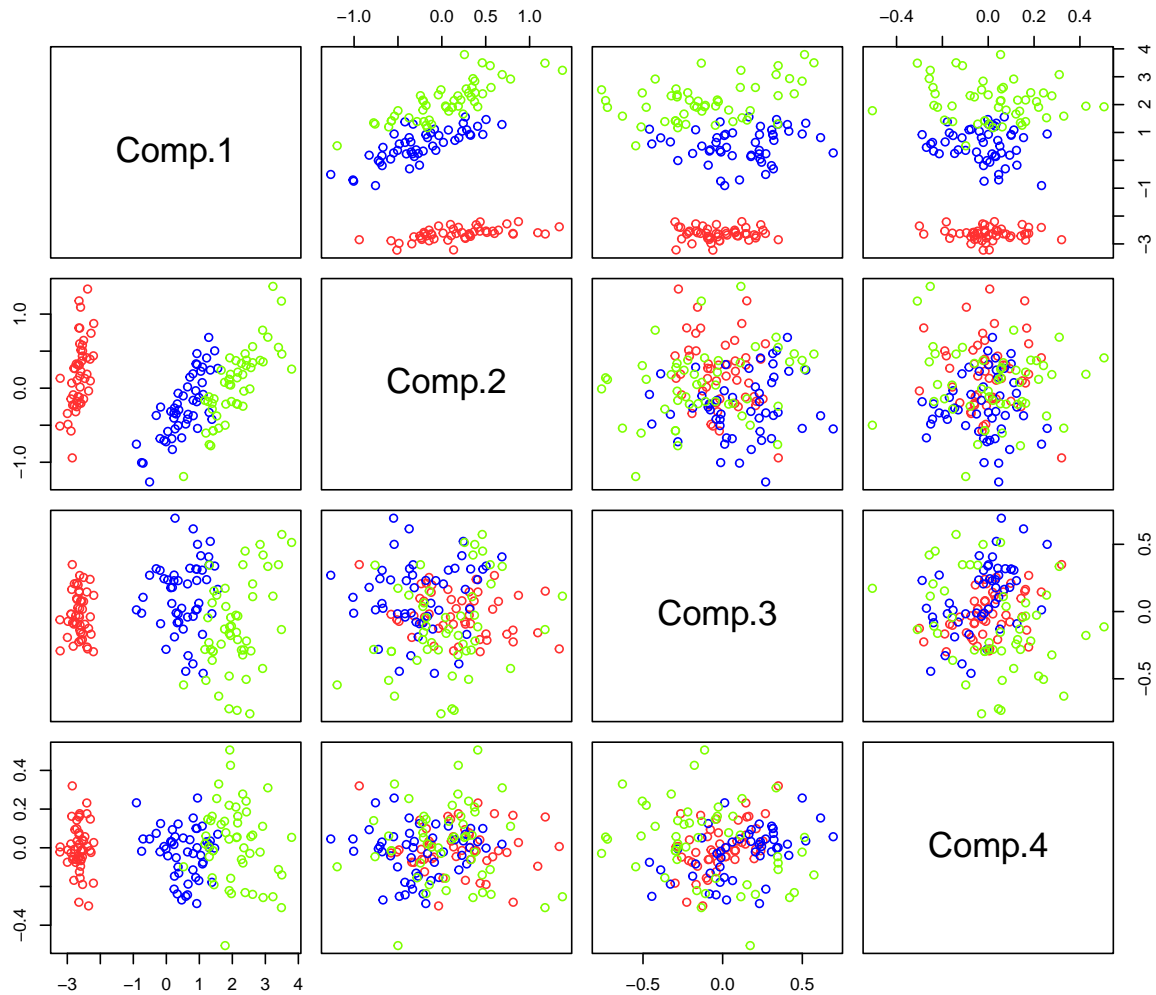


Al realizar el análisis de componentes principales se obtienen las gráficas anteriores en las que se observan 2 nubes de datos, viendo la gráfica de izquierda a derecha, la primer nube de datos agrupa a todas las observaciones que presentan características similares en cuanto al ancho del sépalo pero que no se relacionan con el ancho ni el largo del pétalo. La segunda nube de datos que seria la de mayor tamaño presenta características similares en cuanto al largo del sépalo, ancho y largo del pétalo, pero no presentan características similares respecto al ancho del sépalo.

2.2.2 Componentes principales

Importance of components:

	Comp.1	Comp.2	Comp.3	Comp.4
Standard deviation	2.0494032	0.49097143	0.27872586	0.153870700
Proportion of Variance	0.9246187	0.05306648	0.01710261	0.005212184
Cumulative Proportion	0.9246187	0.97768521	0.99478782	1.000000000




Se obtiene el porcentaje de varianza explicada por la 1^a, 2^a, 3^a y 4^a componente principal respectivamente.

Comp.1	Comp.2	Comp.3	Comp.4
92.46187	97.76852	99.47878	100.00000

Comp.1	Comp.2	Comp.3	Comp.4
92.4618723	5.3066483	1.7102610	0.5212184

Gráfica de codo




La gráfica de codo muestra que la mayor variabilidad de los datos se encuentra en las dos primeras componentes principales con las que tenemos un 97% aprox de variabilidad explicada de nuestros datos.

Loadings:

	Comp.1	Comp.2	Comp.3	Comp.4
Sepal.Length	0.361	0.657	0.582	0.315
Sepal.Width		0.730	-0.598	-0.320
Petal.Length	0.857	-0.173		-0.480
Petal.Width	0.358		-0.546	0.754

	Comp.1	Comp.2	Comp.3	Comp.4
SS loadings	1.00	1.00	1.00	1.00
Proportion Var	0.25	0.25	0.25	0.25
Cumulative Var	0.25	0.50	0.75	1.00

Calculando las cargas que presentan cada una de las componentes principales, se puede concluir que la primera componente representa la longitud del pétalo, la segunda componente representa el ancho y largo del sépalo orientada de manera perpendicular, la tercera componente representa un contraste entre la longitud del sépalo y el ancho del pétalo. Finalmente, la cuarta componente representa el ancho del pétalo.

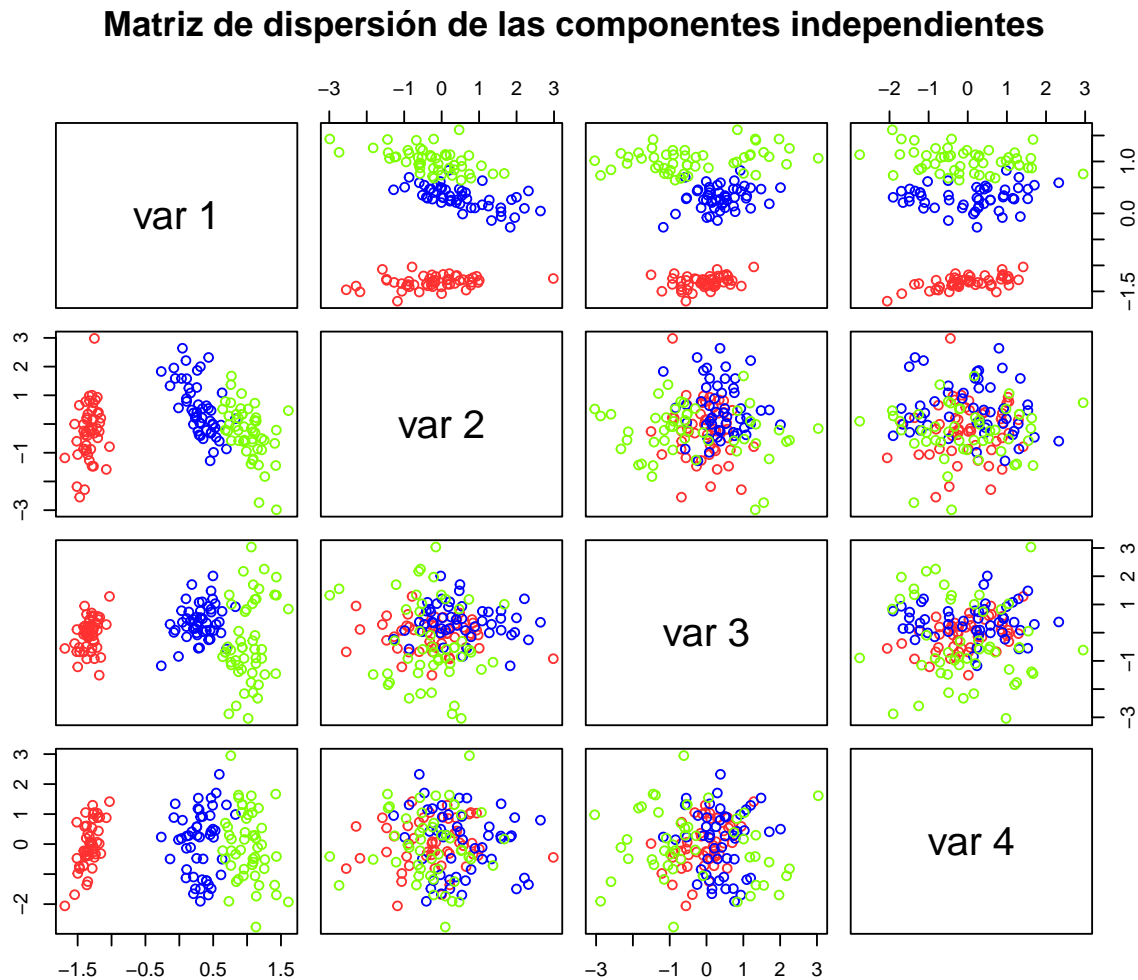


En esta gráfica se comparan la segunda componente principal contra la primera componente principal, notese la similitud a la gráfica resultante del modelo PCA a la base de datos iris, con la diferencia que en esta gráfica se le asignó un color diferente a cada una de las especies de lirios (rojo-setosa, azul-versicolor, verde-virginica). Es así, como se pueden observar datos en 3 agrupaciones. Ahora, comparando nuestras agrupaciones con las componentes principales, se tiene que las setosas se caracterizan por presentar similares anchuras del sépalo, en el caso de las versicolor presentan una principal similitud en la longitud del sépalo así como la anchura del pétalo y por último, las virginicas se caracterizan por la longitud del pétalo y la longitud del sépalo.

2.3 Análisis de componentes independientes (FastICA)

2.3.1 Calculando las cuatro componentes independientes

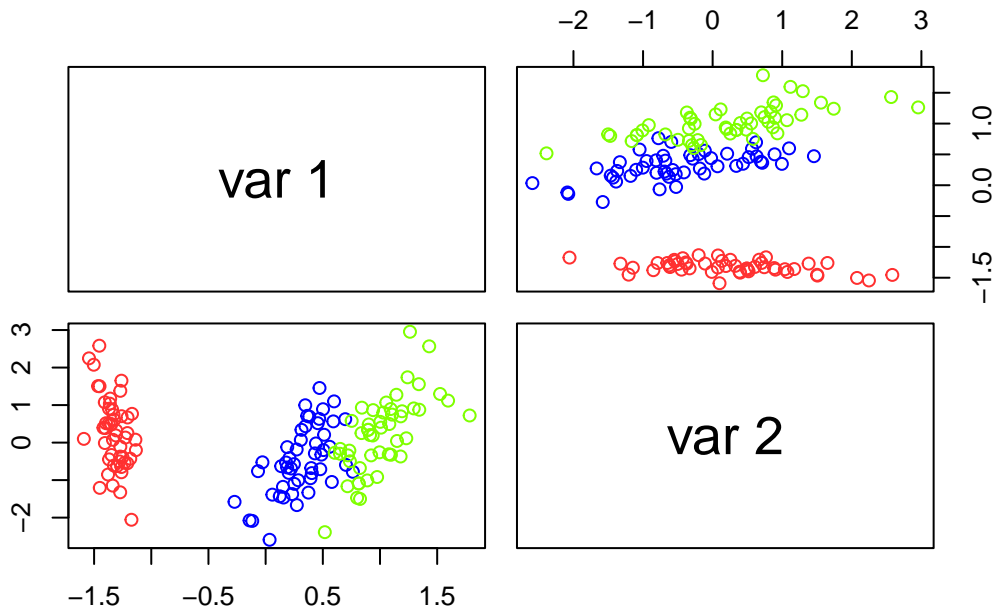
Usando la función $\frac{1}{a} \log \cosh(aS)$ para la aproximación de la entropía negativa. Las 4 componentes independientes calculadas están en el Anexo A.



En la matriz de dispersión se observa que basta con las dos primeras componentes independientes para separar los datos en tres visibles agrupaciones independientes que corresponden a la setosa, versicolor y virginica, también se presenta una buena agrupación de los datos para la primera componente contra la tercera componente, así como la primera componente con la cuarta componente. Pero las gráficas que relacionan las componentes restantes no presentan una agrupación de los datos, al contrario, en esas gráficas los datos se ven muy dispersos y dependientes.

2.3.2 Calculando las dos primeras componentes independientes



Usando la función $\frac{1}{a} \log \cosh(aS)$ para la aproximación de la negentropía. Este número de componentes fue elegido por los resultados del análisis de componentes principales, donde se indica que las 2 primeras componentes principales explican la mayor cantidad de varianza en los datos. Las 2 primeras componentes independientes se encuentran calculadas en el Anexo A.



En esta matriz de dispersión se están calculando dos componentes independientes, ya que considerando los resultados del modelo PCA, basta con dos componentes independientes para observar una agrupación de los datos. Así, los datos quedan separados en tres grupos correspondientes a las especies setosa (rojo), versicolor (azul) y virginica (verde).


2.3.3 Gráfica de mezclas con proceso previo

Las siguientes gráficas representan los datos Iris después de sustraerles la media del vector.




2.3.4 Gráficas de las componentes independientes

Gráfica de la 1° componente independiente



Gráfica de la 2° componente independiente



Las gráficas anteriores se pueden apreciar como señales independientes, en este caso no estamos trabajando con señales pero podemos verlas como tal. Para la primera gráfica que representa a la primera componente independiente se observa la separación en tres señales independientes y los colores representan que la primera separación corresponde a los lirios de la especie setosa, la siguiente señal corresponde a los lirios de la especie versicolor y la última señal corresponde a los lirios de la especie virginica.

Ahora para la gráfica de la segunda componente independiente se observa la misma separación que para la gráfica de la primera componente independiente con la diferencia que en esta se presenta una separación mucho más clara entre cada una de las tres señales independientes, esto se atribuye a la posición que tiene la segunda componente independiente con respecto a los datos y de esta manera se logra una mejor apreciación de los datos. Tampoco se observan más señales independientes de las tres observadas en la primera gráfica , con lo que se puede pensar que se ha logrado una óptima separación de señales independientes, es decir, una óptima agrupación de datos independientes.

Comparación del modelo PCA contra el modelo ICA

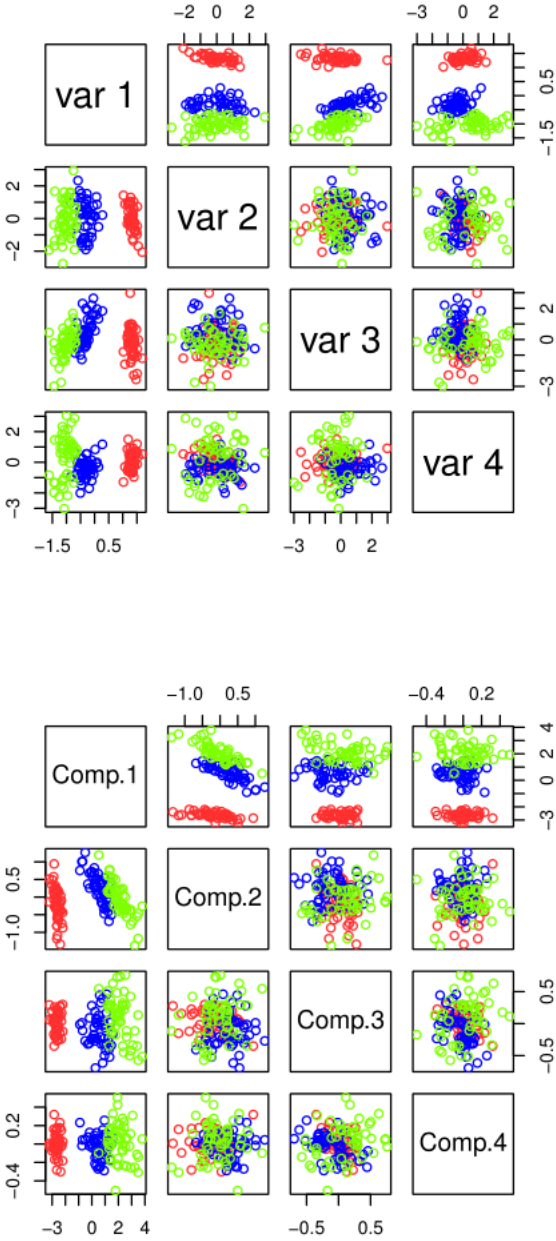


Figura 9: Las matrices de dispersión después de aplicar FastICA y PCA respectivamente.

Se comparan las matrices de dispersión de los datos después de realizar el modelo FastICA y el modelo PCA y se observa que los datos presentan un comportamiento muy similar, se separa en tres agrupaciones setosa, versicolor y virginica que son independientes entre ellas y a su vez los datos en cada una de las tres agrupaciones están correlacionados es decir presentan características similares. También se puede observar que basta con las dos primeras componentes independientes así como las dos primeras componentes principales para lograr una buena separación de los datos. Como se llega al mismo resultado en ambos métodos se puede concluir que tanto el análisis de componente principales como el análisis de componentes independientes son igualmente buenos para la agrupación de los datos, pero esto no ocurre en general, son por las características de los datos Iris que se presentan estos resultados tan similares.

Capítulo 3

Aplicación a la base de datos E.coli

Introducción

Theodore von Escherich, pediatra y microbiólogo alemán, estudió en el año 1884 los microbios que se encontraban en el intestino infantil a partir de sus heces, para establecer su rol en la digestión y la enfermedad. En el año 1885 publicó los resultados de su estudio, en cuyo reporte describe el aislamiento y caracterización de bacterias de rápido crecimiento con forma de varas cortas y delgadas que llamó *Bacterium coli commune*. Aunque posteriormente el microorganismo fue descrito por varios otros investigadores con múltiples sinónimos, Escherich fue reconocido como el primero estableciéndose el nombre definitivo del microbio como *Escherichia coli* en 1954.

Escherichia coli también conocida por la abreviación de su nombre, *E.coli*, es una bacteria gramnegativa con forma de bacilo de la familia de las enterobacterias que se encuentra en el tracto gastrointestinal de humanos y animales de sangre caliente. Es el principal organismo anaerobio facultativo del sistema digestivo. Si la bacteria no adquiere elementos genéticos que codifican factores virulentos, la bacteria actúa como un comensal formando parte de la microbiota intestinal y ayudando así a la absorción de nutrientes. En humanos, la *escherichia coli* coloniza el tracto gastrointestinal de un neonato adhiriéndose a las mucosidades del intestino grueso a las pocas horas de nacido. Desde este momento permanece en una relación de mutuo beneficio. No obstante, estas cepas comensales pueden producir infecciones en el paciente inmunodeprimido. Las cepas patógenas de *E. coli*, por el contrario, en cuanto colonizan un huésped sano, pueden producir infecciones de diversa severidad en el intestino, las vías urinarias, meningitis, sepsis, entre otras infecciones.

La identificación serológica de los distintos tipos de cepas de *E. coli* tuvo un papel relevante en su clasificación previo al uso de los factores genéticos de virulencia. Para ello en 1933, Alfred Adam mostró que ciertos serotipos de “dyspepsie koli” (como le llamaba a las cepas de *E.coli* diarreogénicas) estaban implicados en epidemias de diarrea pediátrica. En 1944, Kauffman propuso un esquema de clasificación que aún se usa hoy en día con el fin de diferenciar los tipos comensales de los patógenos y los distintos tipos de estos últimos.

Con los avances de las técnicas de decodificación genética, las cepas de *E.coli* productoras de diarrea en el hombre se han clasificado según el factor genético que define su virulencia y el cuadro clínico asociado, configurando diferentes tipos patogénicos, “patotipos” o “virotipos”; de esta forma se han definido al menos siete tipos de *E. coli* entéricos y tres extraintestinales. Entre ellos están: la *E.coli* enteropatogénica (ECEP), la *E. coli* enterotoxigénica (ECET), la *E.coli* enteroinvasiva (ECEI), la *E. coli* enteroagregativa (ECEA), la *E.coli* productora de toxina Shiga (STEC), la *E.coli* de adherencia difusa (ECAD) y la *E. coli* adherente invasiva (ECAI) que se ha asociado con la enfermedad de Crohn.

Hay tipos híbridos, como la *E. coli* enteroagregativa hemorrágica (EAHEC) que lleva genes de virulencia de la ECEA y la STEC. La familia es heterogénea y seguirá evolucionando.

La diarrea producida por cepas patógenas de *E. coli* es una causa importante de muerte en niños menores de 5 años, especialmente en las regiones de África subsahariana y Asia del Sur donde es una de las cuatro causas más importantes de diarrea moderada y severa, potencialmente letales.

La transmisión de esta bacteria ocurre a través del agua o alimentos contaminados, o a través del contacto con las heces de la persona contaminada. El tratamiento incluye la ingesta de suficientes líquidos y sales de rehidratación oral, y en algunos casos, se aconseja la ingesta de antibióticos. Los medicamentos antidiarreicos no se deben utilizar porque pueden agravar la enfermedad, ya que las bacterias no se eliminan a través de las heces. Otra excelente forma de ayudar a regular el intestino es tomar un probiótico.




Figura 10: Micrografía electrónica de un cumulo de bacterias *E. coli*

Descripción de la base de datos *E.coli*

E.coli, base de datos donada por Paul Horton en 1996, es una colección de 336 observaciones de localización de proteína en células. Para cada una se miden 9 variables

Nombre de Secuencia: Número de acceso para la base de datos SWISS-PROT.

Mcg: Valor obtenido en el método de McGeoch para el reconocimiento de la señal de secuencia que toma valores desde 0 hasta 0.89.

Gvh: Valor obtenido en el método de von Heijne para el reconocimiento de la señal de secuencia que toma valores desde 0.16 hasta 1.

Lip: Puntuación obtenida en el consenso de la señal PeptidasaII de von Heijne que toma valores desde 0.48 hasta 1.

Chg: Cantidad de carga en el extremo N en la predicción de lipoproteínas que toma valores desde 0.5 hasta 1.

Aac: Puntuación obtenida del análisis discriminante del contenido de aminoácidos en la membrana externa y en las proteínas periplásmicas, toma valores desde 0 hasta 0.88.

Alm1: Puntuación obtenida en la predicción de la magnitud de la abertura en la membrana ALOM que toma valores desde 0.03 hasta 1.

Alm2: Puntuación de la variable anterior excluyendo las señales susceptibles de división que toma valores desde 0 hasta 0.99.

Clase de Distribución: La clase es el lugar donde se localiza la proteína en la bacteria. Los lugares donde se localiza la proteína son los siguientes (se asignará un color a cada uno):

cp: citoplasma (color rojo)

im: membrana interna sin señal de secuencia (color naranja)

pp: peri plasma (color magenta)

imU: membrana interna con señal de secuencia indivisible (color verde)

om: membrana externa (color azul)

omL: membrana externa lipoproteica (color violeta)

imL: membrana interna lipoproteica (color azul medio)

imS: membrana interna con señal de secuencia divisible (color cian)




Figura 11: Lugares donde se localiza la proteína en una bacteria. Se considerará que la proteína se localiza en: el citoplasma, el periplasma, la membrana interna y externa.

3.1 Análisis exploratorio de datos

Primero, se obtiene un resumen de la base de datos, donde se muestran las medidas (como el mínimo, la mediana, la media, el máximo) de cada una de las variables continuas que se presentan.

3.1.1 Descripción de los datos

Seq. name	mcg	gvh	lip
Length:336	Min. :0.0000	Min. :0.16	Min. :0.4800
Class :character	1st Qu.:0.3400	1st Qu.:0.40	1st Qu.:0.4800
Mode :character	Median :0.5000	Median :0.47	Median :0.4800
	Mean :0.5001	Mean :0.50	Mean :0.4955
	3rd Qu.:0.6625	3rd Qu.:0.57	3rd Qu.:0.4800
	Max. :0.8900	Max. :1.00	Max. :1.0000


chg	aac	alm1	alm2
Min. :0.5000	Min. :0.000	Min. :0.0300	Min. :0.0000
1st Qu.:0.5000	1st Qu.:0.420	1st Qu.:0.3300	1st Qu.:0.3500
Median :0.5000	Median :0.495	Median :0.4550	Median :0.4300
Mean :0.5015	Mean :0.500	Mean :0.5002	Mean :0.4997
3rd Qu.:0.5000	3rd Qu.:0.570	3rd Qu.:0.7100	3rd Qu.:0.7100
Max. :1.0000	Max. :0.880	Max. :1.0000	Max. :0.9900

```
class dist
Length:336
Class :character
Mode :character
```

Es importante saber si se deben estandarizar los datos, ya que es recomendable cuando se tienen diferentes escalas o los resultados se encuentran disparados unos de otros. Así que, se calcularán las varianzas de las variables y se graficaran las varianzas contra las variables para verificar si es necesario estandarizar los datos.

	mcg	gvh	lip	chg	aac
mcg	0.0378823845	1.311493e-02	0.0025292253	3.730455e-04	0.0052567146
gvh	0.0131149254	2.195045e-02	0.0005743284	7.462687e-05	0.0012659701
lip	0.0025292253	5.743284e-04	0.0078314144	7.530206e-04	0.0007601350
chg	0.0003730455	7.462687e-05	0.0007530206	7.440476e-04	-0.0001492982
aac	0.0052567146	1.265970e-03	0.0007601350	-1.492982e-04	0.0149758200
alm1	0.0166701386	5.545672e-03	0.0018288699	-4.504264e-05	0.0073790991
alm2	0.0068101652	-3.729254e-03	-0.0010668870	-2.981077e-04	0.0064752319
	alm1	alm2			
mcg	1.667014e-02	0.0068101652			
gvh	5.545672e-03	-0.0037292537			
lip	1.828870e-03	-0.0010668870			
chg	-4.504264e-05	-0.0002981077			
aac	7.379099e-03	0.0064752319			
alm1	4.654862e-02	0.0365657196			
alm2	3.656572e-02	0.0438527639			

Como se ha mencionado anteriormente, la varianza es una medida de dispersión. Mientras más pequeña sea la varianza menor será la dispersión de los datos. En este caso las varianzas son todas pequeñas, esto indica que la mayor parte de los datos tienden a estar agrupados cerca de su media y el valor de ninguna sobresale demasiado por encima de las otras, por lo que no es necesario estandarizar.



3.1.2 Análisis de la correlación de los datos E.coli

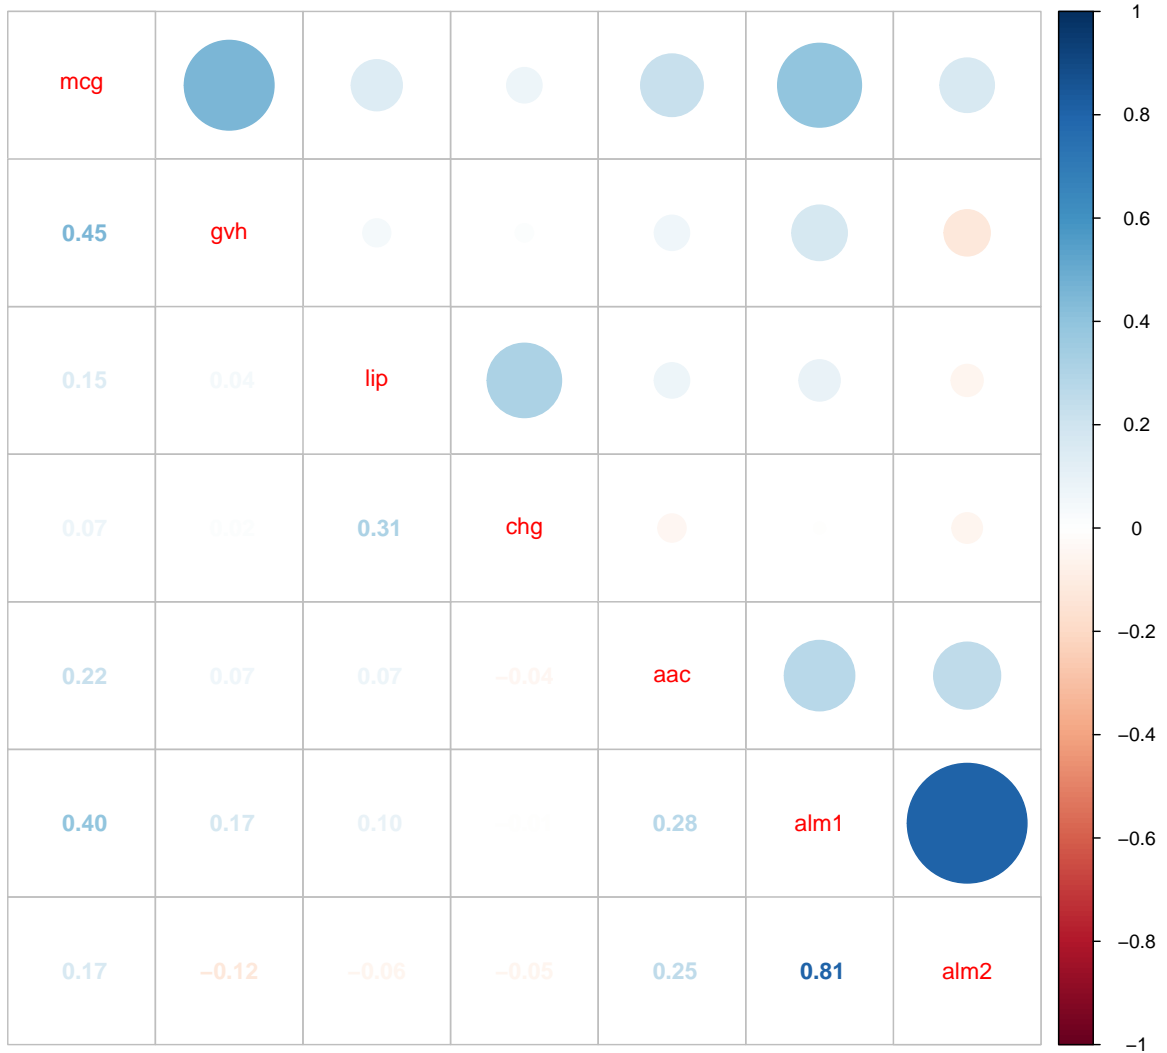
Se calcula la matriz de correlación para compararla con la matriz de varianzas y covarianzas que se calculó anteriormente y así elegir la matriz más adecuada para realizar el análisis de componentes principales.

	mcg	gvh	lip	chg	aac	alm1
mcg	1.0000000	0.45480526	0.14684148	0.070265602	0.22069904	0.396978631
gvh	0.4548053	1.00000000	0.04380447	0.018466013	0.06982428	0.173491832
lip	0.1468415	0.04380447	1.00000000	0.311951010	0.07019002	0.095787600
chg	0.0702656	0.01846601	0.31195101	1.000000000	-0.04472587	-0.007653676
aac	0.2206990	0.06982428	0.07019002	-0.044725866	1.00000000	0.279482496
alm1	0.3969786	0.17349183	0.09578760	-0.007653676	0.27948250	1.000000000
alm2	0.1670862	-0.12019925	-0.05757048	-0.052188439	0.25267457	0.809323614
	alm2					
mcg	0.16708617					
gvh	-0.12019925					
lip	-0.05757048					
chg	-0.05218844					
aac	0.25267457					
alm1	0.80932361					
alm2	1.00000000					

La siguiente gráfica representa la correlación entre cada una de las variables de la base de datos E.coli, el tamaño de los círculos está asociado al valor absoluto de la correlación.

Se observa que existe una correlación positiva de 0.81 entre la puntuación obtenida en la abertura en la membrana ALOM con respecto a la puntuación de la abertura en la membrana ALOM sin las señales de división. También se presenta una correlación positiva de 0.45 entre el valor obtenido por el método MCGreoch y el valor obtenido por el método Von Heijne, así como la abertura de la membrana ALOM con el valor obtenido por el método MCGreoch.

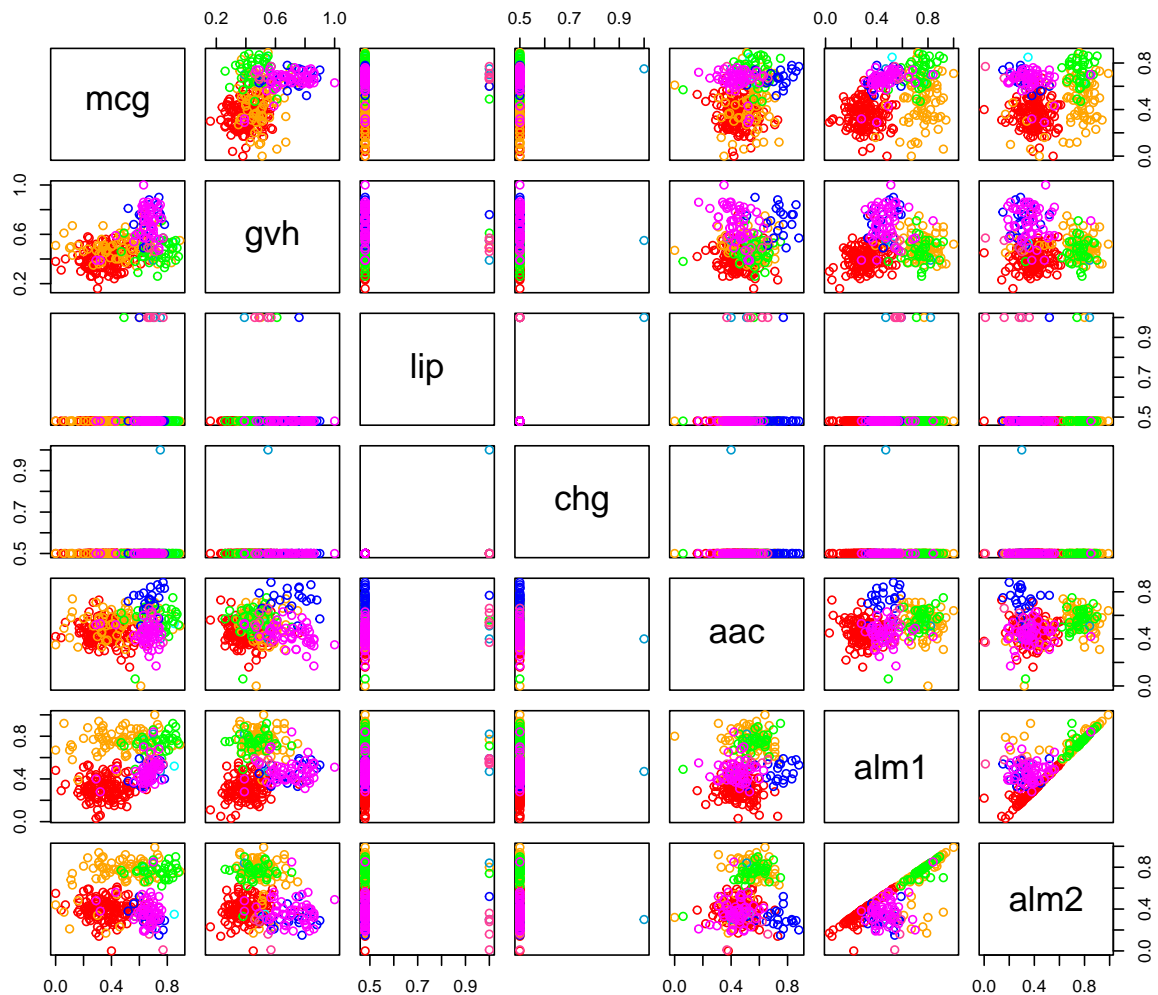
Por otro lado, es importante destacar que no se presenta una correlación entre la cantidad de carga en el extremo N y el valor obtenido por el método Von Heijne, mientras que la puntuación en la abertura de la membrana ALOM y la cantidad de carga en el extremo N tampoco se ven correlacionados. Por último, se puede notar que existe una correlación positiva de 0.4 entre la puntuación en la abertura de la membrana ALOM y el valor obtenido por el método MCGreoch.



3.1.3 Matriz de dispersión para los datos E.coli


La matriz de dispersión mostrará cada variable contra otra variable para visualizar la correlación entre ellas. Si los puntos en el diagrama están dispersos, significa que las dos variables que se están graficando no tienen correlación entre sí. Si los puntos forman algún patrón, denota la existencia de correlación entre las dos variables.

En la gráfica se observa una correlación positiva entre la variable *mcg* y la variable *gvh*, así como una fuerte correlación positiva entre la variable *alm1* y la variable *alm2*. Además son visibles algunas agrupaciones que se definen por su clase de distribución. Los colores indican la clase de distribución, que es el lugar donde se localiza la proteína en la bacteria, la clasificación se encuentra en la descripción de la base de datos.



3.1.4 Curvas de Andrews para datos E.coli


En 1972, Andrew propuso un método basado en la transformación de Fourier para representar datos multivariados en dos dimensiones. Una gráfica de Andrews está basado en una transformación de Fourier, es una representación funcional alternante de senos y cosenos llamemosla f , de cada observación. La magnitud de cada variable de un sujeto particular afecta la frecuencia, la amplitud y la periodicidad de f , dando una representación única para cada sujeto.



Los cuatro tipos de gráficas de curvas de Andrews nos muestran las 9 variables de la base de datos E.coli que están representadas con distinto color cada una de ellas, y cada una de las curvas representa una observación. Notemos que la muestra presenta similitud en la periodicidad y la amplitud de curva. Lo que nos lleva a pensar que el comportamiento de las variables es muy similar y no presentan alguna observación atípica.

3.1.5 Diagrama de caja

Este ha sido un aporte fundamental realizado por Tukey (1977). Es una manera de representar la distribución de los datos a través de los cuartiles. Es un diagrama que suministra información sobre el mínimo y máximo, los cuartiles (Q_1 , $Q_2 =$ mediana, Q_3) la presencia de valores atípicos y la simetría de los datos. Se representa con una caja que se divide por líneas horizontal a nivel de los cuartiles y una línea vertical (un bigote). La dispersión está dada por la altura de la caja, así como por la distancia entre los extremos de los bigotes. El sesgo se observa en la desviación que exista entre la línea de la mediana con relación al centro de la caja, y también la relación entre las longitudes de los bigotes.





En este diagrama de caja se observa que existen datos atípicos en la variable “gvh” (valor obtenido por el método Von Heijne) así como en la variable “aac” (puntuación del contenido de aminoácidos) y los datos se encuentran centrados respecto a la mediana, mientras que la variable “lip” (puntuación del consenso de la señal peptídica) y “chg” (cantidad de carga en el extremo N) presentan un dato atípico cada una, además ambas variables presentan todos sus datos concentrados muy cerca de la mediana. La variable mcg no presenta datos atípicos pero sí una mayor dispersión de los datos respecto a la mediana, aun así se encuentran bastante centrados. En cuanto a las variables alm1 y alm2, los datos están mucho más dispersos y sesgados a la derecha pero no presentan algún dato atípico.

3.2 Análisis de componentes principales

3.2.1 Aplicación

Se calculan los valores y vectores propios de la matriz de varianzas y covarianzas o de la matriz de correlación que se obtienen de la matriz de datos. La elección de una u otra matriz para realizar el modelo PCA depende de cómo se comportan los datos. En este caso se utilizará la matriz de varianzas y covarianzas porque los datos no presentan diferentes escalas.



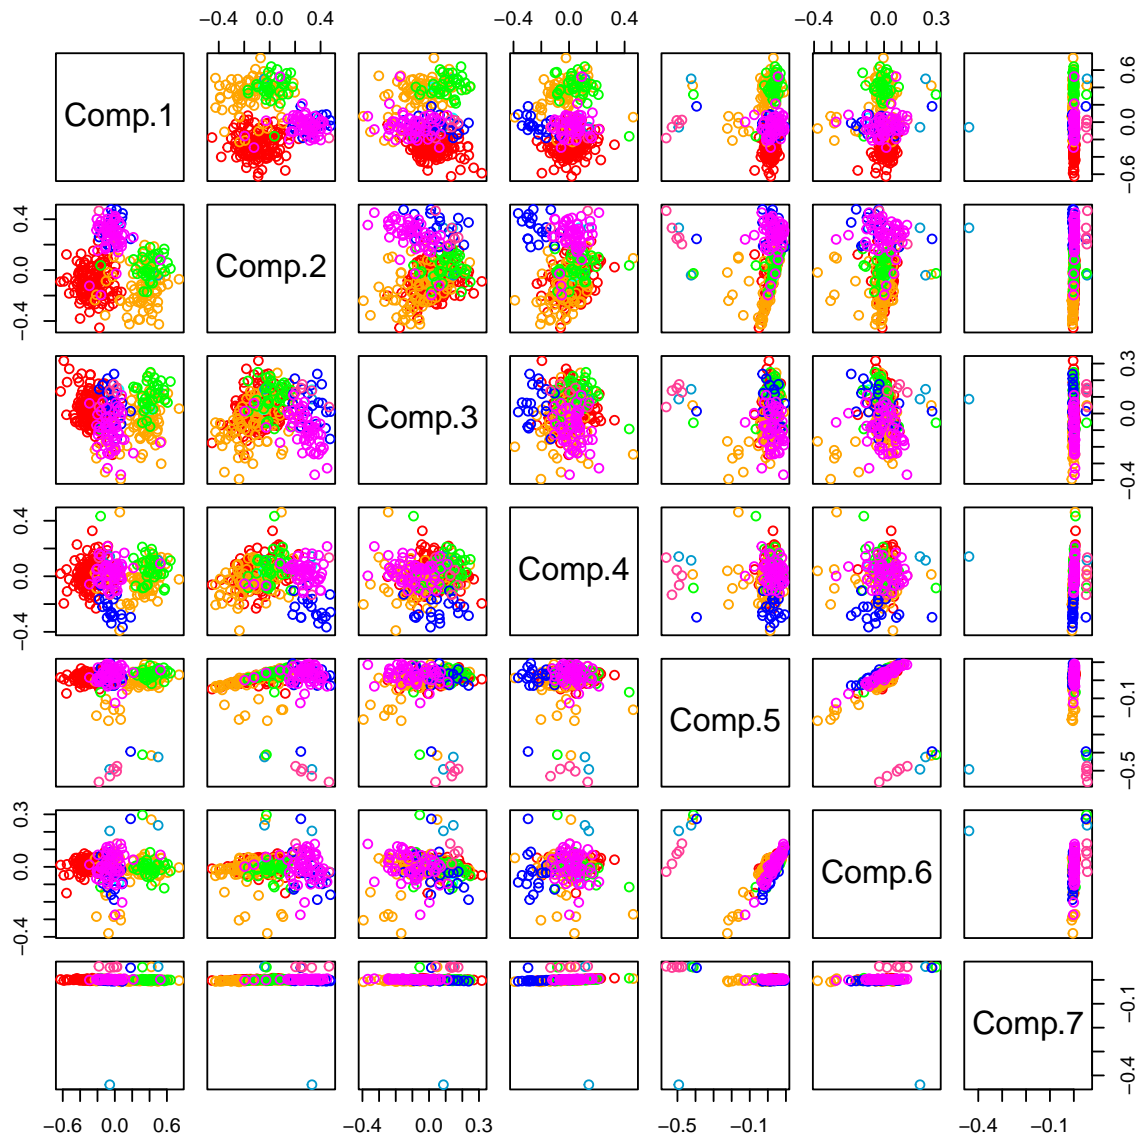


Aplicando el modelo PCA a la base de datos E.coli se observa la separación en tres nubes de datos. La primera nube de datos que se encuentra en la parte superior del plano entre los cuadrantes I y II se caracterizan por tener similitud en el valor obtenido por el método MCGreoch y el método Von Heijne, pero no se ven relacionadas con la abertura de la membrana ALOM ni con la puntuación del contenido de aminoácidos. La segunda nube de datos que se encuentra de lado derecho entre los cuadrantes I y IV presenta similitudes con respecto a la puntuación en la abertura de la membrana ALOM, la puntuación de ésta pero sin señales de división y la puntuación del contenido de aminoácidos, pero no presentan relación con el valor obtenido en el método MCGreoch o Von Heijne. Por último, la nube de datos que se encuentra de lado izquierdo entre los cuadrantes II y III, están agrupados porque presentan similitudes entre ellos pero no están caracterizadas por ninguna de las variables presentes.

3.2.2 Componentes principales

Importance of components:

	Comp.1	Comp.2	Comp.3	Comp.4	Comp.5
Standard deviation	0.2990578	0.2057005	0.12078481	0.11333703	0.09224002
Proportion of Variance	0.5161681	0.2442034	0.08419874	0.07413522	0.04910432
Cumulative Proportion	0.5161681	0.7603715	0.84457023	0.91870545	0.96780977
	Comp.6	Comp.7			
Standard deviation	0.07014688	0.02563124			
Proportion of Variance	0.02839865	0.00379158			
Cumulative Proportion	0.99620842	1.00000000			




Se obtiene el porcentaje de varianza explicada por la 1^a, 2^a, 3^a y 4^a componente principal respectivamente.

Comp.1	Comp.2	Comp.3	Comp.4	Comp.5	Comp.6	Comp.7
51.616810	24.420340	8.419874	7.413522	4.910432	2.839865	0.379158

Comp.1	Comp.2	Comp.3	Comp.4	Comp.5	Comp.6	Comp.7
51.61681	76.03715	84.45702	91.87054	96.78098	99.62084	100.00000

Gráfica de codo



La gráfica de codo nos muestra el porcentaje de variabilidad explicada por cada una de las componentes principales, de esta manera, se observa que la mayor variabilidad se encuentra explicada en las tres primeras componentes principales, las cuales representan aproximadamente un 84% de la variabilidad de los datos.


Loadings:

	Comp.1	Comp.2	Comp.3	Comp.4	Comp.5	Comp.6	Comp.7
mcg	0.342	0.730	0.457	0.353	0.129		
gvh		0.529	-0.704	-0.343	0.139	0.281	
lip					-0.855	0.494	0.106
chg							-0.994
aac	0.147		0.470	-0.866			
alm1	0.690		-0.254		-0.351	-0.575	
alm2	0.614	-0.418			0.317	0.583	

	Comp.1	Comp.2	Comp.3	Comp.4	Comp.5	Comp.6	Comp.7
SS loadings	1.000	1.000	1.000	1.000	1.000	1.000	1.000
Proportion Var	0.143	0.143	0.143	0.143	0.143	0.143	0.143
Cumulative Var	0.143	0.286	0.429	0.571	0.714	0.857	1.000

Como se menciona antes, las primeras tres componentes principales explican un 84% de la variabilidad de nuestros datos e interpretando las cargas de cada una de ellas, concluimos que la primera componente tiene una representación perpendicular a la puntuación obtenida de la abertura de la membrana ALOM (con y sin señales), la segunda componentes representa el valor obtenido en el método Mcgeoch y el método Von Heijne y los contrasta con la abertura de la membrana ALOM, mientras que la tercera componente representa el valor obtenido por el método Von Heijne.

Gráfica de las dos primeras componentes principales



Graficando la segunda componente principal contra la primera componente principal se observa una similitud a la gráfica que se obtuvo al aplicar el modelo PCA a la base de datos E.coli, en este caso se asignó un color para cada clase de distribución, es decir, el lugar donde se localiza la proteína de esa bacteria. Así se tienen nuevamente 3 grupos, clasificados por la localización de su proteína, que al compararlos con las componentes principales, se podrá encontrar una relación entre las clases de distribución y las variables restantes. Uno de los grupos se conforma por la clase “cp”, el cual no se relaciona específicamente con ninguna de nuestras variables pero si presentan similitudes entre ellos. Otro grupo se conforma en su mayoría por las “im” e “imU” presentan similitudes en cuanto a la puntuación de la abertura de la membrana ALOM y la puntuación de la abertura de la membrana ALOM pero sin señales de división, además de la puntuación del contenido de aminoácidos. El último grupo se encuentra conformado por diferentes clases en gran parte por la clase “om”, “pp” y algunos de la clase “imS” y “omL” que se encuentran relacionados por el valor obtenido en el método MCGreoch y Von Heijne.

La siguiente gráfica representa a la base de datos E.coli con respecto a las tres primeras componentes principales, en la cual se aprecia una mayor visibilidad de los datos representados en R^3 . Se observan las mismas agrupaciones que en la gráfica de las dos primeras componentes principales.





Figura 12: Gráfica de las 3 primeras componentes principales, cada color corresponde a la clase de distribución de la bacteria.

3.2.3 Biplot

Un biplot es una representación gráfica de datos multivariados. Aproxima la distribución de una muestra multivariada en un espacio de dimensión reducida, normalmente de dimensión dos, y superpone sobre las mismas representaciones de las variables sobre las que se mide la muestra. Las representaciones de las variables son solo vectores, y coinciden con las direcciones en las que mejor se muestra el cambio individual de cada variable. Aquí los puntos representan a los individuos, y los dos ejes a las componentes principales.

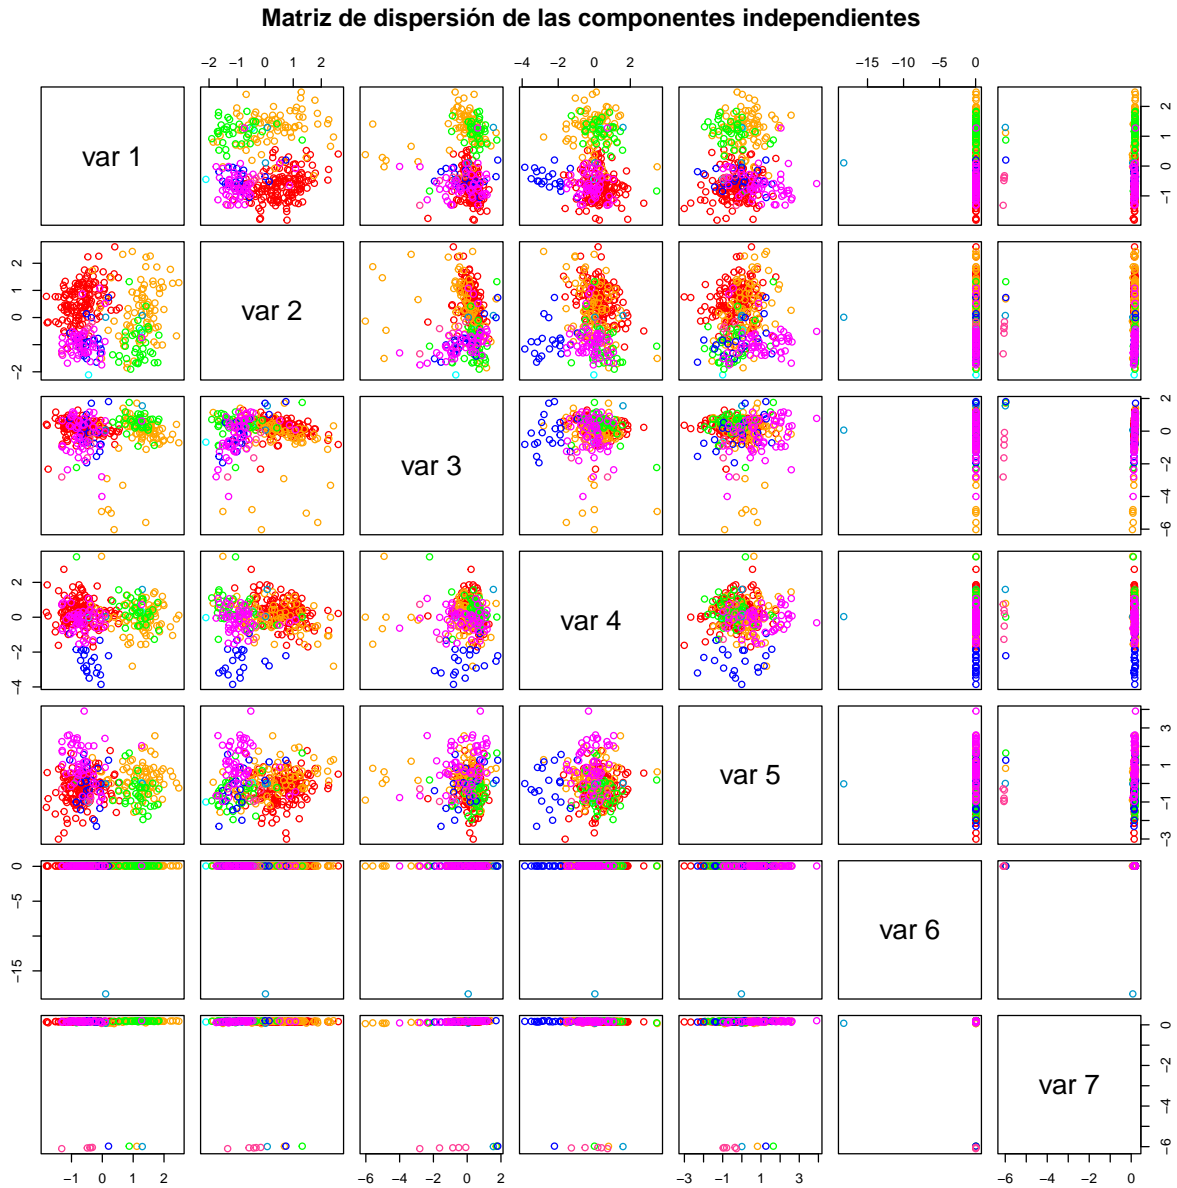


Es otra forma de representar los datos, las variables y las componentes principales juntas. Y así, poder observar de manera sencilla pero no tan detallada, los tres grupos, su relación con las variables y las dos primeras componentes principales que encontramos en las gráficas anteriores.

3.3 Análisis de componentes independientes (FastICA)

3.3.1 Calculando las 7 componentes independientes

Usando la función $\frac{1}{a} \log \cosh(aS)$ para la aproximación de la negentropía. Las 7 componentes independientes calculadas están en el Anexo B.




En la matriz de dispersión se observa que con las tres primeras componentes independientes (var1, var2 y var3) bastan para lograr una buena separación de los datos. Los datos se dividen en dos visibles agrupaciones independientes, que a su vez están conformadas por varias nubes de datos, las cuales se encuentran clasificadas por un color que corresponde a la localización que tienen de la proteína. Se presenta una buena proyección de las agrupaciones para la cuarta componente (var4) y la quinta componente (var5) contra la primera componente (var1). Las agrupaciones varían con respecto al ángulo en que se observan los datos, es decir, respecto a cuales componentes se está observando la nube de datos. Para las componentes independientes restantes tenemos que los datos se encuentran dispersos y no independientes unos de otros por lo que no se consideran relevantes para este análisis.

3.3.2 Calculando las 3 primeras componentes independientes

Usando la función $\frac{1}{a} \log_{\cosh}(aS)$ para la aproximación de la negentropía. Este número de componentes fue elegido por los resultados del análisis de componentes principales, donde se indica que las 3 primeras componentes principales explican la mayor cantidad de varianza en los datos. Las 3 componentes independientes calculadas están en el Anexo C.


Matriz de dispersión de las 3 primeras componentes independientes





En la matriz de dispersión se observan solo tres componentes independientes, ya que, considerando los resultados del modelo PCA basta con tomar tres componentes independientes para obtener la mejor agrupación de los datos. Tenemos dos grupos (el primero corresponde principalmente a los colores rojo, magenta y azul, mientras que el segundo corresponde a los colores verde y naranja), pero también se aprecia una pequeña separación del primer grupo en dos (un grupo el color rojo y el otro son los colores magenta y azul).

3.3.3 Gráfica de mezclas con blanqueamiento


Las siguientes gráficas representan el comportamiento de los datos después de haber realizado el blanqueamiento es decir, después de sustraer la media del vector.






3.3.4 Gráficas de las componentes independientes


Gráfica de la primera componente independiente



Gráfica de la segunda componente independiente



Gráfica de la tercera componente independiente




En las gráficas anteriores se pueden apreciar los datos como señales independientes. En la primera gráfica se representa a la primera componente independiente, se observa una muy buena separación de las señales, se tienen ahora tres señales independientes, la primera corresponde a las bacterias citoplásmicas (color rojo), la segunda corresponde a las proteínas de membrana interna con señal de secuencia y sin señal de secuencia (los colores: naranja, cian, azul medio y verde), la tercera corresponde principalmente a las proteínas de membrana externa y periplásmicas (los colores: azul, violeta y magenta).

La segunda gráfica representa la segunda componente independiente, no presenta una mejor separación de las señales en comparación a la gráfica de la segunda componente independiente, al contrario, se aprecian solo dos señales independientes (como en la gráfica de la primera componente independiente). Por lo tanto, se tiene una mejor separación de las señales hasta la segunda componente independiente.

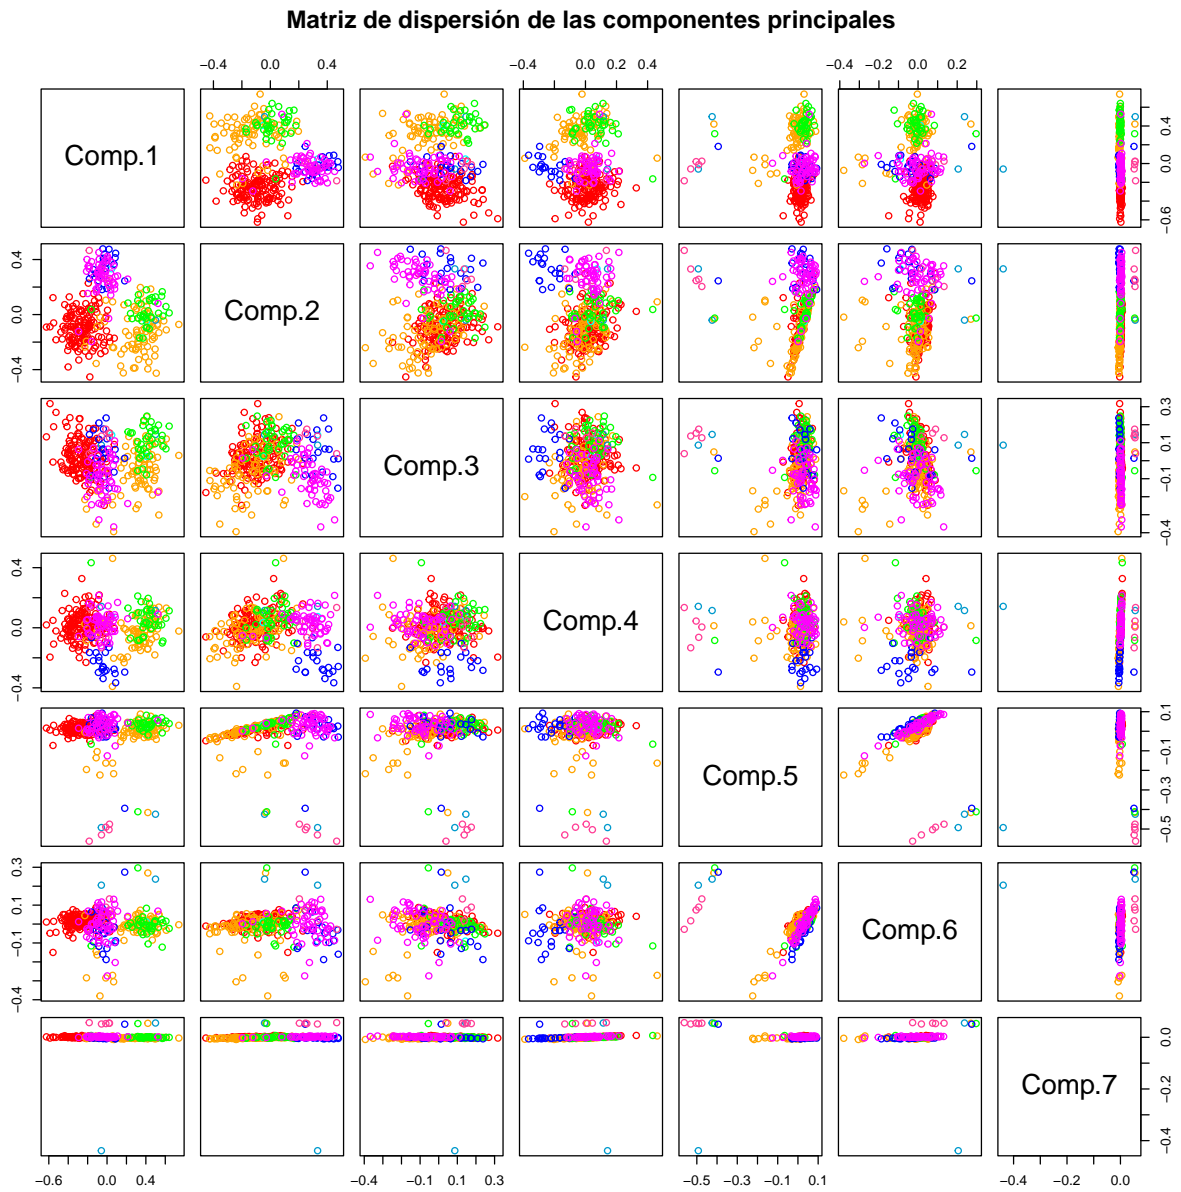
Por último, para la tercera gráfica se representa a la tercera componente independiente, la cual no presenta una buena separación de señales independientes, destaca la gran cantidad de bacterias citoplásmicas (color rojo), bacterias de membrana interna (color naranja) y bacterias periplásmicas (color magenta), como su nombre lo indica son bacterias que concentran la mayor cantidad de proteína en el citoplasma, membrana interna o periplasma.

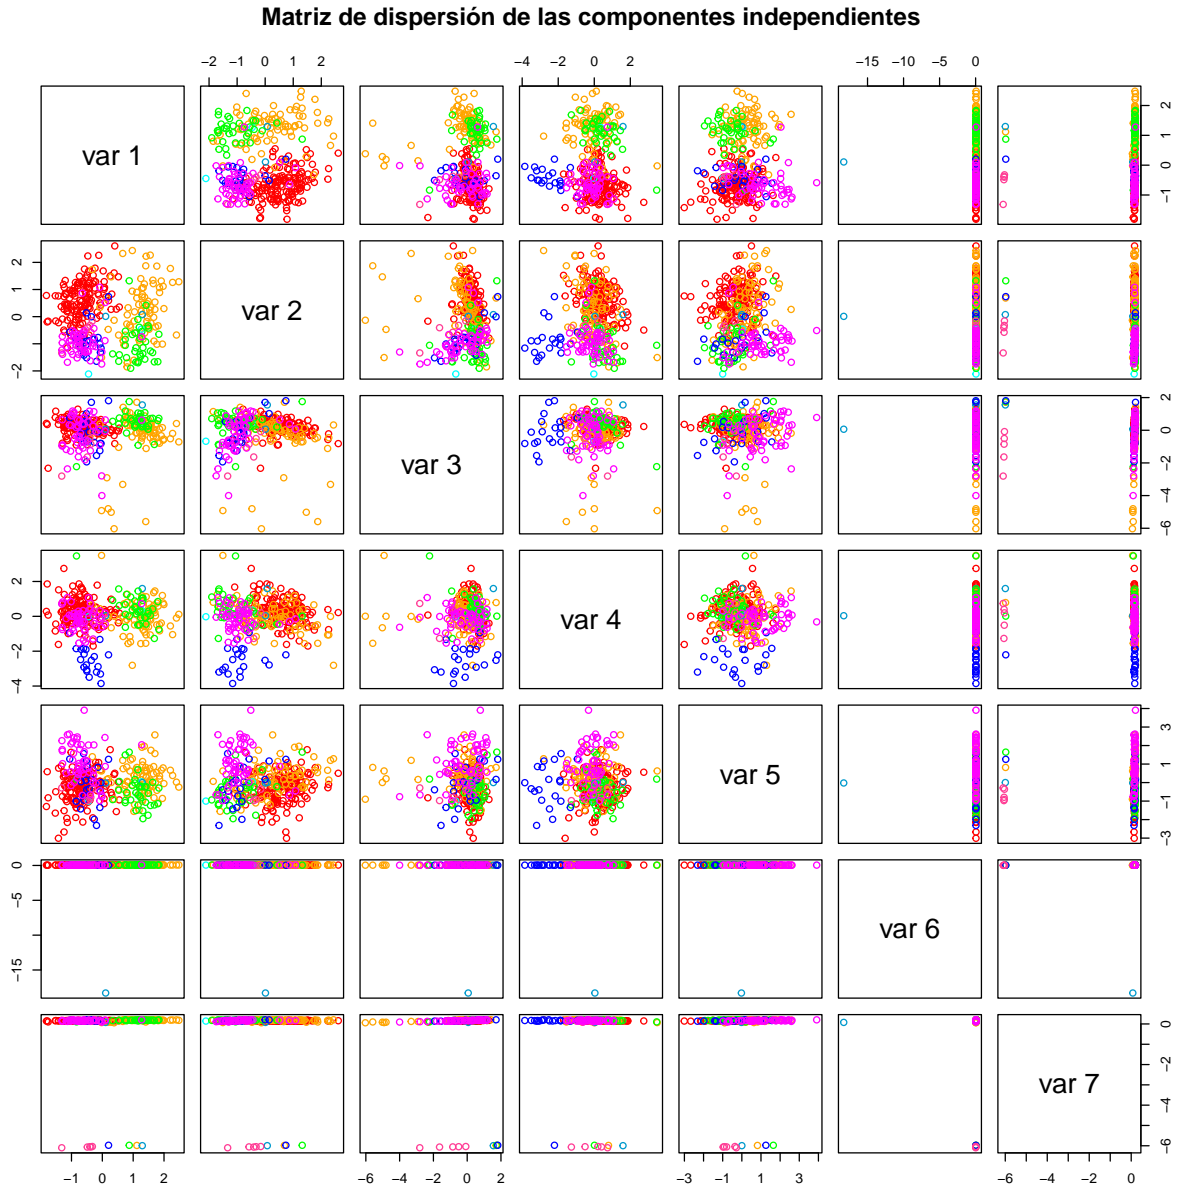
Gráfica de las dos primeras componentes independientes



Graficando la segunda componente independiente contra la primera componente independiente y asignando un color diferente dependiendo el lugar donde se encuentra localizada la proteína. Se observan dos agrupaciones. La primera agrupación esta conformada principalmente por “ImU”, “Im” es decir son las proteínas de membrana interna con y sin señales de secuencia. La segunda agrupación se conforma principalmente por “cp”, “pp” “om” es decir en su mayoría son proteínas citoplásmicas, periplásmicas y membrana externa.

Conclusiones






Comparando las matrices de dispersión de las componentes principales y las componentes independientes se puede concluir que en la gráfica de componentes principales se aprecia una clara agrupación de los datos que están correlacionados, con la primera y segunda componente principal, cabe destacar que los datos presentan una mejor proyección (es decir, una mayor variabilidad) en todas las componentes principales restantes, porque el modelo PCA busca que las observaciones se encuentren con mayor varianza posible. Mientras que la gráfica de las componentes independientes presenta desde el principio una agrupación de los datos independientes en las dos primeras componentes independientes, sin embargo de la tercera componente independiente en adelante, se pierden gradualmente las agrupaciones. Ambas gráficas presentan las mismas tres agrupaciones, con la diferencia de una rotación de los datos.


Es importante recordar que las componentes principales agrupan los datos con respecto a su correlación mientras que las componentes independientes agrupan los datos respecto a su independencia. Es por esto que a pesar de que se tiene una agrupación muy parecida en ambas matrices, los resultados obtenidos tienen una interpretación diferente.

Para nuestra base E.coli las agrupaciones que son correlaciones son casi las mismas que las agrupaciones independientes, así concluimos que los datos están separados por correlación y a su vez por independencia.

Gráfica de las dos primeras componentes principales



Gráfica de las dos primeras componentes independientes



Ahora comparando las gráficas para las dos componentes principales e independientes respectivamente, a simple vista en ambas gráficas parece que las agrupaciones son bastante diferentes, pero si observamos cuidadosamente notaremos que la diferencia radica en la proyección que se tiene de los datos como lo mencionamos anteriormente se presenta una rotación de los datos. De esta manera logramos encontrar tres grupos, uno que corresponde a los “Im” e “ImU”, otro grupo que corresponde a los “om”, “pp” y “omL”, y finalmente el grupo que corresponde a los “cp”, en ambas gráficas.

Referencias

- Chatfield, C., Collins, A.,(1980). *Introduction to Multivariate Analysis*, Springer-Science.
- Chattopadhyay, A., Mondal, S., Biswas, A.,(2015). *Independent Component Analysis and Clustering for Pollution Data*, Environ Ecol Stat 22, 33-43. D.P: Acharya & G. Panda (2008). *A Review of Independent Component Analysis Techniques and their Applications*, IETE Technical Review, 25:6, 320-332.
- Fisher, R.A. (1936). *The use of multivariate measurements in taxonomic problems*, Ann. Eugenics 7, Pt.II, 179,188.
- Hyvarinen, A., Karhunen, J. & Oja, E. (2001). *Independent Component Analysis*, Wiley-Interscience.
- Hardle, W., Simar, L. (2015). *Applied Multivariate Statistical Analysis*, Springer-Verlag. 4° Edition.
- Jeffers, J., (1967). *Two Cases Studies in the Application of Principal Component Analysis*, Journal of the Royal Statistical Society, 16:3, 225-236.
- Kendall, M. G.,(1980). *Multivariate Analysis*, Lubrecht & rammer Ltd. 2° Edition.
- Machine Learning Repository*. <https://archive.ics.uci.edu/ml/about.html>.
- Naik, G., (2012).Editor *Independent Component Analysis for Audio and Biosignal Application*, InTech, Croacia.
- Nakai, K., Kanehisa, M.,(1991). *Expert System for Predicting Protein Localization Sites in Gram-Negative Bacteria*, Proteins: Structure, Function, and Genetics, 11:95-110.
- Nakai, K., Kanehisa, M.,(1992). *A Knowledge Base for Predicting Protein Localization Sites in Eukaryotic Cells*, Genomics, 14, 897-911.
- Rencher, A.,(2002), *Methods of Multivariate Analysis*, Wiley-Interscience publications. 2° Edition.

Código en R

```
# ##### Base de datos Iris #####

# ##### Análisis de componentes principales #####

#Biblioteca para utilizar la función que realizara el PCA.
library(FactoMineR)

#Cargamos la base de datos.
ir <- iris
i2 <- iris[,-5]

#Aplicamos el modelo PCA a a base de datos.
pca <- princomp(i2)

#Se obtiene un resumen de los datos más importantes de la base.
summary(pca)

#La gráfica de dispersión.
coloris1=rep("firebrick1",50)
coloris2=rep("blue",50)
coloris3=rep("chartreuse1",50)

coloris <- c(coloris1, coloris2, coloris3)
pairs(pca$scores[, 1:4], col=coloris)

#Se calculan los valores propios.
valores.propios <- pca$sdev^2
cumsum(valores.propios / sum(valores.propios) * 100)
(valores.propios / sum(valores.propios) * 100)

#La gráfica de codo
plot(valores.propios, type = "o", pch = 10, main = "Gráfica de codo",
      ylab = "Valores propios", xlab = "Componentes")

#Las cargas de cada componente.
aux<- princomp(i2, cor=F)
aux$loadings

# ##### Análisis de componentes independientes #####

#Biblioteca para la función FastICA.
```

```

library(fastICA)

#Se calculan las componentes independientes.
ica4 <- fastICA(i2, fun = "logcosh", alpha = 1, n.comp = 4)

#La gráfica de dispersión.
ica4$$S

#Se calculan solo dos componentes principales.
ica2 <- fastICA(i2, fun = "logcosh", alpha = 1,
               method = "R", row.norm = FALSE, maxit = 200,
               tol = 0.0001, verbose = TRUE, n.comp = 2)

#La gráfica de dispersión.
ica2$$S

#Gráficas de mezclas.
plot(ica2$$X[,1], type = "o", xlab="x1", ylab= "", col=coloris)
plot(ica2$$X[,2], type = "o", xlab="x2", ylab= "", col=coloris)

#Gráficas de las componentes independientes.
plot(ica2$$S[,1], xlab = "s1", ylab = "", type="o",
     main = "Gráfica de la 1° componente independiente", col=coloris)
plot(ica2$$S[,2], xlab = "s2", ylab="", type="o",
     main= "Gráfica de la 2° componente independiente", col=coloris)

# ##### Base de datos E.coli #####

# ##### Análisis de componentes principales #####

#Se carga la base de datos E.coli.
Eco <- read.table(file = "Ecoli.txt", header = F, sep = "", dec = ".")

colnames(Eco) <- c("Seq. name", "mcg", "gvh", "lip", "chg", "aac",
                 "alm1", "alm2", "class dist")
Eco2 <- Eco[,-c(1,9)]

#Se obtiene un resumen de los datos importantes de la base.
summary(Eco)

#Aplicamos el modelo PCA a la base de datos.
pca <- PCA(Eco2, scale.unit =F, ncp = 7 )

```

```

#La gráfica de dispersión.
pca2 <- princomp(Eco2)

col1=rep("red",143)
col2=rep("orange",77)
col3=rep("cyan",2)
col4=rep("deepskyblue3",2)
col5=rep("green",35)
col6=rep("blue",20)
col7=rep("violetred1",5)
col8=rep("magenta",52)

colores <- c(col1, col2, col3, col4, col5, col6, col7, col8)

pairs(pca2$scores[,1:7], col=colores)

#Se calculan los valores propios.
v.p <- pca2$sdev^2
(v.p / sum(v.p) * 100)
cumsum(v.p / sum(v.p) * 100)

#La gráfica de codo.
plot(v.p, type = "o", main = "Gráfica de codo",
      ylab = "Valores propios", xlab = "Componentes")

#La gráfica de biplot.
pca_bi <- prcomp(Eco2, scale = F)
biplot(pca_bi,cex = 0.6, col = c("dodgerblue3", "red"))

#Las cargas de cada componente.
aux<- princomp(Eco2, cor=F)
aux$loadings

# ##### Análisis de componentes independientes #####

#Se calculan las componentes independientes.
icaE7 <- fastICA(Eco2, fun = "logcosh", alpha = 1, n.comp = 7)

#La gráfica de dispersión.
icaE7$S

#Se calculan solo tres componentes independientes.
icaE3 <- fastICA(Eco2, fun = "logcosh", alpha = 1,

```



```

        method = "R", row.norm = FALSE, maxit = 200,
        tol = 0.0001, verbose = TRUE, n.comp = 3)

#La matriz de dispersión.
icaE3$$S

#Las gráficas de mezclas.
plot(icaE3$X[,1], type = "b", xlab="X1", ylab= "", col= colores)
plot(icaE3$X[,2], type = "b", xlab="X2", ylab= "", col= colores)
plot(icaE3$X[,3], type = "b", xlab="X3", ylab= "", col= colores)

#Las gráficas de las componentes independientes.
plot(icaE3$$S[,1], xlab = "s1", ylab = "", type="o",
     main = "Gráfica de la primera componente independiente",
     col= colores)

plot(icaE3$$S[,2], xlab = "s2", ylab="", type="o",
     main= "Gráfica de la segunda componente independiente",
     col=colores)

plot(icaE3$$S[,3], xlab = "s3", ylab="", type="o",
     main= "Gráfica de la tercera componente independiente",
     col=colores)

```

Anexo A

	[,1]	[,2]	[,3]	[,4]
[1,]	-0.3731103299	1.39305184	-0.018046918	0.26203582
[2,]	0.9756048949	1.32922681	0.084039160	0.37752998
[3,]	0.3485638914	1.34781575	0.161068441	-0.36229856
[4,]	0.3729353161	1.20514015	-0.314506286	-0.88231674
[5,]	-0.7378007985	1.37334752	-0.097233541	-0.19695499
[6,]	-1.4704233469	1.26607910	0.271943729	0.26537969
[7,]	-0.3184716210	1.25534723	0.318819658	-1.04992861
[8,]	-0.2463989716	1.30837382	-0.258219118	-0.07982928
[9,]	0.9333778337	1.20977687	-0.088643106	-1.03158768
[10,]	0.4795283108	1.29297195	-0.698120683	-0.04541574
[11,]	-0.8657332593	1.41160750	-0.201931950	0.72265817
[12,]	-0.4843780818	1.20399149	-0.577577941	-0.88068519
[13,]	0.8109195365	1.32428910	-0.467487830	-0.03097467
[14,]	0.7788413960	1.38231998	0.028829011	-1.05327248
[15,]	-1.1780477459	1.68883392	0.560562799	2.05960488
[16,]	-2.5466391161	1.46909168	0.682640853	0.81754310
[17,]	-1.0610636123	1.49806944	1.213553837	0.97799202
[18,]	-0.2762445598	1.37479717	0.491501923	0.35918905
[19,]	-1.0669594719	1.35042284	-0.074462193	1.24992008
[20,]	-1.2691971343	1.32726375	0.144473972	-0.26188222
[21,]	-0.1798004857	1.28514816	-0.561111580	0.80927019
[22,]	-0.8754604839	1.30552103	0.691231288	-0.01708959
[23,]	-0.5997194171	1.51256835	0.676463975	-0.72974830
[24,]	0.2042089399	1.15731897	0.878808975	0.31431507
[25,]	-0.7913978828	1.02999873	-1.283785522	-1.41514444
[26,]	0.8387446159	1.23642402	-0.344787746	0.33257522
[27,]	-0.1550073651	1.21386690	0.525476037	-0.06367589
[28,]	-0.4076306753	1.35824663	-0.211471297	0.39523414
[29,]	-0.0084198614	1.41275616	0.061139705	0.72102662
[30,]	0.0415440904	1.17382300	-0.545139140	-0.89675781
[31,]	0.4062345590	1.19352732	-0.465952517	-0.43776700
[32,]	0.2186109218	1.36463399	0.928791157	1.35988284
[33,]	-2.2857217270	1.39742964	-0.944270986	-0.58775547
[34,]	-2.1799281387	1.51023774	-0.110593649	0.47396568
[35,]	0.5763940809	1.27471728	-0.188571842	0.05173750
[36,]	0.6543625899	1.47539047	0.522405412	0.74990876
[37,]	0.0005079569	1.54381893	0.385268201	1.68559454
[38,]	-0.9024861569	1.36840981	-0.648760530	-0.60545964
[39,]	0.7388468871	1.27126251	0.109550946	-1.00107400
[40,]	-0.1785793833	1.33156620	-0.216240970	0.23152213
[41,]	-0.2417242145	1.40960238	0.684926302	0.22599072

[42,] 2.9816284074 1.25178383 0.921537259 0.44090643
[43,] 0.1451051265 1.27823862 0.035133997 -1.29635279
[44,] -0.2581467052 1.18084562 1.507365245 -0.01700882
[45,] -1.5816910988 1.07701875 -0.287587294 -0.87734132
[46,] 1.0046510767 1.28777976 0.551609853 0.16333180
[47,] -1.4684028381 1.28752084 -0.600477396 -0.53718854
[48,] 0.1784043694 1.26662579 -0.116312234 -0.85180305
[49,] -0.9335528475 1.38841512 -0.243910098 0.41130676
[50,] 0.1528118423 1.36288335 0.014391884 0.24596320
[51,] -0.4087540810 -0.30973351 -0.762533973 1.90741790
[52,] -0.5141259733 -0.35114726 -0.034048967 0.49276883
[53,] -0.2875168862 -0.47066378 -0.728559859 1.48455295
[54,] 1.8653037826 -0.26477389 0.080938925 -0.28418035
[55,] 0.6388372024 -0.39990469 -0.078639447 1.21652475
[56,] 0.0048888895 -0.49093678 -1.198159787 -1.29043993
[57,] -0.9866305391 -0.50510142 -0.074491802 -0.22537490
[58,] 1.5872975979 0.06030701 -0.088967273 -1.34431634
[59,] 0.2160543703 -0.33671492 -1.092967456 1.18593029
[60,] 0.6735672004 -0.28065588 0.551121950 -1.53348585
[61,] 2.6379208400 -0.04644801 -0.368960280 -0.79871351
[62,] 0.0475376467 -0.30009250 0.536684823 -0.23425018
[63,] 2.2106752941 -0.09753605 -1.200608383 1.12875639
[64,] -0.1285177348 -0.52892906 -1.028711882 -0.45182661
[65,] 0.5612578239 0.01133716 0.841276333 -0.14605299
[66,] -0.0083221646 -0.20880594 -0.145052362 1.65546231
[67,] -0.4629409191 -0.54366239 -0.295457202 -1.70276366
[68,] 0.4883417824 -0.18447811 -1.706009580 -0.41029650
[69,] 2.3189436529 -0.43241257 0.254079485 1.34645998
[70,] 1.2479900038 -0.14009848 -0.735195032 -0.28426112
[71,] -0.8696464055 -0.69586591 0.578499236 -1.30698776
[72,] 0.7878669110 -0.10817935 0.146765440 0.84573113
[73,] 1.0867908657 -0.63074637 -0.757177899 0.50228086
[74,] -0.0253783947 -0.49590778 -2.010601090 -0.49849369
[75,] 0.3874349946 -0.20910692 -0.470716171 1.09768672
[76,] 0.2207291274 -0.23548637 -0.149822035 1.49175030
[77,] 0.5407503299 -0.42806807 -0.933058897 1.69711958
[78,] -0.0348935760 -0.61504351 0.008387475 1.02564292
[79,] 0.1052083143 -0.45438094 -0.090336135 -0.30971862
[80,] 1.3314326763 0.13682696 -0.298364092 0.49490999
[81,] 1.5793812294 -0.10878133 -0.504562178 -0.26982006
[82,] 1.5848553930 -0.03252907 -0.778708492 -0.18882021
[83,] 0.8867531899 -0.10499228 -0.216106844 0.14031614
[84,] 0.1817762431 -0.82759723 -0.918785505 -0.98620509
[85,] -0.5985800957 -0.59004714 -0.379413498 -2.32546649
[86,] -1.2822803170 -0.45519533 0.233170333 -0.95076237

[87,] -0.2184761955 -0.40105336 -0.341711102 1.21815630
[88,] 1.9985007543 -0.31122522 -0.524845998 1.49401860
[89,] -0.2473127247 -0.27516271 -0.372944777 -1.18445780
[90,] 1.2715620221 -0.25779778 0.006521976 -0.57945915
[91,] 0.4684656371 -0.46804539 -1.481845448 -1.53686411
[92,] -0.3230486814 -0.46744342 -0.830517830 -0.42131293
[93,] 1.0812841366 -0.16647792 -0.414300896 0.10980245
[94,] 1.9519880664 0.08001133 -0.009780650 -0.88532553
[95,] 0.5409599825 -0.34362446 -0.496721879 -0.91969270
[96,] -0.3786988401 -0.29171325 -1.075917997 -1.14841271
[97,] 0.0150378102 -0.31345597 -0.529160681 -0.90362008
[98,] 0.2517958180 -0.25549168 -0.554672467 0.47498390
[99,] 1.8299514652 0.26591790 1.173536970 -0.23764043
[100,] 0.4142486242 -0.25894644 -0.256549679 -0.57782760
[101,] -1.4452577457 -1.42336205 1.451214919 -1.66698586
[102,] 0.3367343768 -0.92874599 0.525904722 -1.31744821
[103,] -0.2972115453 -1.11727094 0.095872690 1.05628376
[104,] -0.5264748807 -1.07754125 -1.025182963 -1.04388860
[105,] -0.5049233713 -1.21668229 0.588955170 -0.53651839
[106,] -0.6744931394 -1.40729216 -1.342054258 1.36596923
[107,] 0.7404079044 -0.75995864 0.615835818 -2.94972009
[108,] -0.5646585333 -1.25160058 -2.253219170 0.82255393
[109,] 0.7276071263 -1.11471914 -1.179241525 0.43576847
[110,] -1.8278340256 -1.26216408 1.481990301 0.51410557
[111,] -0.5760171365 -0.76721374 1.143258226 0.22096793
[112,] 0.5389720392 -0.90558690 0.306968557 0.19435409
[113,] -0.0913105756 -0.95485773 0.911548354 0.83484186
[114,] 1.0618622528 -0.91917156 1.303294892 -1.05821450
[115,] 0.5241923470 -1.01653128 3.036440454 -0.97932142
[116,] -0.5579192818 -0.96116530 2.159121548 -0.15522994
[117,] -0.5853666507 -0.96967086 -0.743032614 -0.39067209
[118,] -2.9871147569 -1.43244759 -1.323597593 0.41520562
[119,] 0.4675217092 -1.60855410 -0.838352109 1.92772545
[120,] 1.6716048080 -0.76878525 -1.006889446 -0.16700826
[121,] -0.6281810749 -1.07719376 1.427402181 0.68891478
[122,] 0.2057699573 -0.87390218 1.385093846 -1.63433102
[123,] -0.2121374943 -1.43081881 -1.970610529 1.69729311
[124,] 0.7836464154 -0.67853427 0.697051675 0.49846178
[125,] -1.2544226720 -1.08358111 0.287139727 -0.27573391
[126,] -1.2160709615 -1.09033603 -1.700615162 0.60274358
[127,] 0.5212958805 -0.64024100 0.853267579 0.21762406
[128,] -0.2426054020 -0.71445485 0.501469955 -0.56715923
[129,] 0.1288128982 -1.11260094 0.582650184 -0.29343808
[130,] -0.6113808738 -0.94480764 -2.174490841 1.06002207
[131,] 0.1015775726 -1.13415576 -1.193678653 1.73500414

[132,] -2.7381873195 -1.17556074 -1.552531399 1.37806122
[133,] 0.2256786683 -1.13085561 1.092199025 -0.19628484
[134,] -0.0085016424 -0.73627737 -1.339608377 -0.29694349
[135,] -0.1589644968 -1.06137149 -3.035709200 -1.61228618
[136,] 0.0987576573 -1.13062119 0.896034207 2.76239253
[137,] -1.4296346615 -1.16962899 1.846067711 -1.19916616
[138,] -0.9500571193 -0.98937518 -0.822219237 -0.84966290
[139,] -0.2080850566 -0.67964964 0.694894334 -0.70035756
[140,] -0.2180219339 -0.87017972 1.151720554 1.17670696
[141,] -0.2677436675 -1.08732365 2.125605728 0.48915768
[142,] 0.2827294073 -0.73269630 2.877025817 1.90547268
[143,] 0.3367343768 -0.92874599 0.525904722 -1.31744821
[144,] -0.9006805305 -1.21638130 0.914618979 0.02125720
[145,] -0.8669595916 -1.15659979 2.325335092 0.11287904
[146,] 0.3416211773 -0.84056670 2.594875469 1.25225617
[147,] 1.3719140124 -0.76176263 1.045614939 0.71274073
[148,] -0.0846153096 -0.83218744 0.982272649 0.33809364
[149,] -1.3896401526 -1.05857153 1.765345776 -1.25136464
[150,] -0.5829244459 -0.87683477 -0.053291395 -1.54616822

Anexo B

	[,1]	[,2]
[1,]	1.37277503	-0.50401923
[2,]	1.27721158	0.50261461
[3,]	1.36913144	0.44701319
[4,]	1.26099959	0.79035288
[5,]	1.39603575	-0.51654535
[6,]	1.27077626	-1.37972308
[7,]	1.34823846	0.33103069
[8,]	1.31004162	-0.19122872
[9,]	1.27172809	1.32428637
[10,]	1.27116407	0.37240190
[11,]	1.35908366	-1.17281033
[12,]	1.27056892	0.10903567
[13,]	1.29922754	0.62409405
[14,]	1.45023723	1.20673454
[15,]	1.54432103	-2.24603947
[16,]	1.45417373	-2.58231290
[17,]	1.45237003	-1.50191981
[18,]	1.35372194	-0.49064107
[19,]	1.26064290	-1.65029035
[20,]	1.36921701	-0.90224306
[21,]	1.20739325	-0.66956079
[22,]	1.32986608	-0.74148117
[23,]	1.58948101	-0.09931165
[24,]	1.13882473	-0.07746974
[25,]	1.13437359	0.20068322
[26,]	1.18345182	0.42885536
[27,]	1.22653699	-0.13392321
[28,]	1.32441372	-0.60832766
[29,]	1.34951432	-0.49149312
[30,]	1.23293611	0.53866073
[31,]	1.20967540	0.55118685
[32,]	1.26008395	-0.70390282
[33,]	1.46525386	-1.50600818
[34,]	1.50300843	-2.07513574
[35,]	1.25211097	0.38578006
[36,]	1.40564127	0.01189119
[37,]	1.40632199	-1.07399884
[38,]	1.41805171	-0.39506591
[39,]	1.33742438	1.14635346
[40,]	1.30707875	-0.32608633
[41,]	1.40208325	-0.38633264

[42,] 1.17332353 2.05656010
[43,] 1.37802006 0.85158601
[44,] 1.20872863 -0.25455060
[45,] 1.16857014 -0.76666818
[46,] 1.26112135 0.65085038
[47,] 1.34287167 -0.88507205
[48,] 1.32669587 0.61241998
[49,] 1.36204653 -1.03795272
[50,] 1.33514223 -0.07439418
[51,] -0.47119885 -1.45550163
[52,] -0.38167783 -0.69407619
[53,] -0.59838380 -1.09878377
[54,] -0.27259414 1.66659357
[55,] -0.51123050 -0.20884971
[56,] -0.40402290 0.81270563
[57,] -0.46826710 -0.63212578
[58,] 0.14042933 2.07437672
[59,] -0.45578934 -0.51784737
[60,] -0.15616881 1.46446047
[61,] -0.03452179 2.59015238
[62,] -0.27126382 0.18333176
[63,] -0.25054704 1.09955477
[64,] -0.50542653 0.20036801
[65,] 0.02782381 0.52523689
[66,] -0.34641274 -0.99519263
[67,] -0.39857054 0.67955212
[68,] -0.18853055 0.66290053
[69,] -0.57873049 1.04947628
[70,] -0.15145669 1.17966300
[71,] -0.56021809 0.11199389
[72,] -0.18888216 0.12052930
[73,] -0.70239362 0.59466422
[74,] -0.48761818 0.32099540
[75,] -0.31366827 -0.33977970
[76,] -0.36374771 -0.71295130
[77,] -0.59186291 -0.56570234
[78,] -0.69626054 -0.62437932
[79,] -0.43071986 0.28750542
[80,] 0.06652515 0.76184678
[81,] -0.12339322 1.43135515
[82,] -0.05894168 1.38742781
[83,] -0.13583985 0.62855850
[84,] -0.76275931 0.77894612
[85,] -0.39264480 0.94926733
[86,] -0.34828376 -0.43603505

[87,] -0.50166117 -0.89016692
[88,] -0.47789088 0.70992944
[89,] -0.17887057 0.53059907
[90,] -0.23199846 1.37182612
[91,] -0.37424130 1.33326095
[92,] -0.43973024 0.02243510
[93,] -0.20153613 0.80649141
[94,] 0.11716862 2.08690284
[95,] -0.28516254 1.00329942
[96,] -0.20817879 0.41291247
[97,] -0.24752973 0.57367436
[98,] -0.30774253 -0.07006449
[99,] 0.27194366 1.57900841
[100,] -0.22242912 0.69050891
[101,] -1.22992474 -0.11458294
[102,] -0.81399285 1.08879583
[103,] -1.19291040 -0.83535446
[104,] -0.99615065 0.25910808
[105,] -1.14878783 -0.04337983
[106,] -1.52551387 -1.29579823
[107,] -0.51742583 2.38723033
[108,] -1.34356847 -0.87562372
[109,] -1.17999039 0.37031092
[110,] -1.24109551 -1.73990340
[111,] -0.75229685 -0.57874788
[112,] -0.92256697 0.34074855
[113,] -1.00242801 -0.55297836
[114,] -0.82528031 1.50124987
[115,] -0.88896049 1.00830293
[116,] -0.89729015 -0.34265742
[117,] -0.93638011 -0.18854004
[118,] -1.43054556 -2.56579829
[119,] -1.78396962 -0.72271706
[120,] -0.79979697 1.47193740
[121,] -1.09369828 -0.89474873
[122,] -0.71602548 1.16340712
[123,] -1.59541777 -1.11871737
[124,] -0.71895722 0.34003127
[125,] -1.02936851 -0.79917357
[126,] -1.14351675 -1.27456483
[127,] -0.65029807 0.29695597
[128,] -0.65213796 0.16759530
[129,] -1.07657065 0.31176870
[130,] -1.05520935 -1.06765207
[131,] -1.29508539 -0.91081780

[132,] -1.26216978 -2.95391738
[133,] -1.09562375 0.32514686
[134,] -0.73229698 0.21361141
[135,] -0.97490605 0.91746181
[136,] -1.33959071 -1.55664541
[137,] -1.00898003 -0.39754155
[138,] -0.91311940 -0.20106616
[139,] -0.60377664 0.27190373
[140,] -0.93969460 -0.86576888
[141,] -1.08172503 -0.49482080
[142,] -0.84160546 -0.93066009
[143,] -0.81399285 1.08879583
[144,] -1.18153230 -0.69879276
[145,] -1.10558089 -0.74566091
[146,] -0.90137600 -0.48301197
[147,] -0.82400444 0.67872607
[148,] -0.83829097 -0.25343125
[149,] -0.89616717 -0.33716047
[150,] -0.73700911 0.49840888

Anexo C

	[,1]	[,2]	[,3]	[,4]	[,5]
[1,]	-0.86245988	-0.108425697	0.667138107	0.067540649	-1.8849649328
[2,]	-0.11472830	2.260562250	-0.219213555	-0.760975429	-0.0995827598
[3,]	-0.47745343	-0.389223684	0.691726934	0.490739068	-0.7861963821
[4,]	-0.43042123	-0.682814223	-0.590772846	-0.211812388	-0.6663638245
[5,]	-0.65067636	1.292691968	0.088414872	-0.413081448	-1.1570326603
[6,]	-0.68971120	-1.086692644	0.590483134	1.678827381	-0.5813012259
[7,]	-0.89120627	0.864901590	0.041568812	0.634427212	-1.1482656541
[8,]	-0.53451935	1.423735577	0.095027578	-0.154686049	-0.7445047688
[9,]	0.38230162	1.609776028	-0.321004615	0.090463836	0.4392964875
[10,]	-1.14954969	0.312845377	0.844506782	-0.474326170	-1.0281835061
[11,]	-0.63268345	0.247272275	0.347501987	0.055484252	-2.1338238570
[12,]	-1.25929383	1.187435487	0.455585392	-0.148415989	0.3073992584
[13,]	-0.92421436	0.377810578	0.353915972	0.542236171	-1.1019986355
[14,]	-0.87884494	-0.203755698	0.237197476	0.119041791	-0.1031723782
[15,]	-1.20238586	1.334655016	0.367193947	-0.349717971	-0.1690300114
[16,]	0.06019762	1.291097155	-0.101542204	0.251352232	-0.0067762965
[17,]	-1.06468583	0.679129567	0.371157224	0.628907298	0.2396290165
[18,]	0.45465104	0.275945937	-0.014551680	0.403173629	-1.5671231145
[19,]	-0.75390389	1.257125221	-0.033635842	0.560867148	0.0818798206
[20,]	-1.33023471	0.370671317	0.774956306	0.244529299	0.8940144730
[21,]	-1.75580776	-0.166621156	-2.326517857	0.071841338	-0.8221660438
[22,]	-1.42290008	0.760899534	0.360226866	-1.613920745	-3.0070574103
[23,]	-0.76982244	-0.103921292	0.738678034	0.504248454	0.5776504844
[24,]	-1.24082669	0.737286029	0.155563262	0.004043971	-2.6687970484
[25,]	-1.18143356	0.432074236	-0.387444571	-0.106381262	-0.9244554283
[26,]	0.07141825	1.069922601	-0.044780542	0.269333979	-0.3750623224
[27,]	-0.44475192	1.229530720	0.038360275	0.047110536	-0.2021195433
[28,]	-0.49283266	1.533970242	0.224512586	-0.618040566	0.5416395132
[29,]	-0.40049034	0.300818157	0.441339537	0.036982283	-0.9483189517
[30,]	-0.66512083	0.256794035	0.479231497	0.384654036	-0.6149721834
[31,]	-1.01989228	-0.346322694	0.630975603	0.747209578	-0.8438453914
[32,]	-0.48833084	0.649398619	-0.071468440	1.130126611	-0.5034993470
[33,]	-0.73276114	-0.419858344	0.655079764	1.251771070	0.5824902175
[34,]	-0.46224178	0.328210024	0.040144885	1.066196482	-1.0574714145
[35,]	-1.23355249	1.073975482	-0.042423370	1.254695922	-0.0930558817
[36,]	-0.47044378	0.716197599	0.332817001	0.278471703	0.8957422187
[37,]	-0.79238670	1.047137849	0.369548834	0.063997867	0.7463656227
[38,]	-0.79373592	-0.790730113	1.288866597	-0.402513964	-0.9133590102
[39,]	-0.88917132	0.759530533	0.122340638	0.950614576	0.2118674225
[40,]	-1.14257201	0.465617680	0.303823546	-0.184277347	-0.2857929654
[41,]	-0.52767241	0.862738470	0.386323788	-0.363324660	-0.1933866744

[42,]	0.05415218	1.071588024	0.169912962	-0.574686834	-0.8611421679
[43,]	-0.37958467	0.509980105	0.400147197	0.193315309	0.3957438054
[44,]	-0.41930236	1.076051175	0.110896815	-0.059473245	-0.5170145833
[45,]	-0.70856242	-0.691584730	0.624399299	0.404687264	-0.5944803707
[46,]	0.02825303	1.684165749	-0.313912540	0.225014684	0.0005379349
[47,]	0.54990403	0.354215227	0.131075651	0.183222755	-0.9347547322
[48,]	-0.89973298	0.199267963	0.460772479	0.927662516	-0.2617017779
[49,]	-1.23887413	0.269556489	0.790784933	-0.501316934	-1.5181740351
[50,]	-0.41755406	1.275388074	-0.120136259	0.558024877	-0.4946919893
[51,]	-0.49078961	0.470673602	-0.881999471	0.071405984	0.3722436015
[52,]	-1.81250328	0.779185487	0.422459240	0.281709334	-1.2941249290
[53,]	-0.26940200	1.307934281	-0.407762655	1.082638038	0.0908111604
[54,]	0.25525851	1.496879951	-0.144334692	0.385278013	1.7766959652
[55,]	-1.78608678	-0.195060020	0.349727153	1.856124031	0.5877727608
[56,]	-0.95991877	-0.413466225	0.449536297	1.740873260	0.4888021868
[57,]	-0.64018826	-0.248909185	0.300287689	1.532680364	-0.3976635566
[58,]	-0.55985885	0.375767035	0.214044598	0.619869474	-0.7684818622
[59,]	-0.75558579	0.062884167	0.1111032311	1.860453756	-0.3190717313
[60,]	-0.43479598	0.360868644	0.460523729	-0.101114470	-0.9117655458
[61,]	-0.04805153	0.425914149	0.658570480	-0.210953141	0.6861814194
[62,]	-0.93933284	-0.312548551	0.514566617	1.045885568	-0.8233390859
[63,]	0.11849679	0.729472453	0.080307355	0.282086103	-0.1913771618
[64,]	-0.74115421	1.490905739	-0.114222919	0.242418680	-0.8575337686
[65,]	-0.48796413	0.016719266	0.426260926	0.508437276	-1.5345247477
[66,]	0.52042498	1.468176985	-0.042639025	-0.371651146	0.0336370569
[67,]	-0.50030060	1.166091309	-0.120464719	0.592527042	-0.1928613720
[68,]	-0.18651860	-0.061157247	0.618629163	0.486769219	0.9026995662
[69,]	-0.79870685	1.142217711	0.022530385	0.367791526	-0.3587633041
[70,]	-0.14141839	0.850369420	0.439618181	-0.635716937	-0.0570414075
[71,]	-0.89777222	0.940790504	-0.318493292	1.401456249	-0.8530393731
[72,]	-0.99143745	0.247911731	0.750497878	-0.056440158	0.1550553409
[73,]	-0.52152461	0.642100700	0.384544934	0.343662040	0.5424413360
[74,]	-1.29323735	-0.088687400	-0.790131722	0.307927555	-0.7435119317
[75,]	-0.80571320	1.209983324	0.011787037	0.629779121	0.3573256615
[76,]	-0.83062634	0.217096779	0.317233853	0.518113070	-1.3730886505
[77,]	-1.04060849	-0.050868148	0.626857888	0.441893643	-0.5148239719
[78,]	-0.07453736	0.507985458	0.379282832	-0.123446476	0.0606665804
[79,]	-0.84776474	0.068007027	0.232085149	1.004631503	-1.3493060239
[80,]	-0.24496449	1.051723339	0.053602972	0.057874363	-0.1851599830
[81,]	-0.41964656	0.636158046	-0.118688351	1.069110802	-0.9808861415
[82,]	-0.69887077	0.377558974	0.482825561	0.368861709	-0.2110902763
[83,]	-1.04800429	0.974979686	0.361535447	0.239490066	0.3473685133
[84,]	-0.55630725	0.928697376	0.791038522	-1.113649639	0.2988523651
[85,]	-0.11847943	0.797772682	0.381375382	0.158816700	1.0832511784
[86,]	0.20124591	0.593152173	0.319565418	-0.082651681	-0.0199503980

[87,]	-0.08163176	0.032992351	0.542418533	0.176694035	0.0757793753
[88,]	-0.71712974	-0.286149840	0.233547246	1.115183744	-0.0662633448
[89,]	-1.41732257	-0.223888075	0.634419866	1.518833457	0.7790936431
[90,]	-1.24680485	-0.494934332	0.230238719	2.746855049	0.5590473426
[91,]	-0.39648029	0.838925708	0.416014665	-0.337920312	-0.0887100156
[92,]	-1.14309420	0.182723759	-0.533996590	0.734671031	-0.3071238836
[93,]	-1.12531840	0.220944196	-0.180691265	-0.271934800	-0.7685106444
[94,]	-1.20262864	0.856619660	0.266177775	0.668036083	0.3392064362
[95,]	-0.97042733	0.820498682	0.184604164	1.237328276	0.8493284143
[96,]	-1.01481665	-0.705718545	0.982449097	-0.386591922	1.6348957228
[97,]	-0.66939876	0.558840653	-0.103533606	1.600651594	0.0552949059
[98,]	-1.22545898	-0.561861342	0.472155226	0.748926507	0.4057362386
[99,]	-1.12845779	-1.152513877	-0.625123239	0.931938780	0.2062811537
[100,]	-0.63766423	-0.045831249	0.963128782	-0.525098374	-0.6713918609
[101,]	-0.72355286	0.599996362	0.684662789	-1.009894566	-1.1569696231
[102,]	-0.29661435	1.522262989	0.613384550	-1.704293615	0.4631852138
[103,]	-1.15084421	0.401142468	0.463371295	0.034286795	-1.9300158790
[104,]	-1.17428768	0.807480948	0.661088180	-0.654075679	-0.2659996098
[105,]	-0.63959450	1.170134425	-0.153638892	0.875335466	-0.3014957810
[106,]	-0.60155770	1.216048312	0.206835952	-0.050866476	0.6035214099
[107,]	-0.62788043	0.145625682	-0.148577971	0.614256527	0.2926813084
[108,]	-0.16482744	0.169566403	-0.196101008	1.789068232	-0.4409810857
[109,]	-0.76272710	-0.030932859	0.716649651	0.195885571	-0.5281081772
[110,]	-1.13322272	-0.131045428	0.106398697	-0.104096571	-2.1545859854
[111,]	-1.52405882	0.768601362	0.782935920	-0.842545720	-1.6497555262
[112,]	0.30677952	0.831930537	-0.034086907	0.245943321	-0.6706846770
[113,]	-0.84448276	0.436445185	-0.908705910	0.219685623	-1.1701450802
[114,]	-0.71457686	0.419109741	0.141608891	0.862285350	-1.0587587310
[115,]	-1.22297604	0.462555119	0.530709590	0.303771863	-0.1642704384
[116,]	-1.10531063	0.456705295	0.979341845	-0.991349135	-0.2794859555
[117,]	-0.55629486	0.725351048	0.157467687	0.599626622	0.0205236512
[118,]	-1.51060723	-0.159793881	1.167223756	-0.441298832	-0.4943315448
[119,]	-0.21774902	1.287861967	-0.030991481	0.537609485	1.1007811058
[120,]	0.05580373	1.006610371	-0.179839340	0.386146712	-1.1391430920
[121,]	-0.48788736	1.083539202	-0.279146003	1.105702487	-0.9061533054
[122,]	-0.87041232	1.258712359	0.276298475	-0.248944980	-0.2994550822
[123,]	-0.44468969	1.671675026	-0.034009694	-0.547657322	-0.4042739801
[124,]	-0.46967771	2.236349065	-0.567223837	0.388077413	-0.2788955051
[125,]	-0.58993590	-0.700497040	0.722802466	0.680842614	-1.2036395484
[126,]	-0.43012061	0.831881561	0.372766561	0.123251529	0.6118969702
[127,]	-0.95068725	0.952619941	0.138680639	0.366058186	-0.8207844274
[128,]	-0.56923703	0.445798445	0.371337336	0.512539321	0.1789718240
[129,]	-0.74706421	1.244201937	0.008880998	0.449958726	-0.5120439540
[130,]	-0.35468353	0.608123923	0.171755385	0.560443637	0.1287832037
[131,]	0.40372120	2.605556006	-0.817655649	0.215399042	0.5031679222

[132,]	-0.56486642	0.359603716	-0.004838404	1.268625245	-0.7586410227
[133,]	-0.98653482	0.949838995	0.460774965	-0.255907944	-0.2095050189
[134,]	-0.30994976	1.216383019	0.474318949	-1.412515649	-1.9050209349
[135,]	-0.23638776	1.786648220	0.128470418	-0.577848775	0.8107405238
[136,]	-0.52073907	0.688112454	0.405918664	-0.288102939	-0.5051956572
[137,]	-1.19452076	0.843562180	0.323329744	0.384876424	-0.5307458475
[138,]	-0.89601568	1.074910596	0.069974031	0.829017567	0.1340067094
[139,]	-0.97440048	0.435143711	0.707077588	-0.432128598	-0.8408352916
[140,]	-0.62227346	1.298275494	-0.124183884	0.528571886	-0.4328333119
[141,]	0.28437063	0.268427932	0.042945091	0.982655453	-0.5404892633
[142,]	-0.42105516	1.041478979	-0.408828060	0.753693240	0.2583696888
[143,]	-0.57842032	1.752595913	0.136109007	-0.791300243	-0.1554207273
[144,]	1.40802245	1.873498961	-5.591400619	-1.548021248	0.8177783679
[145,]	-0.07770249	0.340678996	0.374454230	0.435960890	0.6496750801
[146,]	1.51485152	-0.466074813	0.251508223	0.709538051	0.0803701507
[147,]	2.20718916	1.774750357	-0.518773211	-0.553162661	0.6657978767
[148,]	1.85443760	1.068871555	-0.795008188	-0.475862403	0.3550028397
[149,]	1.48488204	0.570472391	-0.066958811	-0.007889456	-0.4128397584
[150,]	1.70513683	0.536863925	0.027330464	0.216907006	1.5675723504
[151,]	1.63994328	1.344577435	-0.700956816	0.407063960	-0.2081518804
[152,]	1.29428757	0.084402453	0.142567696	-0.414589088	-1.0131765525
[153,]	1.24691891	1.401632328	0.120549536	-1.565303427	-0.2771772944
[154,]	1.46008535	-0.024658062	0.202029476	0.068670900	-0.0658899111
[155,]	0.97304245	2.435488732	0.322485255	-2.811457677	1.2893075005
[156,]	1.85634841	0.888538289	0.074123349	-0.832539307	0.1949047813
[157,]	1.94800188	-1.011172690	0.158682088	1.194897340	-0.8574206587
[158,]	0.80869089	-1.703780246	0.695220537	1.266429056	-0.5714617144
[159,]	1.56671228	0.358495294	0.070196934	-0.211700323	-0.1951045809
[160,]	1.66501530	-0.024719485	-0.180205512	1.357234737	0.8663542214
[161,]	1.99655454	0.296894736	-0.541891985	0.675633152	-0.0539169505
[162,]	1.70499289	0.266303386	-0.184046317	1.454066687	2.5746594227
[163,]	0.70458398	-1.047456637	0.641847812	0.720456203	-0.3733171377
[164,]	1.18039091	0.444404179	0.406324864	-0.461799915	0.5642962424
[165,]	1.28431024	1.047432958	-0.473762394	1.184075119	1.9070106479
[166,]	1.09046867	-0.603433624	-0.149997346	0.403855910	0.7137763263
[167,]	1.53846337	0.113993698	0.349453840	-0.159176138	0.7684194248
[168,]	1.30693254	0.452197590	0.281156511	-0.095924252	1.1390868596
[169,]	1.72428832	-0.380880878	0.347894876	0.036257298	0.0180275660
[170,]	1.53917540	0.241922361	-0.088330342	0.439244868	-0.1496678601
[171,]	1.91071126	1.314470380	-0.336136630	-0.384156306	0.6711851824
[172,]	1.76873981	-1.018204311	0.378661963	0.761900433	-0.4204638071
[173,]	1.97122286	1.117760026	-0.607068145	0.762991022	0.7926477272
[174,]	1.45732710	0.476845547	0.027513952	-0.210519342	-0.5805404311
[175,]	1.19270366	-0.862422013	0.825479754	-0.539763574	-1.4819706342
[176,]	1.04535073	0.177723838	0.360335600	-0.495886271	-1.1939390313

[177,]	0.74237120	-0.681774291	0.446758122	-0.285624412	-0.1671738455
[178,]	0.79333891	-0.270753889	0.735613866	-0.186934678	0.8435891962
[179,]	1.02213092	-1.606043937	0.755898679	0.506983470	-1.5548344439
[180,]	2.27879629	1.262003580	-0.194171254	-1.048808451	0.3823693046
[181,]	1.49886141	-0.340983082	0.632327814	-0.603694135	0.0082550102
[182,]	1.67561942	-0.901027478	-0.100145427	0.644094628	-0.8198202134
[183,]	1.11846966	0.686244945	1.713161877	0.789490200	0.8170474011
[184,]	-0.32338757	1.734847549	-0.185945071	0.658302467	1.3967958646
[185,]	0.67483731	-0.889699271	1.404644923	-1.159231924	0.7496410405
[186,]	1.76702562	1.862048669	-0.447074065	-0.487796594	0.5390385709
[187,]	0.80114530	-1.851612750	1.144156553	0.803969583	0.0666393113
[188,]	1.21652857	-0.951498937	-0.127319780	0.301995459	-0.5736874075
[189,]	1.55352835	2.267544982	-0.455691129	-1.065863950	0.1350114644
[190,]	0.52787841	-0.679432202	-1.047019375	-0.241632518	-0.3573701309
[191,]	0.96726053	0.939940701	-0.410768867	0.695360155	-0.1310438405
[192,]	0.89267073	-0.318698868	1.075610761	-1.160495321	0.6239048321
[193,]	1.36986013	0.718311835	0.022818981	-0.027802111	0.6138928536
[194,]	1.36211241	1.205156089	0.171331974	-0.582392472	1.9623269823
[195,]	1.80975291	-0.337150903	-0.722699561	0.586827879	-1.0998953456
[196,]	1.44322893	-0.175998992	0.418835908	0.021373144	0.6239187105
[197,]	0.80963706	0.065489633	0.295467961	0.068294272	-0.6868053078
[198,]	0.83589544	0.328703355	0.843851107	-1.560934893	0.0206423012
[199,]	1.42253381	-0.362334943	0.073745635	1.124150964	0.2739587633
[200,]	1.30237054	0.813335120	-0.374483891	1.091148445	0.9448008473
[201,]	1.03015620	-0.160651285	0.617810290	-0.209546236	0.3811192612
[202,]	1.11960671	0.898863791	-0.170297073	0.083626531	0.3905977489
[203,]	1.29102526	0.726420440	-0.219375863	0.297146128	-0.0888943589
[204,]	1.32366855	1.066631510	0.047673807	-0.783149207	0.3546787055
[205,]	1.65201753	1.215759801	-0.381750350	0.304367971	0.4715268767
[206,]	1.57562609	-0.240085581	0.394424564	0.477516485	1.7453671638
[207,]	1.26155692	0.198332269	-0.667666390	0.087682042	0.1600245750
[208,]	1.42042801	2.226073965	-1.115583941	-1.064827014	0.6636902451
[209,]	2.48005004	1.285784275	-0.711916765	0.113269688	-0.2443745361
[210,]	1.37397183	-0.602531456	0.875753305	-0.901712922	-0.5698062566
[211,]	1.31624426	-0.831160349	0.424779704	0.564675902	-0.9135940895
[212,]	1.42186337	0.220443833	0.453230286	-0.592377358	0.3034968369
[213,]	0.19113348	-0.470853602	-4.804487195	0.004249362	0.2085670571
[214,]	0.38210752	-0.132572049	-6.029402593	0.004786757	-0.8993174931
[215,]	0.66145339	2.328662884	-3.316381617	-0.005176098	1.2005861547
[216,]	0.28720400	1.466488061	-5.021010680	-0.656035956	0.0030675769
[217,]	0.14744653	0.661066147	-2.908389970	-0.164214070	0.1660399529
[218,]	-0.02492118	-1.507316825	-4.919278552	3.492248468	0.6282332909
[219,]	0.91434755	-0.387385568	0.274142496	-1.467176552	1.2224973185
[220,]	2.40375110	-0.676928778	0.411523339	-0.098415079	0.0224075693
[221,]	-0.44671593	-2.113033852	-0.673982161	-0.023901336	-1.0004840446

[222,]	1.26479720	-0.461355206	0.446787709	0.358578904	0.0388607030
[223,]	0.10751478	0.010323737	0.062101575	0.033962042	-0.0217687203
[224,]	1.29545660	0.074995223	1.550323606	1.593818178	0.0014513016
[225,]	1.40425871	-0.922245326	0.589295708	-0.083531066	-1.0653159458
[226,]	1.56027169	-1.267112486	0.715964782	0.050194390	-1.2385828453
[227,]	1.24519166	-1.463275698	1.020072622	-0.082084029	-0.8222310602
[228,]	1.21880984	-0.804552022	0.542985721	0.258103747	-0.7321594415
[229,]	1.16081573	-1.652067452	-0.918833820	1.449853515	-1.2161329024
[230,]	1.31295657	-1.363395778	0.402740955	0.910803749	-1.5280397154
[231,]	1.09227900	-1.147629337	0.731672516	0.149786626	-1.5090756047
[232,]	1.48213502	-0.336946906	0.060439834	0.161486416	-1.7652130365
[233,]	0.74196317	-0.835337665	0.421334350	0.675756498	-1.0824667284
[234,]	0.97205608	-0.659720624	0.594742561	0.381316346	-0.1628217028
[235,]	1.05552709	-0.601391470	0.318627563	0.880780483	-0.0209619033
[236,]	0.74503487	-1.058077797	1.176866723	0.118044309	1.4928065016
[237,]	1.08811936	-1.673740309	0.286182940	0.541432874	-0.5497559122
[238,]	1.05756035	-1.285054492	0.193096525	0.522848123	0.1682481028
[239,]	0.53142435	-1.646874061	0.375827485	1.569439260	-0.4112121708
[240,]	1.15257513	-0.104311932	0.652781495	-0.500250824	0.6916946239
[241,]	1.28295844	-0.544817960	0.206625767	1.047798907	-0.2259713662
[242,]	1.49566998	-0.420126649	0.260998854	0.292074958	-0.5805973721
[243,]	1.80095086	-1.660645091	0.590005516	0.848342061	-1.1417384716
[244,]	1.63154661	-1.325009664	0.733926570	0.427670370	0.0114919381
[245,]	1.15680674	-1.699470902	1.054382653	0.253337747	-0.6721352284
[246,]	1.41573363	0.418135514	0.202009100	-0.445788981	-0.2191937801
[247,]	0.33490958	-1.372729569	0.547651058	0.913491187	-0.9189822589
[248,]	1.83357257	-0.649866214	0.730018304	-0.747070359	-0.2939143151
[249,]	0.74815305	-0.534045306	0.829265404	-0.628340787	-0.9604576547
[250,]	1.21755500	-1.385318775	0.830798636	0.357677908	-0.1849990973
[251,]	1.31705864	-1.143378587	0.256671834	1.044044542	-1.9502192354
[252,]	0.87213522	1.320990141	1.756572519	0.009650486	1.6445038218
[253,]	0.91897124	-1.903927831	0.712435081	1.110447265	-0.9369377788
[254,]	1.68677307	-1.667190927	-0.871603156	-1.270313385	-1.2085746878
[255,]	1.19864723	-0.391543291	0.752357715	-0.487648812	-0.2343366273
[256,]	1.37811870	-1.567262251	1.081580231	-0.060251206	-0.2365847131
[257,]	0.55195279	-1.405695780	0.752691250	0.617740615	0.0609129675
[258,]	-0.83712630	-1.056134596	-2.228850389	3.463721357	0.1874313543
[259,]	0.78504617	-1.511124070	-0.169770423	1.259311316	-0.5348844474
[260,]	-0.59540927	-1.419476752	0.532017147	-2.919686857	-0.9521747545
[261,]	-0.68774437	-0.758848543	-0.230941996	-1.894708928	0.0427191635
[262,]	-0.50205467	-0.901263168	-0.703924765	-3.149801779	0.8652706360
[263,]	-1.05638548	-0.570471799	0.751843888	-0.938596287	1.2734012559
[264,]	-0.13813084	-0.767969846	-0.093398525	-2.886259454	0.8260172639
[265,]	-0.60781768	-1.338566197	-0.714138418	-1.839573080	1.5655942683
[266,]	-0.04214638	-1.158896999	-0.811697669	-3.853932505	-0.0062984122

[267,] -0.06072951 -1.319730998 -0.802119132 -3.309864576 -0.4728424061
[268,] -0.18864905 -1.645935514 -1.548135880 -3.198855175 -2.3154558311
[269,] -0.50835118 -1.516987881 -1.935245181 -3.066669203 -0.3894008511
[270,] -0.42518428 -0.890030573 -0.116504447 -3.495524831 -0.3328138401
[271,] -0.35487456 -0.003980095 1.709066276 -2.524022140 0.1720086108
[272,] -0.07954155 -1.007455335 -1.253694983 -1.326202891 -1.3448457015
[273,] -0.51791037 0.141632010 1.019084037 -2.789750330 1.1650040920
[274,] -0.84743352 -0.828646568 0.180656838 -1.852533835 -1.0062031581
[275,] 0.20126695 0.738038549 1.809144773 -2.209276934 1.2553032331
[276,] -0.70434939 -1.156952675 -0.523913256 -2.483345252 -1.4234875538
[277,] -0.26016148 -0.828637420 -0.742679761 -2.310766640 -1.9864122729
[278,] -0.53183582 -1.045236371 0.528909033 -1.902285910 0.1262617703
[279,] -0.59028739 -0.973167660 0.148609897 -2.165226304 -0.7232849571
[280,] -1.31620557 -1.337265440 -2.806559793 0.737905299 -0.2879287202
[281,] -0.32325870 -0.157583205 -0.082516600 0.200103897 -0.3596022212
[282,] -0.37290306 -0.576623388 -0.853496887 0.401548570 -0.7943197946
[283,] -0.48677419 -0.408066590 -1.635991769 -1.269138575 -0.9741525590
[284,] -0.40446801 -0.323496093 -0.504085542 -0.510162963 -0.9113019169
[285,] -0.38815734 -1.628787302 -1.253233226 0.743852601 -0.6642683719
[286,] -0.20588030 -1.108136167 -0.089129629 -0.615219322 -0.0316017323
[287,] -1.07144366 -0.899538965 0.328296217 0.070714240 2.6208706159
[288,] -0.54273539 -1.314446613 -0.602129104 -1.490934233 0.7509112433
[289,] -0.27960096 -0.769431888 0.710947891 0.281937857 0.3884326290
[290,] -1.13079550 -1.682293968 -2.365655173 1.075547986 2.5840465109
[291,] -0.75154086 -1.055778404 -0.375547229 -0.366661020 0.8565795503
[292,] -0.75875363 -1.107915288 -1.240426649 -1.536821388 1.0318013446
[293,] -0.80631426 -0.943302435 0.673751517 -0.305025487 0.2388751237
[294,] -0.58787655 -0.511925979 0.779379432 -0.319019974 3.9086263211
[295,] -0.62394866 -0.660563440 -1.089485394 0.328752787 0.4856883333
[296,] -0.47750170 -1.283628055 -0.662391242 0.182117752 1.1506941912
[297,] -1.01347991 -0.872734939 0.911253179 0.836998379 2.0890928488
[298,] -1.30951070 -1.229077858 -0.930696508 0.705387191 2.2633117375
[299,] -1.02994605 -1.052037888 -1.279848282 -0.959808537 0.5879372533
[300,] 0.08584334 -0.884240072 -0.066342232 0.185136570 2.4341560548
[301,] -0.64699922 0.866845177 0.365032713 -0.294818123 -0.6886905540
[302,] -0.30231343 -1.082019843 0.250507291 0.041216122 0.6498333173
[303,] -0.01464539 -1.304113180 -4.001068813 -0.628745060 -0.7630586187
[304,] -0.58643513 -1.234861328 0.380527041 -0.728675948 1.6641266231
[305,] -0.82606307 -0.780376557 -0.355182248 -0.427092107 2.3658220434
[306,] -1.29873258 -0.963028675 -0.969314685 -0.646799799 1.7805625376
[307,] -0.61258400 -0.603330370 0.755823622 -1.369636895 0.6942402255
[308,] -0.68758880 -1.287733372 -0.969853702 -0.440946661 2.0472195270
[309,] -0.73050249 -0.929009308 0.610666193 -0.207297054 1.7945480107
[310,] -0.81126715 -0.754123976 0.285010964 -0.068638367 2.4661660819
[311,] -0.08114877 -1.516544021 -0.911575492 0.310294126 -0.9791541656

[312,]	-0.81698942	-1.520857636	-0.746890181	0.097397042	2.0666907641
[313,]	-0.77339357	-0.886932229	-0.411393770	0.293125591	0.8990548105
[314,]	-1.28815968	-1.389784675	-0.897351775	0.820851348	1.0234288027
[315,]	1.27587344	-0.739862934	0.619074711	0.728966037	2.0430378906
[316,]	-0.56228724	-1.294963403	-1.808499051	-0.860398726	1.2210102977
[317,]	-1.17092439	-1.111757090	-1.177670194	-0.131162127	0.5154213977
[318,]	-1.29623574	-0.724893441	0.641956174	-0.759088972	1.7002365448
[319,]	-0.61864624	-1.038774936	-0.734208653	-0.033519581	1.1382750492
[320,]	-0.41656573	-0.938665257	1.167838028	0.397223679	0.5581372239
[321,]	-0.84708093	-1.054619678	0.167701089	-0.427767436	0.5885755786
[322,]	-0.93337025	-0.664074874	1.015982835	-0.830510903	1.5798730408
[323,]	-0.27382358	-0.432488148	1.137608783	-0.407844878	2.0329621015
[324,]	-0.96119169	-1.393191223	0.881868670	-0.009260627	1.2158053148
[325,]	-0.91833655	-0.666656563	1.103722679	0.140083336	2.4247361525
[326,]	-0.08568756	1.081637458	0.074740040	-0.148401920	-0.4485847576
[327,]	-0.96517280	-0.519805386	1.176939364	-0.691192897	2.1878631990
[328,]	-0.90440773	-0.581611374	-0.506628109	0.174970667	0.0150387597
[329,]	-0.77678674	-1.388435072	-1.627009035	-0.010747849	0.4411197446
[330,]	-0.29718966	-0.976762743	0.270447808	-1.300885285	0.0007390450
[331,]	0.09507281	0.522082860	0.634140958	-0.453900336	0.8698609086
[332,]	-0.02121808	-1.745942359	-2.794343985	-0.052190010	-0.6645464281
[333,]	-1.01399667	-1.283890933	0.291519882	0.014673529	-0.1573895542
[334,]	-0.77413139	-0.693570973	0.236380075	0.134222614	0.5210313106
[335,]	-0.70949872	-0.632257543	-0.171380153	0.179846226	0.6461135258
[336,]	-0.44955721	-1.279824708	0.509587810	1.063673786	2.0264374055

[,6] [,7]

[1,]	0.05479001	0.15463437
[2,]	0.05389275	0.16474418
[3,]	0.05649885	0.16504983
[4,]	0.05073694	0.14723187
[5,]	0.05310368	0.15476736
[6,]	0.05644068	0.15664429
[7,]	0.05318845	0.14634310
[8,]	0.05388449	0.15793255
[9,]	0.05705264	0.16799101
[10,]	0.05195563	0.16349497
[11,]	0.05550967	0.14990830
[12,]	0.04950249	0.16388175
[13,]	0.05357749	0.15205511
[14,]	0.05117793	0.15950852
[15,]	0.04979891	0.16051549
[16,]	0.05653889	0.16427520
[17,]	0.05158003	0.16019301
[18,]	0.06068890	0.15777102
[19,]	0.05240133	0.15584487

[20,]	0.04976920	0.17080779
[21,]	0.03786753	0.10031127
[22,]	0.04911386	0.14334325
[23,]	0.05353607	0.17256713
[24,]	0.05204708	0.13653773
[25,]	0.04811912	0.14068038
[26,]	0.05713693	0.16257931
[27,]	0.05385140	0.16080531
[28,]	0.05230094	0.17212810
[29,]	0.05583157	0.16269771
[30,]	0.05462337	0.16125263
[31,]	0.05363913	0.15652436
[32,]	0.05522229	0.15095595
[33,]	0.05465376	0.16791777
[34,]	0.05610680	0.14939509
[35,]	0.05090450	0.14592659
[36,]	0.05358191	0.17232591
[37,]	0.05176998	0.16953385
[38,]	0.05497702	0.17523287
[39,]	0.05242476	0.15605023
[40,]	0.04988102	0.15815465
[41,]	0.05359571	0.16786868
[42,]	0.05679384	0.16661985
[43,]	0.05465980	0.17121613
[44,]	0.05433605	0.16053184
[45,]	0.05434622	0.16306905
[46,]	0.05577905	0.16052316
[47,]	0.06066501	0.16695995
[48,]	0.05372541	0.15836579
[49,]	0.05173460	0.15817608
[50,]	0.05476601	0.15382953
[51,]	0.04933829	0.14800954
[52,]	0.04852809	0.14363833
[53,]	0.05494880	0.15215967
[54,]	0.05584013	0.17791499
[55,]	0.04859044	0.14847792
[56,]	0.05360670	0.15889784
[57,]	0.05572043	0.15438914
[58,]	0.05500427	0.15557978
[59,]	0.05506821	0.14895905
[60,]	0.05543305	0.16359593
[61,]	0.05639180	0.18327894
[62,]	0.05425614	0.15411125
[63,]	0.05746722	0.16642662
[64,]	0.05283395	0.14938302

[65,]	0.05664587	0.15495483
[66,]	0.05837700	0.17355467
[67,]	0.05392671	0.15490741
[68,]	0.05618819	0.17920258
[69,]	0.05242216	0.15404133
[70,]	0.05540183	0.17523001
[71,]	0.05301030	0.13851861
[72,]	0.05192462	0.17009258
[73,]	0.05394615	0.16980236
[74,]	0.04631782	0.13162306
[75,]	0.05203266	0.15772362
[76,]	0.05418343	0.15053363
[77,]	0.05272738	0.16013240
[78,]	0.05619901	0.17322199
[79,]	0.05456812	0.14669209
[80,]	0.05498647	0.16324218
[81,]	0.05589906	0.14771666
[82,]	0.05400716	0.16397370
[83,]	0.05097291	0.16291090
[84,]	0.05291834	0.18173267
[85,]	0.05544284	0.17891340
[86,]	0.05784104	0.17440937
[87,]	0.05698743	0.17453768
[88,]	0.05386195	0.15673547
[89,]	0.05090297	0.16038957
[90,]	0.05286759	0.14771014
[91,]	0.05438708	0.17042992
[92,]	0.04852553	0.13893776
[93,]	0.04856392	0.14673374
[94,]	0.05045632	0.15746016
[95,]	0.05198149	0.15952154
[96,]	0.04972958	0.18580258
[97,]	0.05420415	0.15022074
[98,]	0.05030453	0.16045553
[99,]	0.04730836	0.13984447
[100,]	0.05468742	0.17378607
[101,]	0.05325173	0.16698796
[102,]	0.05290061	0.18558900
[103,]	0.05265583	0.14795781
[104,]	0.05023958	0.16651970
[105,]	0.05363454	0.15071068
[106,]	0.05238580	0.16831714
[107,]	0.05197412	0.15610752
[108,]	0.05757122	0.14946141
[109,]	0.05425864	0.16576992

[110,]	0.05122809	0.14077547
[111,]	0.04982744	0.15578125
[112,]	0.05873243	0.16321057
[113,]	0.04919272	0.13190548
[114,]	0.05464332	0.14942515
[115,]	0.05094492	0.15982524
[116,]	0.05094921	0.17420368
[117,]	0.05407515	0.16052096
[118,]	0.05011154	0.16877471
[119,]	0.05437795	0.16913650
[120,]	0.05764068	0.15397648
[121,]	0.05517239	0.14468634
[122,]	0.05174224	0.16107153
[123,]	0.05299333	0.16102984
[124,]	0.05288887	0.14811980
[125,]	0.05659760	0.16037612
[126,]	0.05406856	0.17218282
[127,]	0.05235029	0.15104946
[128,]	0.05423829	0.16557972
[129,]	0.05306674	0.15290156
[130,]	0.05505444	0.16387330
[131,]	0.05617619	0.15973633
[132,]	0.05538635	0.14871052
[133,]	0.05140262	0.16362287
[134,]	0.05544746	0.16448312
[135,]	0.05339080	0.17504795
[136,]	0.05410548	0.16562925
[137,]	0.05118363	0.15360945
[138,]	0.05224806	0.15517474
[139,]	0.05244552	0.16417427
[140,]	0.05342727	0.15214118
[141,]	0.05974975	0.16160018
[142,]	0.05309860	0.15317603
[143,]	0.05210139	0.16552522
[144,]	0.04155766	0.09751909
[145,]	0.05641316	0.17465678
[146,]	0.06612036	0.18404722
[147,]	0.06581892	0.18894787
[148,]	0.06287628	0.17748574
[149,]	0.06467973	0.17832026
[150,]	0.06440846	0.19554048
[151,]	0.06436215	0.16868511
[152,]	0.06395220	0.17735980
[153,]	0.06137458	0.18761039
[154,]	0.06486725	0.18469958

[155,]	0.05693433	0.20567028
[156,]	0.06532916	0.19315967
[157,]	0.07003257	0.17788290
[158,]	0.06455635	0.17646138
[159,]	0.06489316	0.18406039
[160,]	0.06604031	0.18087712
[161,]	0.06674644	0.17482220
[162,]	0.06462576	0.19318436
[163,]	0.06289415	0.17861590
[164,]	0.06248059	0.19243973
[165,]	0.06185111	0.18029617
[166,]	0.06084332	0.17841211
[167,]	0.06453525	0.19524905
[168,]	0.06280560	0.19403767
[169,]	0.06657867	0.19074220
[170,]	0.06525708	0.17821632
[171,]	0.06474075	0.18803375
[172,]	0.06842855	0.18497706
[173,]	0.06601375	0.17935998
[174,]	0.06461355	0.17939008
[175,]	0.06549637	0.18510324
[176,]	0.06334650	0.17758849
[177,]	0.06056239	0.18195852
[178,]	0.06110733	0.19450268
[179,]	0.06583111	0.17635109
[180,]	0.06649672	0.19552094
[181,]	0.06508922	0.19623634
[182,]	0.06653048	0.17332325
[183,]	0.04278695	-5.98474851
[184,]	0.05334665	0.16699633
[185,]	0.06069893	0.20861818
[186,]	0.06377814	0.18425699
[187,]	0.06439562	0.19095123
[188,]	0.06277674	0.17126282
[189,]	0.06212081	0.18174586
[190,]	0.05441720	0.15197086
[191,]	0.06159711	0.16556221
[192,]	0.06131415	0.20450412
[193,]	0.06316692	0.18618470
[194,]	0.06132994	0.20117852
[195,]	0.06570482	0.16232794
[196,]	0.06454700	0.19344869
[197,]	0.06211074	0.17487007
[198,]	0.06050487	0.19759141
[199,]	0.06555309	0.17941947

[200,]	0.06311456	0.17565697
[201,]	0.06265767	0.19181085
[202,]	0.06158158	0.17803449
[203,]	0.06327649	0.17451158
[204,]	0.06209037	0.18792413
[205,]	0.06449090	0.17973067
[206,]	0.06474735	0.20035953
[207,]	0.06057642	0.16897279
[208,]	0.05841108	0.17257133
[209,]	0.06876668	0.17866484
[210,]	0.06516880	0.19629751
[211,]	0.06622510	0.17833635
[212,]	0.06400857	0.19452999
[213,]	0.03931222	0.08567894
[214,]	0.03767315	0.05846597
[215,]	0.04767038	0.12483976
[216,]	0.03925179	0.08518522
[217,]	0.04600626	0.11918250
[218,]	0.04296624	0.06759660
[219,]	0.05736854	0.19647158
[220,]	0.07040171	0.19975790
[221,]	0.05027565	0.14185153
[222,]	0.06472352	0.18611639
[223,]	-18.30237556	0.07680363
[224,]	0.04534661	-5.99554450
[225,]	0.06625077	0.18409263
[226,]	0.06786474	0.18600041
[227,]	0.06621737	0.19147241
[228,]	0.06529999	0.18211000
[229,]	0.06215910	0.14657247
[230,]	0.06717599	0.17168802
[231,]	0.06571278	0.17884467
[232,]	0.06647058	0.16968532
[233,]	0.06321093	0.17033717
[234,]	0.06366684	0.18391828
[235,]	0.06398931	0.17868243
[236,]	0.06171312	0.20467720
[237,]	0.06345343	0.17591346
[238,]	0.06230322	0.17934182
[239,]	0.06221058	0.16763408
[240,]	0.06264173	0.19736812
[241,]	0.06552362	0.17693456
[242,]	0.06606547	0.18122658
[243,]	0.06998336	0.18320781
[244,]	0.06756014	0.19429111

[245,]	0.06612134	0.19054288
[246,]	0.06408823	0.18568241
[247,]	0.06118227	0.16803608
[248,]	0.06732163	0.19995514
[249,]	0.06229644	0.18465113
[250,]	0.06551042	0.19041064
[251,]	0.06755232	0.16558195
[252,]	0.03944729	-5.97680974
[253,]	0.06529297	0.17599040
[254,]	0.06042522	0.16594130
[255,]	0.06419379	0.19278274
[256,]	0.06651988	0.19806404
[257,]	0.06148039	0.18240228
[258,]	0.04819806	0.10293647
[259,]	0.06147144	0.16145366
[260,]	0.04859588	0.17553132
[261,]	0.04650654	0.16375467
[262,]	0.04262807	0.16928956
[263,]	0.04816625	0.18136576
[264,]	0.04750339	0.18240104
[265,]	0.04331290	0.16670032
[266,]	0.04454894	0.16932717
[267,]	0.04592082	0.16331787
[268,]	0.04473284	0.13500342
[269,]	0.03958140	0.13808329
[270,]	0.04587979	0.17338358
[271,]	0.05432348	0.20537764
[272,]	0.04907315	0.13969706
[273,]	0.04941007	0.20001614
[274,]	0.04824184	0.16144480
[275,]	0.03170618	-5.97566597
[276,]	0.04578653	0.15054150
[277,]	0.04881262	0.14675038
[278,]	0.04979073	0.17925751
[279,]	0.04866925	0.16712525
[280,]	0.01274940	-6.09834852
[281,]	0.02783269	-6.03764754
[282,]	0.02550309	-6.05586738
[283,]	0.01935323	-6.06413526
[284,]	0.02513241	-6.04656924
[285,]	0.04990792	0.13132343
[286,]	0.05208817	0.16475595
[287,]	0.04671386	0.17864894
[288,]	0.04568447	0.16185576
[289,]	0.05577681	0.17684441

[290,]	0.03846902	0.12569411
[291,]	0.04732158	0.15910701
[292,]	0.04190006	0.15067929
[293,]	0.05152740	0.17214301
[294,]	0.04915099	0.20298526
[295,]	0.04753214	0.14218960
[296,]	0.04848719	0.15651302
[297,]	0.05111609	0.18202575
[298,]	0.04233371	0.14841314
[299,]	0.04176345	0.14116537
[300,]	0.05263176	0.18236498
[301,]	0.05351776	0.16231948
[302,]	0.05312462	0.17147256
[303,]	0.04037212	0.09321029
[304,]	0.04921787	0.18156310
[305,]	0.04524634	0.16990350
[306,]	0.04049127	0.15083432
[307,]	0.05066864	0.18407344
[308,]	0.04399238	0.15826723
[309,]	0.05014172	0.18260954
[310,]	0.04810969	0.18028947
[311,]	0.05254216	0.14041614
[312,]	0.04483318	0.15829463
[313,]	0.04832546	0.15549600
[314,]	0.04413402	0.13969891
[315,]	0.06358563	0.20184838
[316,]	0.04201062	0.14099099
[317,]	0.04285465	0.13698271
[318,]	0.04611297	0.17903689
[319,]	0.04715968	0.15474028
[320,]	0.05646903	0.18397308
[321,]	0.04883827	0.16592416
[322,]	0.04960032	0.18897621
[323,]	0.05430789	0.19956536
[324,]	0.05048818	0.17960679
[325,]	0.05079451	0.19218286
[326,]	0.05594618	0.16441439
[327,]	0.04960258	0.19521435
[328,]	0.04820022	0.14670492
[329,]	0.04378097	0.13219504
[330,]	0.05157212	0.17355838
[331,]	0.05654981	0.18689557
[332,]	0.04521065	0.11207193
[333,]	0.04982670	0.15875392
[334,]	0.05082233	0.16489225

[335,]	0.04976491	0.15917194
[336,]	0.05332057	0.17944464

Anexo D

	[,1]	[,2]	[,3]
[1,]	-0.628818991	0.404345636	2.0266582810
[2,]	0.052737547	1.937854064	-0.3420769035
[3,]	-0.294082374	-0.007706169	1.0460028167
[4,]	-0.552310918	-0.405522856	0.5177337302
[5,]	-0.429722962	1.418466160	0.9248461784
[6,]	-0.410373093	-0.319269098	0.9551578505
[7,]	-0.542366906	1.351275846	0.9929663821
[8,]	-0.282537590	1.509879452	0.5232844856
[9,]	0.545950726	1.388825296	-0.8052861704
[10,]	-0.984421484	0.534840198	1.2612385763
[11,]	-0.377207234	0.745769465	2.0690895146
[12,]	-1.048159327	1.222715091	-0.2169283847
[13,]	-0.626638063	0.862946550	1.1362019547
[14,]	-0.815861057	0.046351916	0.2622720940
[15,]	-0.984877007	1.383047661	0.1588518917
[16,]	0.273553832	1.266875013	-0.2448084729
[17,]	-0.797179997	0.946396986	-0.1172930101
[18,]	0.660747412	0.582863980	1.3344904664
[19,]	-0.462292182	1.449074017	-0.2286684883
[20,]	-1.165303574	0.473286765	-0.5082781817
[21,]	-1.883004791	0.524267570	0.0781214821
[22,]	-1.300960405	1.075663621	2.8436267724
[23,]	-0.624680069	0.064534550	-0.2033149775
[24,]	-0.890626403	1.397639966	2.4649292211
[25,]	-1.070170070	0.806547395	0.7189354120
[26,]	0.288998956	1.130419923	0.1444040031
[27,]	-0.230028346	1.277332767	0.0312576309
[28,]	-0.383352275	1.244345953	-0.6304333591
[29,]	-0.220850356	0.529986104	0.9917986158
[30,]	-0.440709163	0.569056282	0.7313708286
[31,]	-0.769771937	0.213856645	1.1165587959
[32,]	-0.151981428	1.103487422	0.3680098173
[33,]	-0.510057618	-0.028558464	-0.1862998557
[34,]	-0.131448303	0.881405893	0.9594772688
[35,]	-0.818013232	1.585889641	0.0001712141
[36,]	-0.328587641	0.663416236	-0.7868681079
[37,]	-0.618248781	0.991682867	-0.6631316447
[38,]	-0.738595198	-0.563128738	1.4513943744
[39,]	-0.584682969	1.091893954	-0.2032752766
[40,]	-1.013827794	0.651504104	0.3705839703
[41,]	-0.395531000	0.828404445	0.2045627376

[42,] 0.181099162 0.986197045 0.6584470568
[43,] -0.242042271 0.521290535 -0.2830684201
[44,] -0.215491110 1.156510291 0.3648447324
[45,] -0.593201462 -0.291103915 0.9103207911
[46,] 0.268462483 1.634998047 -0.3833414581
[47,] 0.696508965 0.456964442 0.7866298114
[48,] -0.606550418 0.641582699 0.4341167504
[49,] -1.053073093 0.595473226 1.7035781546
[50,] -0.104794059 1.509879958 0.2379658692
[51,] -0.507652725 0.561334264 -0.7007825672
[52,] -1.455546113 1.354303683 1.3447647878
[53,] 0.063971858 1.564065098 -0.4111228463
[54,] 0.385769262 1.138950484 -1.9355456254
[55,] -1.423713834 0.549252667 -0.2430276436
[56,] -0.658169700 0.177732824 -0.1518066919
[57,] -0.318029297 0.379525873 0.5534648297
[58,] -0.298995951 0.763337684 0.7536393709
[59,] -0.355393316 0.768185413 0.3799216643
[60,] -0.270506675 0.546960266 0.9577020570
[61,] 0.003159683 0.208990216 -0.4746810101
[62,] -0.648834253 0.311636095 1.0476901157
[63,] 0.291199140 0.775434582 0.0682710138
[64,] -0.417747092 1.747037715 0.5625615511
[65,] -0.222552557 0.516995202 1.5760973572
[66,] 0.636527279 1.167352097 -0.3299050506
[67,] -0.214220983 1.381726125 -0.0146347954
[68,] -0.093502885 -0.060003934 -0.5962860720
[69,] -0.518538762 1.377035974 0.2131694220
[70,] -0.075535965 0.646062314 0.0672610791
[71,] -0.462440016 1.593342222 0.5915893665
[72,] -0.858808838 0.352302997 0.1471730679
[73,] -0.346823972 0.682088815 -0.4298547658
[74,] -1.230314833 0.457425821 0.5021821331
[75,] -0.520896838 1.382285669 -0.4525335938
[76,] -0.547254531 0.743740253 1.3874822923
[77,] -0.826332033 0.347722473 0.7689565127
[78,] 0.017933061 0.440230120 -0.0110999743
[79,] -0.509502345 0.740478614 1.3636440984
[80,] -0.058733503 1.077531766 0.0319397922
[81,] -0.070117070 1.150314093 0.7836163247
[82,] -0.487228568 0.608979636 0.3478880248
[83,] -0.817577811 1.091168113 -0.2683699899
[84,] -0.537012080 0.583545853 -0.1164157217
[85,] -0.006428210 0.603993251 -0.9826816174
[86,] 0.302198732 0.494858078 0.0068584017

[87,]	0.015390951	0.076037897	0.1073516339
[88,]	-0.499932811	0.196225922	0.2351888518
[89,]	-1.113879144	0.313552195	-0.3454953986
[90,]	-0.798347367	0.422782495	-0.2495592754
[91,]	-0.271728080	0.768496751	0.1126364890
[92,]	-0.977744243	0.693658216	0.1445585124
[93,]	-1.062533264	0.520119989	0.6752947986
[94,]	-0.917439011	1.132579806	-0.2606912113
[95,]	-0.642347547	1.120543542	-0.7641156282
[96,]	-1.145173379	-0.872417358	-0.9809057424
[97,]	-0.298769023	1.081496534	-0.1218560032
[98,]	-1.099564364	-0.154111182	-0.0327217710
[99,]	-1.153824734	-0.554017946	-0.1554353204
[100,]	-0.559460281	0.029627416	0.9894488220
[101,]	-0.635519913	0.608607254	1.2404410871
[102,]	-0.339095184	0.901148365	-0.4446443397
[103,]	-0.862585521	0.932962531	1.9420414241
[104,]	-1.044599513	0.817900557	0.4257924930
[105,]	-0.294835094	1.506930115	0.0859456352
[106,]	-0.438325380	1.115027149	-0.6317969671
[107,]	-0.507411263	0.401067351	-0.3043472290
[108,]	0.193513041	0.777411801	0.3186978118
[109,]	-0.587949557	0.246004834	0.7853861359
[110,]	-0.963017798	0.473348950	2.0986693286
[111,]	-1.312567841	1.035904208	1.7659595713
[112,]	0.501634642	0.916109893	0.4350902180
[113,]	-0.724559296	0.910269185	0.7343920140
[114,]	-0.387834978	0.951218920	1.0013510707
[115,]	-0.991537513	0.755494228	0.3507763031
[116,]	-1.050046406	0.380181951	0.5949204290
[117,]	-0.312212048	0.938374580	-0.0405847244
[118,]	-1.394208596	0.066604084	0.9877354936
[119,]	-0.014294235	1.190015542	-1.2069332598
[120,]	0.324337648	1.250648849	0.8068518700
[121,]	-0.091215723	1.575691511	0.5970850622
[122,]	-0.657390086	1.307564023	0.2315653018
[123,]	-0.267783880	1.563091002	0.1188178153
[124,]	-0.116701973	2.337603366	-0.2591270756
[125,]	-0.379496898	-0.147329065	1.4960449224
[126,]	-0.277448942	0.767895544	-0.5352945282
[127,]	-0.647265096	1.307312562	0.7172327191
[128,]	-0.366226252	0.622421747	-0.0674804239
[129,]	-0.431463652	1.509518870	0.3296540590
[130,]	-0.146095766	0.763987904	-0.1333813133
[131,]	0.666503567	2.341839149	-1.1896512950

[132,] -0.216268456 0.932054255 0.6757045553
[133,] -0.799361359 1.019310360 0.2702831337
[134,] -0.193673691 1.131290528 1.7204059490
[135,] -0.123163633 1.394780313 -0.9686179849
[136,] -0.375724643 0.742379754 0.5228523637
[137,] -0.894925957 1.195489793 0.5535388309
[138,] -0.570116891 1.364638623 -0.1985668051
[139,] -0.818624981 0.599836295 1.0093259571
[140,] -0.309237019 1.550442190 0.1927490055
[141,] 0.531666158 0.574070357 0.4362248820
[142,] -0.187397246 1.234746306 -0.5151828363
[143,] -0.427988571 1.542527612 -0.0520531835
[144,] 0.712343654 1.280145572 -3.1494789915
[145,] 0.048875378 0.331575664 -0.5209421087
[146,] 1.552382508 -0.517197660 -0.0482360444
[147,] 2.182124380 1.001730064 -1.2591659282
[148,] 1.752567612 0.520271879 -0.9374524608
[149,] 1.538729499 0.348817913 0.1303105022
[150,] 1.659580183 -0.020954524 -1.6572181148
[151,] 1.785114596 1.135675177 -0.4061817211
[152,] 1.281373903 -0.070374143 0.8380381803
[153,] 1.159317250 0.702994670 -0.0467492702
[154,] 1.452068075 -0.245332239 0.0004436795
[155,] 0.729803202 1.074863267 -1.5514582573
[156,] 1.769274381 0.235075102 -0.4601145161
[157,] 2.036875922 -0.793226355 0.8275123874
[158,] 0.891879004 -1.275532415 0.9521033403
[159,] 1.552924375 0.040332162 0.0033360402
[160,] 1.770833587 -0.086419537 -0.9921068311
[161,] 2.041191787 0.151276695 -0.3596360520
[162,] 1.747509466 -0.106963700 -2.6010626365
[163,] 0.765290704 -0.835371845 0.6570510612
[164,] 1.130431027 -0.031443632 -0.5560397228
[165,] 1.415179648 0.746590729 -2.1792492523
[166,] 0.985370456 -0.729090047 -0.7168837713
[167,] 1.464569925 -0.351270099 -0.7391583774
[168,] 1.264927379 -0.045880983 -1.1338369162
[169,] 1.662981892 -0.650661523 0.0073809296
[170,] 1.604577589 0.112516996 -0.0688691033
[171,] 1.881913121 0.671001456 -1.1050201769
[172,] 1.780056328 -0.971288715 0.5176008512
[173,] 2.077447291 0.777890242 -1.2771906195
[174,] 1.485529274 0.239516949 0.3315383932
[175,] 1.137192608 -0.904317424 1.6573894958
[176,] 1.074429986 0.057448389 1.0854601399

[177,] 0.641054681 -0.798303691 0.3330132620
[178,] 0.723277018 -0.606789701 -0.5538904568
[179,] 1.052702938 -1.255405454 1.8339926830
[180,] 2.149024362 0.422472184 -0.8182559237
[181,] 1.369253368 -0.756757517 0.1234327302
[182,] 1.663080060 -0.776784877 0.7022880376
[183,] 1.277044719 -0.681782572 0.2677813049
[184,] -0.071555170 1.604487661 -1.5899898258
[185,] 0.431887337 -1.427678033 -0.1373031641
[186,] 1.796375162 1.198088629 -1.0951828802
[187,] 0.786744673 -1.671558080 0.5463757429
[188,] 1.133470016 -0.868423532 0.5092713915
[189,] 1.570878300 1.526505764 -0.7777643090
[190,] 0.299721340 -0.614495417 -0.0036568826
[191,] 1.156127466 0.937286340 -0.2567130068
[192,] 0.693387509 -0.907053756 -0.2420786299
[193,] 1.382724801 0.311445872 -0.7895973610
[194,] 1.266658422 0.360677065 -2.0470142875
[195,] 1.813134493 -0.215383311 0.6421939181
[196,] 1.382201756 -0.528155916 -0.5297262911
[197,] 0.888433754 0.061815122 0.6396790354
[198,] 0.673328706 -0.292122759 0.1311279444
[199,] 1.517716224 -0.319985414 -0.2926266295
[200,] 1.461453302 0.670580492 -1.2317142290
[201,] 0.982460951 -0.467455937 -0.2086000681
[202,] 1.180094269 0.603239471 -0.6598414855
[203,] 1.387577323 0.558893220 -0.2249104779
[204,] 1.273687901 0.482450494 -0.5990719375
[205,] 1.747898844 0.848552224 -0.8971025589
[206,] 1.501256332 -0.688634771 -1.5604579508
[207,] 1.187729537 0.015130474 -0.5307653108
[208,] 1.331941279 1.462879898 -1.4771892816
[209,] 2.538634761 0.855602888 -0.4381208491
[210,] 1.226535447 -0.962139516 0.7846392024
[211,] 1.372588156 -0.684373442 0.9911439131
[212,] 1.333526918 -0.270769735 -0.2879094082
[213,] -0.384045537 -0.155741312 -1.8507227979
[214,] -0.205012328 0.391096635 -1.3371291829
[215,] 0.531896158 2.022301940 -2.6908657211
[216,] -0.153915487 1.461497486 -2.0443345864
[217,] -0.103176485 0.720488869 -1.3102180035
[218,] -0.164649569 -0.208471663 -2.0716273774
[219,] 0.527053243 -1.108190032 -1.0664043628
[220,] 2.262125755 -1.086316404 0.0146613016
[221,] -0.713511814 -1.586358220 1.0118885625

[222,] 1.273462899 -0.563479795 0.0750741810
[223,] -1.026977142 -1.327651269 0.5835418939
[224,] 1.545191041 -0.903536512 1.0403781202
[225,] 1.359794958 -0.937100272 1.1890269405
[226,] 1.512446479 -1.221554629 1.4326606487
[227,] 1.161612644 -1.468818022 1.2132600718
[228,] 1.228390770 -0.762191216 0.8682711915
[229,] 1.147515270 -1.027844229 0.9365700997
[230,] 1.398132341 -0.965629446 1.6283002635
[231,] 1.114201672 -0.952737105 1.7059215902
[232,] 1.549778286 -0.198155822 1.5496486213
[233,] 0.848059602 -0.521681192 1.1920049334
[234,] 0.997266953 -0.656659771 0.3652605296
[235,] 1.134393061 -0.495710480 0.1268376755
[236,] 0.624972870 -1.375751664 -0.8664003970
[237,] 0.995301143 -1.467944097 0.7545585819
[238,] 0.955778989 -1.235682604 0.0092031041
[239,] 0.640397171 -1.100494757 0.7090984116
[240,] 1.039815360 -0.572698250 -0.5009219005
[241,] 1.393260563 -0.399490539 0.2492900434
[242,] 1.513716172 -0.464824505 0.5503009385
[243,] 1.811356913 -1.423369556 1.3463656078
[244,] 1.555131689 -1.411160659 0.3026392524
[245,] 1.096191857 -1.607520285 1.1337151891
[246,] 1.389673329 0.057031692 0.0730750608
[247,] 0.425925830 -0.908104674 1.2028279137
[248,] 1.656852982 -1.089845804 0.4524977376
[249,] 0.701124934 -0.639265199 1.1675983911
[250,] 1.158586168 -1.378369927 0.5582036254
[251,] 1.468848178 -0.647579944 1.9302712135
[252,] 0.936131305 -0.413739119 -0.5556053017
[253,] 0.971171976 -1.454950824 1.3121599034
[254,] 1.183302224 -1.857215671 0.8830526715
[255,] 1.121934865 -0.680917011 0.4203004055
[256,] 1.245864567 -1.690031369 0.7048569755
[257,] 0.533353157 -1.242970711 0.3646182815
[258,] -0.583248467 0.249568013 -0.7210440269
[259,] 0.801316136 -1.048837736 0.5859026809
[260,] -1.146827096 -1.774791001 1.2765847043
[261,] -1.116042443 -1.016530647 0.0144522241
[262,] -1.280626410 -1.624695131 -0.9087275432
[263,] -1.262479695 -0.807691418 -0.7537142743
[264,] -0.799080991 -1.535046102 -0.7041862689
[265,] -1.262376276 -1.781739482 -1.4669044780
[266,] -0.945189349 -1.967474199 -0.1543932626

[267,] -0.856770084 -1.885245125 0.3057800964
[268,] -0.955554733 -1.753526614 1.7867028877
[269,] -1.396728519 -1.858576049 -0.1030975739
[270,] -1.121638198 -1.545045521 0.3830547537
[271,] -0.609945045 -0.706814686 0.4359664237
[272,] -0.473756708 -0.894690841 0.9147708582
[273,] -0.934229046 -0.745383095 -0.7265183846
[274,] -1.157303460 -0.879648556 1.1423049561
[275,] -0.145072653 -1.333531844 -0.0586711212
[276,] -1.217877457 -1.250188787 1.3072811836
[277,] -0.698569513 -0.876083323 1.6608867148
[278,] -0.932130385 -1.371322490 0.2370665032
[279,] -1.005782533 -1.188832758 0.8707983434
[280,] -1.749460380 -1.589322490 0.1805904061
[281,] -0.437390866 -1.008363850 0.9466101392
[282,] -0.556834091 -1.199707348 1.1403303260
[283,] -1.004498297 -1.381095941 0.9977001792
[284,] -0.667896979 -1.204950426 1.3273346093
[285,] -0.541179410 -0.978851907 0.4289209306
[286,] -0.454665788 -1.083988446 0.1572984268
[287,] -1.282067836 -1.050368292 -2.0755856375
[288,] -1.067725373 -1.543447327 -0.6885686045
[289,] -0.269503984 -0.653792743 0.0186966985
[290,] -1.546999602 -1.305743628 -2.8625565531
[291,] -1.022149711 -1.008390985 -0.7176127996
[292,] -1.342224255 -1.336342956 -1.1849436913
[293,] -0.897550968 -0.838186239 0.2057129297
[294,] -0.872623996 -1.148453177 -3.1937714328
[295,] -0.773073141 -0.379502114 -0.6946282793
[296,] -0.742515644 -1.156051066 -1.0708110448
[297,] -0.991600602 -0.779361812 -1.3856904349
[298,] -1.551893758 -0.993940541 -2.1194280652
[299,] -1.469487032 -1.002540932 -0.7748465279
[300,] -0.170564308 -1.163981971 -2.1386706835
[301,] -0.466379446 0.961526219 0.6593133147
[302,] -0.441382214 -1.012902393 -0.3361021821
[303,] -0.654999164 -0.918965941 -0.5422691374
[304,] -0.926973348 -1.488525724 -1.1780099002
[305,] -1.169367312 -1.029239566 -2.1258661309
[306,] -1.712311943 -1.020962860 -1.7443247022
[307,] -0.873206452 -0.930960030 -0.2573553062
[308,] -1.148331915 -1.422943541 -1.9867204849
[309,] -0.919026873 -1.085403521 -1.2458912748
[310,] -1.029377343 -0.973313523 -1.9934611685
[311,] -0.248008113 -1.014214218 0.7921673131

[312,] -1.188949153 -1.487030604 -1.8756460129
[313,] -0.912073211 -0.683363585 -0.7871018591
[314,] -1.443943164 -0.895875899 -0.9509144130
[315,] 1.191188849 -1.087493275 -1.6517061206
[316,] -1.131755005 -1.362296838 -1.5404317827
[317,] -1.453515332 -0.806926677 -0.6450484026
[318,] -1.524405863 -0.924533815 -1.1386224681
[319,] -0.890079164 -0.957223147 -1.1121897773
[320,] -0.368648937 -0.811120116 0.0624721419
[321,] -1.050000989 -0.993079368 -0.2737367501
[322,] -1.131072409 -0.958618626 -0.9353819884
[323,] -0.407751328 -0.848968933 -1.3907683946
[324,] -1.101741482 -1.326530314 -0.5310001344
[325,] -0.996637591 -0.864736789 -1.6691028765
[326,] 0.083466989 1.066190544 0.2611142161
[327,] -1.143183841 -0.903401338 -1.4521893056
[328,] -0.967131260 -0.250015933 -0.0491794154
[329,] -1.130721482 -1.057821761 -0.7248925456
[330,] -0.609614976 -1.156418125 0.2364722550
[331,] 0.096766934 0.174865314 -0.6792537646
[332,] -0.501619153 -1.262831393 -0.1339956820
[333,] -1.100665181 -0.929745054 0.5035424058
[334,] -0.821106700 -0.524235734 -0.2431174141
[335,] -0.793468982 -0.464563684 -0.5155418647
[336,] -0.499708746 -1.157569153 -1.4524414178

Bases de datos

Base de datos Iris

Iris, clásica base de datos introducida por el biólogo y estadístico inglés Ronald Fisher en 1936. Es una colección de 150 flores iris, conformada por 50 flores de tres especies distintas: Iris setosa, Iris virginica e Iris versicolor.

	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width	Species
1	5.1	3.5	1.4	0.2	setosa
2	4.9	3.0	1.4	0.2	setosa
3	4.7	3.2	1.3	0.2	setosa
4	4.6	3.1	1.5	0.2	setosa
5	5.0	3.6	1.4	0.2	setosa
6	5.4	3.9	1.7	0.4	setosa
7	4.6	3.4	1.4	0.3	setosa
8	5.0	3.4	1.5	0.2	setosa
9	4.4	2.9	1.4	0.2	setosa
10	4.9	3.1	1.5	0.1	setosa
11	5.4	3.7	1.5	0.2	setosa
12	4.8	3.4	1.6	0.2	setosa
13	4.8	3.0	1.4	0.1	setosa
14	4.3	3.0	1.1	0.1	setosa
15	5.8	4.0	1.2	0.2	setosa
16	5.7	4.4	1.5	0.4	setosa
17	5.4	3.9	1.3	0.4	setosa
18	5.1	3.5	1.4	0.3	setosa
19	5.7	3.8	1.7	0.3	setosa
20	5.1	3.8	1.5	0.3	setosa
21	5.4	3.4	1.7	0.2	setosa
22	5.1	3.7	1.5	0.4	setosa
23	4.6	3.6	1.0	0.2	setosa
24	5.1	3.3	1.7	0.5	setosa
25	4.8	3.4	1.9	0.2	setosa
26	5.0	3.0	1.6	0.2	setosa
27	5.0	3.4	1.6	0.4	setosa
28	5.2	3.5	1.5	0.2	setosa
29	5.2	3.4	1.4	0.2	setosa
30	4.7	3.2	1.6	0.2	setosa
31	4.8	3.1	1.6	0.2	setosa
32	5.4	3.4	1.5	0.4	setosa
33	5.2	4.1	1.5	0.1	setosa
34	5.5	4.2	1.4	0.2	setosa
35	4.9	3.1	1.5	0.2	setosa

36	5.0	3.2	1.2	0.2	setosa
37	5.5	3.5	1.3	0.2	setosa
38	4.9	3.6	1.4	0.1	setosa
39	4.4	3.0	1.3	0.2	setosa
40	5.1	3.4	1.5	0.2	setosa
41	5.0	3.5	1.3	0.3	setosa
42	4.5	2.3	1.3	0.3	setosa
43	4.4	3.2	1.3	0.2	setosa
44	5.0	3.5	1.6	0.6	setosa
45	5.1	3.8	1.9	0.4	setosa
46	4.8	3.0	1.4	0.3	setosa
47	5.1	3.8	1.6	0.2	setosa
48	4.6	3.2	1.4	0.2	setosa
49	5.3	3.7	1.5	0.2	setosa
50	5.0	3.3	1.4	0.2	setosa
51	7.0	3.2	4.7	1.4	versicolor
52	6.4	3.2	4.5	1.5	versicolor
53	6.9	3.1	4.9	1.5	versicolor
54	5.5	2.3	4.0	1.3	versicolor
55	6.5	2.8	4.6	1.5	versicolor
56	5.7	2.8	4.5	1.3	versicolor
57	6.3	3.3	4.7	1.6	versicolor
58	4.9	2.4	3.3	1.0	versicolor
59	6.6	2.9	4.6	1.3	versicolor
60	5.2	2.7	3.9	1.4	versicolor
61	5.0	2.0	3.5	1.0	versicolor
62	5.9	3.0	4.2	1.5	versicolor
63	6.0	2.2	4.0	1.0	versicolor
64	6.1	2.9	4.7	1.4	versicolor
65	5.6	2.9	3.6	1.3	versicolor
66	6.7	3.1	4.4	1.4	versicolor
67	5.6	3.0	4.5	1.5	versicolor
68	5.8	2.7	4.1	1.0	versicolor
69	6.2	2.2	4.5	1.5	versicolor
70	5.6	2.5	3.9	1.1	versicolor
71	5.9	3.2	4.8	1.8	versicolor
72	6.1	2.8	4.0	1.3	versicolor
73	6.3	2.5	4.9	1.5	versicolor
74	6.1	2.8	4.7	1.2	versicolor
75	6.4	2.9	4.3	1.3	versicolor
76	6.6	3.0	4.4	1.4	versicolor
77	6.8	2.8	4.8	1.4	versicolor
78	6.7	3.0	5.0	1.7	versicolor
79	6.0	2.9	4.5	1.5	versicolor
80	5.7	2.6	3.5	1.0	versicolor

81	5.5	2.4	3.8	1.1 versicolor
82	5.5	2.4	3.7	1.0 versicolor
83	5.8	2.7	3.9	1.2 versicolor
84	6.0	2.7	5.1	1.6 versicolor
85	5.4	3.0	4.5	1.5 versicolor
86	6.0	3.4	4.5	1.6 versicolor
87	6.7	3.1	4.7	1.5 versicolor
88	6.3	2.3	4.4	1.3 versicolor
89	5.6	3.0	4.1	1.3 versicolor
90	5.5	2.5	4.0	1.3 versicolor
91	5.5	2.6	4.4	1.2 versicolor
92	6.1	3.0	4.6	1.4 versicolor
93	5.8	2.6	4.0	1.2 versicolor
94	5.0	2.3	3.3	1.0 versicolor
95	5.6	2.7	4.2	1.3 versicolor
96	5.7	3.0	4.2	1.2 versicolor
97	5.7	2.9	4.2	1.3 versicolor
98	6.2	2.9	4.3	1.3 versicolor
99	5.1	2.5	3.0	1.1 versicolor
100	5.7	2.8	4.1	1.3 versicolor
101	6.3	3.3	6.0	2.5 virginica
102	5.8	2.7	5.1	1.9 virginica
103	7.1	3.0	5.9	2.1 virginica
104	6.3	2.9	5.6	1.8 virginica
105	6.5	3.0	5.8	2.2 virginica
106	7.6	3.0	6.6	2.1 virginica
107	4.9	2.5	4.5	1.7 virginica
108	7.3	2.9	6.3	1.8 virginica
109	6.7	2.5	5.8	1.8 virginica
110	7.2	3.6	6.1	2.5 virginica
111	6.5	3.2	5.1	2.0 virginica
112	6.4	2.7	5.3	1.9 virginica
113	6.8	3.0	5.5	2.1 virginica
114	5.7	2.5	5.0	2.0 virginica
115	5.8	2.8	5.1	2.4 virginica
116	6.4	3.2	5.3	2.3 virginica
117	6.5	3.0	5.5	1.8 virginica
118	7.7	3.8	6.7	2.2 virginica
119	7.7	2.6	6.9	2.3 virginica
120	6.0	2.2	5.0	1.5 virginica
121	6.9	3.2	5.7	2.3 virginica
122	5.6	2.8	4.9	2.0 virginica
123	7.7	2.8	6.7	2.0 virginica
124	6.3	2.7	4.9	1.8 virginica
125	6.7	3.3	5.7	2.1 virginica

126	7.2	3.2	6.0	1.8	virginica
127	6.2	2.8	4.8	1.8	virginica
128	6.1	3.0	4.9	1.8	virginica
129	6.4	2.8	5.6	2.1	virginica
130	7.2	3.0	5.8	1.6	virginica
131	7.4	2.8	6.1	1.9	virginica
132	7.9	3.8	6.4	2.0	virginica
133	6.4	2.8	5.6	2.2	virginica
134	6.3	2.8	5.1	1.5	virginica
135	6.1	2.6	5.6	1.4	virginica
136	7.7	3.0	6.1	2.3	virginica
137	6.3	3.4	5.6	2.4	virginica
138	6.4	3.1	5.5	1.8	virginica
139	6.0	3.0	4.8	1.8	virginica
140	6.9	3.1	5.4	2.1	virginica
141	6.7	3.1	5.6	2.4	virginica
142	6.9	3.1	5.1	2.3	virginica
143	5.8	2.7	5.1	1.9	virginica
144	6.8	3.2	5.9	2.3	virginica
145	6.7	3.3	5.7	2.5	virginica
146	6.7	3.0	5.2	2.3	virginica
147	6.3	2.5	5.0	1.9	virginica
148	6.5	3.0	5.2	2.0	virginica
149	6.2	3.4	5.4	2.3	virginica
150	5.9	3.0	5.1	1.8	virginica

Base de datos E.coli

E.coli, base de datos donada por Paul Horton en 1996. Es una colección de 336 observaciones de localización de proteína en células, para cada una se miden 9 variables

	Seq. name	mcg	gvh	lip	chg	aac	alm1	alm2	class	dist
1	AAT_ECOLI	0.49	0.29	0.48	0.5	0.56	0.24	0.35		cp
2	ACEA_ECOLI	0.07	0.40	0.48	0.5	0.54	0.35	0.44		cp
3	ACEK_ECOLI	0.56	0.40	0.48	0.5	0.49	0.37	0.46		cp
4	ACKA_ECOLI	0.59	0.49	0.48	0.5	0.52	0.45	0.36		cp
5	ADI_ECOLI	0.23	0.32	0.48	0.5	0.55	0.25	0.35		cp
6	ALKH_ECOLI	0.67	0.39	0.48	0.5	0.36	0.38	0.46		cp
7	AMPD_ECOLI	0.29	0.28	0.48	0.5	0.44	0.23	0.34		cp
8	AMY2_ECOLI	0.21	0.34	0.48	0.5	0.51	0.28	0.39		cp
9	APT_ECOLI	0.20	0.44	0.48	0.5	0.46	0.51	0.57		cp
10	ARAC_ECOLI	0.42	0.40	0.48	0.5	0.56	0.18	0.30		cp
11	ASG1_ECOLI	0.42	0.24	0.48	0.5	0.57	0.27	0.37		cp
12	BTUR_ECOLI	0.25	0.48	0.48	0.5	0.44	0.17	0.29		cp
13	CAFA_ECOLI	0.39	0.32	0.48	0.5	0.46	0.24	0.35		cp
14	CAIB_ECOLI	0.51	0.50	0.48	0.5	0.46	0.32	0.35		cp
15	CFA_ECOLI	0.22	0.43	0.48	0.5	0.48	0.16	0.28		cp
16	CHEA_ECOLI	0.25	0.40	0.48	0.5	0.46	0.44	0.52		cp
17	CHEB_ECOLI	0.34	0.45	0.48	0.5	0.38	0.24	0.35		cp
18	CHEW_ECOLI	0.44	0.27	0.48	0.5	0.55	0.52	0.58		cp
19	CHEY_ECOLI	0.23	0.40	0.48	0.5	0.39	0.28	0.38		cp
20	CHEZ_ECOLI	0.41	0.57	0.48	0.5	0.39	0.21	0.32		cp
21	CRL_ECOLI	0.40	0.45	0.48	0.5	0.38	0.22	0.00		cp
22	CSPA_ECOLI	0.31	0.23	0.48	0.5	0.73	0.05	0.14		cp
23	CYNR_ECOLI	0.51	0.54	0.48	0.5	0.41	0.34	0.43		cp
24	CYPB_ECOLI	0.30	0.16	0.48	0.5	0.56	0.11	0.23		cp
25	CYPC_ECOLI	0.36	0.39	0.48	0.5	0.48	0.22	0.23		cp
26	CYSB_ECOLI	0.29	0.37	0.48	0.5	0.48	0.44	0.52		cp
27	CYSE_ECOLI	0.25	0.40	0.48	0.5	0.47	0.33	0.42		cp
28	DAPD_ECOLI	0.21	0.51	0.48	0.5	0.50	0.32	0.41		cp
29	DCP_ECOLI	0.43	0.37	0.48	0.5	0.53	0.35	0.44		cp
30	DDLA_ECOLI	0.43	0.39	0.48	0.5	0.47	0.31	0.41		cp
31	DDLB_ECOLI	0.53	0.38	0.48	0.5	0.44	0.26	0.36		cp
32	DEOC_ECOLI	0.34	0.33	0.48	0.5	0.38	0.35	0.44		cp
33	DLDH_ECOLI	0.56	0.51	0.48	0.5	0.34	0.37	0.46		cp
34	EFG_ECOLI	0.40	0.29	0.48	0.5	0.42	0.35	0.44		cp
35	EFTS_ECOLI	0.24	0.35	0.48	0.5	0.31	0.19	0.31		cp
36	EFTU_ECOLI	0.36	0.54	0.48	0.5	0.41	0.38	0.46		cp
37	ENO_ECOLI	0.29	0.52	0.48	0.5	0.42	0.29	0.39		cp
38	FABB_ECOLI	0.65	0.47	0.48	0.5	0.59	0.30	0.40		cp

39	FES_ECOLI	0.32	0.42	0.48	0.5	0.35	0.28	0.38	cp
40	G3P1_ECOLI	0.38	0.46	0.48	0.5	0.48	0.22	0.29	cp
41	G3P2_ECOLI	0.33	0.45	0.48	0.5	0.52	0.32	0.41	cp
42	G6PI_ECOLI	0.30	0.37	0.48	0.5	0.59	0.41	0.49	cp
43	GCVA_ECOLI	0.40	0.50	0.48	0.5	0.45	0.39	0.47	cp
44	GLNA_ECOLI	0.28	0.38	0.48	0.5	0.50	0.33	0.42	cp
45	GLPD_ECOLI	0.61	0.45	0.48	0.5	0.48	0.35	0.41	cp
46	GLYA_ECOLI	0.17	0.38	0.48	0.5	0.45	0.42	0.50	cp
47	GSHR_ECOLI	0.44	0.35	0.48	0.5	0.55	0.55	0.61	cp
48	GT_ECOLI	0.43	0.40	0.48	0.5	0.39	0.28	0.39	cp
49	HEM6_ECOLI	0.42	0.35	0.48	0.5	0.58	0.15	0.27	cp
50	HEMN_ECOLI	0.23	0.33	0.48	0.5	0.43	0.33	0.43	cp
51	HPRT_ECOLI	0.37	0.52	0.48	0.5	0.42	0.42	0.36	cp
52	IF1_ECOLI	0.29	0.30	0.48	0.5	0.45	0.03	0.17	cp
53	IF2_ECOLI	0.22	0.36	0.48	0.5	0.35	0.39	0.47	cp
54	ILVY_ECOLI	0.23	0.58	0.48	0.5	0.37	0.53	0.59	cp
55	IPYR_ECOLI	0.47	0.47	0.48	0.5	0.22	0.16	0.26	cp
56	KAD_ECOLI	0.54	0.47	0.48	0.5	0.28	0.33	0.42	cp
57	KDSA_ECOLI	0.51	0.37	0.48	0.5	0.35	0.36	0.45	cp
58	LEU3_ECOLI	0.40	0.35	0.48	0.5	0.45	0.33	0.42	cp
59	LON_ECOLI	0.44	0.34	0.48	0.5	0.30	0.33	0.43	cp
60	LPLA_ECOLI	0.42	0.38	0.48	0.5	0.54	0.34	0.43	cp
61	LYSR_ECOLI	0.44	0.56	0.48	0.5	0.50	0.46	0.54	cp
62	MALQ_ECOLI	0.52	0.36	0.48	0.5	0.41	0.28	0.38	cp
63	MALZ_ECOLI	0.36	0.41	0.48	0.5	0.48	0.47	0.54	cp
64	MASY_ECOLI	0.18	0.30	0.48	0.5	0.46	0.24	0.35	cp
65	METB_ECOLI	0.47	0.29	0.48	0.5	0.51	0.33	0.43	cp
66	METC_ECOLI	0.24	0.43	0.48	0.5	0.54	0.52	0.59	cp
67	METK_ECOLI	0.25	0.37	0.48	0.5	0.41	0.33	0.42	cp
68	METR_ECOLI	0.52	0.57	0.48	0.5	0.42	0.47	0.54	cp
69	METX_ECOLI	0.25	0.37	0.48	0.5	0.43	0.26	0.36	cp
70	MURF_ECOLI	0.35	0.48	0.48	0.5	0.56	0.40	0.48	cp
71	NADA_ECOLI	0.26	0.26	0.48	0.5	0.34	0.25	0.35	cp
72	NFRC_ECOLI	0.44	0.51	0.48	0.5	0.47	0.26	0.36	cp
73	NHAR_ECOLI	0.37	0.50	0.48	0.5	0.42	0.36	0.45	cp
74	NIRD_ECOLI	0.44	0.42	0.48	0.5	0.42	0.25	0.20	cp
75	OMPR_ECOLI	0.24	0.43	0.48	0.5	0.37	0.28	0.38	cp
76	OTC1_ECOLI	0.42	0.30	0.48	0.5	0.48	0.26	0.36	cp
77	OTC2_ECOLI	0.48	0.42	0.48	0.5	0.45	0.25	0.35	cp
78	PEPE_ECOLI	0.41	0.48	0.48	0.5	0.51	0.44	0.51	cp
79	PFLA_ECOLI	0.44	0.28	0.48	0.5	0.43	0.27	0.37	cp
80	PFLB_ECOLI	0.29	0.41	0.48	0.5	0.48	0.38	0.46	cp
81	PGK_ECOLI	0.34	0.28	0.48	0.5	0.41	0.35	0.44	cp
82	PHOB_ECOLI	0.41	0.43	0.48	0.5	0.45	0.31	0.41	cp
83	PHOH_ECOLI	0.29	0.47	0.48	0.5	0.41	0.23	0.34	cp

84	PMBA_ECOLI	0.34	0.55	0.48	0.5	0.58	0.31	0.41	cp
85	PNP_ECOLI	0.36	0.56	0.48	0.5	0.43	0.45	0.53	cp
86	PROB_ECOLI	0.40	0.46	0.48	0.5	0.52	0.49	0.56	cp
87	PT1A_ECOLI	0.50	0.49	0.48	0.5	0.49	0.46	0.53	cp
88	PT1_ECOLI	0.52	0.44	0.48	0.5	0.37	0.36	0.42	cp
89	PTCA_ECOLI	0.50	0.51	0.48	0.5	0.27	0.23	0.34	cp
90	PTCB_ECOLI	0.53	0.42	0.48	0.5	0.16	0.29	0.39	cp
91	PTFA_ECOLI	0.34	0.46	0.48	0.5	0.52	0.35	0.44	cp
92	PTGA_ECOLI	0.40	0.42	0.48	0.5	0.37	0.27	0.27	cp
93	PTHA_ECOLI	0.41	0.43	0.48	0.5	0.50	0.24	0.25	cp
94	PTHP_ECOLI	0.30	0.45	0.48	0.5	0.36	0.21	0.32	cp
95	PTKA_ECOLI	0.31	0.47	0.48	0.5	0.29	0.28	0.39	cp
96	PTKB_ECOLI	0.64	0.76	0.48	0.5	0.45	0.35	0.38	cp
97	PTNA_ECOLI	0.35	0.37	0.48	0.5	0.30	0.34	0.43	cp
98	PTWB_ECOLI	0.57	0.54	0.48	0.5	0.37	0.28	0.33	cp
99	PTWX_ECOLI	0.65	0.55	0.48	0.5	0.34	0.37	0.28	cp
100	RHAR_ECOLI	0.51	0.46	0.48	0.5	0.58	0.31	0.41	cp
101	RHAS_ECOLI	0.38	0.40	0.48	0.5	0.63	0.25	0.35	cp
102	RIMI_ECOLI	0.24	0.57	0.48	0.5	0.63	0.34	0.43	cp
103	RIMJ_ECOLI	0.38	0.26	0.48	0.5	0.54	0.16	0.28	cp
104	RIML_ECOLI	0.33	0.47	0.48	0.5	0.53	0.18	0.29	cp
105	RNB_ECOLI	0.24	0.34	0.48	0.5	0.38	0.30	0.40	cp
106	RNC_ECOLI	0.26	0.50	0.48	0.5	0.44	0.32	0.41	cp
107	RND_ECOLI	0.44	0.49	0.48	0.5	0.39	0.38	0.40	cp
108	RNE_ECOLI	0.43	0.32	0.48	0.5	0.33	0.45	0.52	cp
109	SERC_ECOLI	0.49	0.43	0.48	0.5	0.49	0.30	0.40	cp
110	SLYD_ECOLI	0.47	0.28	0.48	0.5	0.56	0.20	0.25	cp
111	SOXS_ECOLI	0.32	0.33	0.48	0.5	0.60	0.06	0.20	cp
112	SYA_ECOLI	0.34	0.35	0.48	0.5	0.51	0.49	0.56	cp
113	SYC_ECOLI	0.35	0.34	0.48	0.5	0.46	0.30	0.27	cp
114	SYD_ECOLI	0.38	0.30	0.48	0.5	0.43	0.29	0.39	cp
115	SYE_ECOLI	0.38	0.44	0.48	0.5	0.43	0.20	0.31	cp
116	SYFA_ECOLI	0.41	0.51	0.48	0.5	0.58	0.20	0.31	cp
117	SYFB_ECOLI	0.34	0.42	0.48	0.5	0.41	0.34	0.43	cp
118	SYGA_ECOLI	0.51	0.49	0.48	0.5	0.53	0.14	0.26	cp
119	SYGB_ECOLI	0.25	0.51	0.48	0.5	0.37	0.42	0.50	cp
120	SYH_ECOLI	0.29	0.28	0.48	0.5	0.50	0.42	0.50	cp
121	SYI_ECOLI	0.25	0.26	0.48	0.5	0.39	0.32	0.42	cp
122	SYK1_ECOLI	0.24	0.41	0.48	0.5	0.49	0.23	0.34	cp
123	SYK2_ECOLI	0.17	0.39	0.48	0.5	0.53	0.30	0.39	cp
124	SYL_ECOLI	0.04	0.31	0.48	0.5	0.41	0.29	0.39	cp
125	SYM_ECOLI	0.61	0.36	0.48	0.5	0.49	0.35	0.44	cp
126	SYP_ECOLI	0.34	0.51	0.48	0.5	0.44	0.37	0.46	cp
127	SYQ_ECOLI	0.28	0.33	0.48	0.5	0.45	0.22	0.33	cp
128	SYR_ECOLI	0.40	0.46	0.48	0.5	0.42	0.35	0.44	cp

129	SYS_ECOLI	0.23	0.34	0.48	0.5	0.43	0.26	0.37	cp
130	SYT_ECOLI	0.37	0.44	0.48	0.5	0.42	0.39	0.47	cp
131	SYV_ECOLI	0.00	0.38	0.48	0.5	0.42	0.48	0.55	cp
132	SYW_ECOLI	0.39	0.31	0.48	0.5	0.38	0.34	0.43	cp
133	SYX_ECOLI	0.30	0.44	0.48	0.5	0.49	0.22	0.33	cp
134	THGA_ECOLI	0.27	0.30	0.48	0.5	0.71	0.28	0.39	cp
135	THIK_ECOLI	0.17	0.52	0.48	0.5	0.49	0.37	0.46	cp
136	TYRB_ECOLI	0.36	0.42	0.48	0.5	0.53	0.32	0.41	cp
137	UBIC_ECOLI	0.30	0.37	0.48	0.5	0.43	0.18	0.30	cp
138	UGPQ_ECOLI	0.26	0.40	0.48	0.5	0.36	0.26	0.37	cp
139	USPA_ECOLI	0.40	0.41	0.48	0.5	0.55	0.22	0.33	cp
140	UVRB_ECOLI	0.22	0.34	0.48	0.5	0.42	0.29	0.39	cp
141	UVRC_ECOLI	0.44	0.35	0.48	0.5	0.44	0.52	0.59	cp
142	XGPT_ECOLI	0.27	0.42	0.48	0.5	0.37	0.38	0.43	cp
143	XYLA_ECOLI	0.16	0.43	0.48	0.5	0.54	0.27	0.37	cp
144	EMRA_ECOLI	0.06	0.61	0.48	0.5	0.49	0.92	0.37	im
145	AAS_ECOLI	0.44	0.52	0.48	0.5	0.43	0.47	0.54	im
146	AMPE_ECOLI	0.63	0.47	0.48	0.5	0.51	0.82	0.84	im
147	ARAE_ECOLI	0.23	0.48	0.48	0.5	0.59	0.88	0.89	im
148	ARAH_ECOLI	0.34	0.49	0.48	0.5	0.58	0.85	0.80	im
149	AROP_ECOLI	0.43	0.40	0.48	0.5	0.58	0.75	0.78	im
150	ATKB_ECOLI	0.46	0.61	0.48	0.5	0.48	0.86	0.87	im
151	ATP6_ECOLI	0.27	0.35	0.48	0.5	0.51	0.77	0.79	im
152	BETT_ECOLI	0.52	0.39	0.48	0.5	0.65	0.71	0.73	im
153	CODB_ECOLI	0.29	0.47	0.48	0.5	0.71	0.65	0.69	im
154	CYDA_ECOLI	0.55	0.47	0.48	0.5	0.57	0.78	0.80	im
155	CYOC_ECOLI	0.12	0.67	0.48	0.5	0.74	0.58	0.63	im
156	CYOD_ECOLI	0.40	0.50	0.48	0.5	0.65	0.82	0.84	im
157	DCTA_ECOLI	0.73	0.36	0.48	0.5	0.53	0.91	0.92	im
158	DHG_ECOLI	0.84	0.44	0.48	0.5	0.48	0.71	0.74	im
159	DHSC_ECOLI	0.48	0.45	0.48	0.5	0.60	0.78	0.80	im
160	DHSD_ECOLI	0.54	0.49	0.48	0.5	0.40	0.87	0.88	im
161	DPPC_ECOLI	0.48	0.41	0.48	0.5	0.51	0.90	0.88	im
162	DSBB_ECOLI	0.50	0.66	0.48	0.5	0.31	0.92	0.92	im
163	ENVZ_ECOLI	0.72	0.46	0.48	0.5	0.51	0.66	0.70	im
164	EXBB_ECOLI	0.47	0.55	0.48	0.5	0.58	0.71	0.75	im
165	FRDC_ECOLI	0.33	0.56	0.48	0.5	0.33	0.78	0.80	im
166	FRDD_ECOLI	0.64	0.58	0.48	0.5	0.48	0.78	0.73	im
167	FTSW_ECOLI	0.54	0.57	0.48	0.5	0.56	0.81	0.83	im
168	GABP_ECOLI	0.47	0.59	0.48	0.5	0.52	0.76	0.79	im
169	GALP_ECOLI	0.63	0.50	0.48	0.5	0.59	0.85	0.86	im
170	GLNP_ECOLI	0.49	0.42	0.48	0.5	0.53	0.79	0.81	im
171	GLPT_ECOLI	0.31	0.50	0.48	0.5	0.57	0.84	0.85	im
172	GLTP_ECOLI	0.74	0.44	0.48	0.5	0.55	0.88	0.89	im
173	KDGL_ECOLI	0.33	0.45	0.48	0.5	0.45	0.88	0.89	im

174	KGTP_ECOLI	0.45	0.40	0.48	0.5	0.61	0.74	0.77	im
175	LACY_ECOLI	0.71	0.40	0.48	0.5	0.71	0.70	0.74	im
176	LGT_ECOLI	0.50	0.37	0.48	0.5	0.66	0.64	0.69	im
177	LLDP_ECOLI	0.66	0.53	0.48	0.5	0.59	0.66	0.66	im
178	LNT_ECOLI	0.60	0.61	0.48	0.5	0.54	0.67	0.71	im
179	LSPA_ECOLI	0.83	0.37	0.48	0.5	0.61	0.71	0.74	im
180	LYSP_ECOLI	0.34	0.51	0.48	0.5	0.67	0.90	0.90	im
181	MALF_ECOLI	0.63	0.54	0.48	0.5	0.65	0.79	0.81	im
182	MALG_ECOLI	0.70	0.40	0.48	0.5	0.56	0.86	0.83	im
183	MCP3_ECOLI	0.60	0.50	1.00	0.5	0.54	0.77	0.80	im
184	MSBB_ECOLI	0.16	0.51	0.48	0.5	0.33	0.39	0.48	im
185	MTR_ECOLI	0.74	0.70	0.48	0.5	0.66	0.65	0.69	im
186	NANT_ECOLI	0.20	0.46	0.48	0.5	0.57	0.78	0.81	im
187	NHAA_ECOLI	0.89	0.55	0.48	0.5	0.51	0.72	0.76	im
188	NHAB_ECOLI	0.70	0.46	0.48	0.5	0.56	0.78	0.73	im
189	PHEP_ECOLI	0.12	0.43	0.48	0.5	0.63	0.70	0.74	im
190	PHOR_ECOLI	0.61	0.52	0.48	0.5	0.54	0.67	0.52	im
191	PNTA_ECOLI	0.33	0.37	0.48	0.5	0.46	0.65	0.69	im
192	POTE_ECOLI	0.63	0.65	0.48	0.5	0.66	0.67	0.71	im
193	PROP_ECOLI	0.41	0.51	0.48	0.5	0.53	0.75	0.78	im
194	PSTA_ECOLI	0.34	0.67	0.48	0.5	0.52	0.76	0.79	im
195	PSTC_ECOLI	0.58	0.34	0.48	0.5	0.56	0.87	0.81	im
196	PTAA_ECOLI	0.59	0.56	0.48	0.5	0.55	0.80	0.82	im
197	PTBA_ECOLI	0.51	0.40	0.48	0.5	0.57	0.62	0.67	im
198	PTCC_ECOLI	0.50	0.57	0.48	0.5	0.71	0.61	0.66	im
199	PTDA_ECOLI	0.60	0.46	0.48	0.5	0.45	0.81	0.83	im
200	PTFB_ECOLI	0.37	0.47	0.48	0.5	0.39	0.76	0.79	im
201	PTGB_ECOLI	0.58	0.55	0.48	0.5	0.57	0.70	0.74	im
202	PTHB_ECOLI	0.36	0.47	0.48	0.5	0.51	0.69	0.72	im
203	PTMA_ECOLI	0.39	0.41	0.48	0.5	0.52	0.72	0.75	im
204	PTOA_ECOLI	0.35	0.51	0.48	0.5	0.61	0.71	0.74	im
205	PTTB_ECOLI	0.31	0.44	0.48	0.5	0.50	0.79	0.82	im
206	RODA_ECOLI	0.61	0.66	0.48	0.5	0.46	0.87	0.88	im
207	SECE_ECOLI	0.48	0.49	0.48	0.5	0.52	0.77	0.71	im
208	SECF_ECOLI	0.11	0.50	0.48	0.5	0.58	0.72	0.68	im
209	SECY_ECOLI	0.31	0.36	0.48	0.5	0.58	0.94	0.94	im
210	TNAB_ECOLI	0.68	0.51	0.48	0.5	0.71	0.75	0.78	im
211	XYLE_ECOLI	0.69	0.39	0.48	0.5	0.57	0.76	0.79	im
212	YCEE_ECOLI	0.52	0.54	0.48	0.5	0.62	0.76	0.79	im
213	EXBD_ECOLI	0.46	0.59	0.48	0.5	0.36	0.76	0.23	im
214	FTSL_ECOLI	0.36	0.45	0.48	0.5	0.38	0.79	0.17	im
215	FTSN_ECOLI	0.00	0.51	0.48	0.5	0.35	0.67	0.44	im
216	FTSQ_ECOLI	0.10	0.49	0.48	0.5	0.41	0.67	0.21	im
217	MOTB_ECOLI	0.30	0.51	0.48	0.5	0.42	0.61	0.34	im
218	TOLA_ECOLI	0.61	0.47	0.48	0.5	0.00	0.80	0.32	im

219	TOLQ_ECOLI	0.63	0.75	0.48	0.5	0.64	0.73	0.66	im
220	EMRB_ECOLI	0.71	0.52	0.48	0.5	0.64	1.00	0.99	im
221	ATKC_ECOLI	0.85	0.53	0.48	0.5	0.53	0.52	0.35	imS
222	NFRB_ECOLI	0.63	0.49	0.48	0.5	0.54	0.76	0.79	imS
223	NLPA_ECOLI	0.75	0.55	1.00	1.0	0.40	0.47	0.30	imL
224	CYOA_ECOLI	0.70	0.39	1.00	0.5	0.51	0.82	0.84	imL
225	ATKA_ECOLI	0.72	0.42	0.48	0.5	0.65	0.77	0.79	imU
226	BCR_ECOLI	0.79	0.41	0.48	0.5	0.66	0.81	0.83	imU
227	CADB_ECOLI	0.83	0.48	0.48	0.5	0.65	0.76	0.79	imU
228	CAIT_ECOLI	0.69	0.43	0.48	0.5	0.59	0.74	0.77	imU
229	CPXA_ECOLI	0.79	0.36	0.48	0.5	0.46	0.82	0.70	imU
230	CRED_ECOLI	0.78	0.33	0.48	0.5	0.57	0.77	0.79	imU
231	CYDB_ECOLI	0.75	0.37	0.48	0.5	0.64	0.70	0.74	imU
232	CYOB_ECOLI	0.59	0.29	0.48	0.5	0.64	0.75	0.77	imU
233	CYOE_ECOLI	0.67	0.37	0.48	0.5	0.54	0.64	0.68	imU
234	DMSC_ECOLI	0.66	0.48	0.48	0.5	0.54	0.70	0.74	imU
235	DPPB_ECOLI	0.64	0.46	0.48	0.5	0.48	0.73	0.76	imU
236	DSBD_ECOLI	0.76	0.71	0.48	0.5	0.50	0.71	0.75	imU
237	FEPD_ECOLI	0.84	0.49	0.48	0.5	0.55	0.78	0.74	imU
238	FEPG_ECOLI	0.77	0.55	0.48	0.5	0.51	0.78	0.74	imU
239	FTSH_ECOLI	0.81	0.44	0.48	0.5	0.42	0.67	0.68	imU
240	GLTS_ECOLI	0.58	0.60	0.48	0.5	0.59	0.73	0.76	imU
241	KEFC_ECOLI	0.63	0.42	0.48	0.5	0.48	0.77	0.80	imU
242	KUP_ECOLI	0.62	0.42	0.48	0.5	0.58	0.79	0.81	imU
243	MCP1_ECOLI	0.86	0.39	0.48	0.5	0.59	0.89	0.90	imU
244	MCP2_ECOLI	0.81	0.53	0.48	0.5	0.57	0.87	0.88	imU
245	MCP4_ECOLI	0.87	0.49	0.48	0.5	0.61	0.76	0.79	imU
246	MELB_ECOLI	0.47	0.46	0.48	0.5	0.62	0.74	0.77	imU
247	MOTA_ECOLI	0.76	0.41	0.48	0.5	0.50	0.59	0.62	imU
248	NUPC_ECOLI	0.70	0.53	0.48	0.5	0.70	0.86	0.87	imU
249	NUPG_ECOLI	0.64	0.45	0.48	0.5	0.67	0.61	0.66	imU
250	PNTB_ECOLI	0.81	0.52	0.48	0.5	0.57	0.78	0.80	imU
251	PTKC_ECOLI	0.73	0.26	0.48	0.5	0.57	0.75	0.78	imU
252	RHAT_ECOLI	0.49	0.61	1.00	0.5	0.56	0.71	0.74	imU
253	SECD_ECOLI	0.88	0.42	0.48	0.5	0.52	0.73	0.75	imU
254	SECG_ECOLI	0.84	0.54	0.48	0.5	0.75	0.92	0.70	imU
255	TEHA_ECOLI	0.63	0.51	0.48	0.5	0.64	0.72	0.76	imU
256	TYRP_ECOLI	0.86	0.55	0.48	0.5	0.63	0.81	0.83	imU
257	UHPB_ECOLI	0.79	0.54	0.48	0.5	0.50	0.66	0.68	imU
258	TONB_ECOLI	0.57	0.38	0.48	0.5	0.06	0.49	0.33	imU
259	LEP_ECOLI	0.78	0.44	0.48	0.5	0.45	0.73	0.68	imU
260	FADL_ECOLI	0.78	0.68	0.48	0.5	0.83	0.40	0.29	om
261	FHUA_ECOLI	0.63	0.69	0.48	0.5	0.65	0.41	0.28	om
262	LAMB_ECOLI	0.67	0.88	0.48	0.5	0.73	0.50	0.25	om
263	NFRA_ECOLI	0.61	0.75	0.48	0.5	0.51	0.33	0.33	om

264	NMPC_ECOLI	0.67	0.84	0.48	0.5	0.74	0.54	0.37	om
265	OMPA_ECOLI	0.74	0.90	0.48	0.5	0.57	0.53	0.29	om
266	OMPC_ECOLI	0.73	0.84	0.48	0.5	0.86	0.58	0.29	om
267	OMPF_ECOLI	0.75	0.76	0.48	0.5	0.83	0.57	0.30	om
268	OMPX_ECOLI	0.77	0.57	0.48	0.5	0.88	0.53	0.20	om
269	PHOE_ECOLI	0.74	0.78	0.48	0.5	0.75	0.54	0.15	om
270	TSX_ECOLI	0.68	0.76	0.48	0.5	0.84	0.45	0.27	om
271	BTUB_ECOLI	0.56	0.68	0.48	0.5	0.77	0.36	0.45	om
272	CIRA_ECOLI	0.65	0.51	0.48	0.5	0.66	0.54	0.33	om
273	FECA_ECOLI	0.52	0.81	0.48	0.5	0.72	0.38	0.38	om
274	FEPB_ECOLI	0.64	0.57	0.48	0.5	0.70	0.33	0.26	om
275	FHUE_ECOLI	0.60	0.76	1.00	0.5	0.77	0.59	0.52	om
276	OMPP_ECOLI	0.69	0.59	0.48	0.5	0.77	0.39	0.21	om
277	OMPT_ECOLI	0.63	0.49	0.48	0.5	0.79	0.45	0.28	om
278	TOLC_ECOLI	0.71	0.71	0.48	0.5	0.68	0.43	0.36	om
279	PA1_ECOLI	0.68	0.63	0.48	0.5	0.73	0.40	0.30	om
280	MULI_ECOLI	0.77	0.57	1.00	0.5	0.37	0.54	0.01	omL
281	NLPB_ECOLI	0.66	0.49	1.00	0.5	0.54	0.56	0.36	omL
282	NLPE_ECOLI	0.71	0.46	1.00	0.5	0.52	0.59	0.30	omL
283	PAL_ECOLI	0.67	0.55	1.00	0.5	0.66	0.58	0.16	omL
284	SLP_ECOLI	0.68	0.49	1.00	0.5	0.62	0.55	0.28	omL
285	AGP_ECOLI	0.74	0.49	0.48	0.5	0.42	0.54	0.36	pp
286	AMY1_ECOLI	0.70	0.61	0.48	0.5	0.56	0.52	0.43	pp
287	ARAF_ECOLI	0.66	0.86	0.48	0.5	0.34	0.41	0.36	pp
288	ASG2_ECOLI	0.73	0.78	0.48	0.5	0.58	0.51	0.31	pp
289	BGLX_ECOLI	0.65	0.57	0.48	0.5	0.47	0.47	0.51	pp
290	C562_ECOLI	0.72	0.86	0.48	0.5	0.17	0.55	0.21	pp
291	CN16_ECOLI	0.67	0.70	0.48	0.5	0.46	0.45	0.33	pp
292	CYPH_ECOLI	0.67	0.81	0.48	0.5	0.54	0.49	0.23	pp
293	CYSP_ECOLI	0.67	0.61	0.48	0.5	0.51	0.37	0.38	pp
294	DGAL_ECOLI	0.63	1.00	0.48	0.5	0.35	0.51	0.49	pp
295	DPPA_ECOLI	0.57	0.59	0.48	0.5	0.39	0.47	0.33	pp
296	DSBA_ECOLI	0.71	0.71	0.48	0.5	0.40	0.54	0.39	pp
297	DSBC_ECOLI	0.66	0.74	0.48	0.5	0.31	0.38	0.43	pp
298	ECOT_ECOLI	0.67	0.81	0.48	0.5	0.25	0.42	0.25	pp
299	ECPD_ECOLI	0.64	0.72	0.48	0.5	0.49	0.42	0.19	pp
300	FECB_ECOLI	0.68	0.82	0.48	0.5	0.38	0.65	0.56	pp
301	FECR_ECOLI	0.32	0.39	0.48	0.5	0.53	0.28	0.38	pp
302	FEPB_ECOLI	0.70	0.64	0.48	0.5	0.47	0.51	0.47	pp
303	FIMC_ECOLI	0.63	0.57	0.48	0.5	0.49	0.70	0.20	pp
304	GGT_ECOLI	0.74	0.82	0.48	0.5	0.49	0.49	0.41	pp
305	GLNH_ECOLI	0.63	0.86	0.48	0.5	0.39	0.47	0.34	pp
306	GLPQ_ECOLI	0.63	0.83	0.48	0.5	0.40	0.39	0.19	pp
307	HTRA_ECOLI	0.63	0.71	0.48	0.5	0.60	0.40	0.39	pp
308	LIVJ_ECOLI	0.71	0.86	0.48	0.5	0.40	0.54	0.32	pp

309	LIVK_ECOLI	0.68	0.78	0.48	0.5	0.43	0.44	0.42	pp
310	MALE_ECOLI	0.64	0.84	0.48	0.5	0.37	0.45	0.40	pp
311	MALM_ECOLI	0.74	0.47	0.48	0.5	0.50	0.57	0.42	pp
312	MEPA_ECOLI	0.75	0.84	0.48	0.5	0.35	0.52	0.33	pp
313	MODA_ECOLI	0.63	0.65	0.48	0.5	0.39	0.44	0.35	pp
314	NRFA_ECOLI	0.69	0.67	0.48	0.5	0.30	0.39	0.24	pp
315	NRFF_ECOLI	0.70	0.71	0.48	0.5	0.42	0.84	0.85	pp
316	OPPA_ECOLI	0.69	0.80	0.48	0.5	0.46	0.57	0.26	pp
317	OSMY_ECOLI	0.64	0.66	0.48	0.5	0.41	0.39	0.20	pp
318	POTD_ECOLI	0.63	0.80	0.48	0.5	0.46	0.31	0.29	pp
319	POTF_ECOLI	0.66	0.71	0.48	0.5	0.41	0.50	0.35	pp
320	PPA_ECOLI	0.69	0.59	0.48	0.5	0.46	0.44	0.52	pp
321	PPB_ECOLI	0.68	0.67	0.48	0.5	0.49	0.40	0.34	pp
322	PROX_ECOLI	0.64	0.78	0.48	0.5	0.50	0.36	0.38	pp
323	PSTS_ECOLI	0.62	0.78	0.48	0.5	0.47	0.49	0.54	pp
324	PTR_ECOLI	0.76	0.73	0.48	0.5	0.44	0.39	0.39	pp
325	RBSB_ECOLI	0.64	0.81	0.48	0.5	0.37	0.39	0.44	pp
326	SPEA_ECOLI	0.29	0.39	0.48	0.5	0.52	0.40	0.48	pp
327	SUBI_ECOLI	0.62	0.83	0.48	0.5	0.46	0.36	0.40	pp
328	TBPA_ECOLI	0.56	0.54	0.48	0.5	0.43	0.37	0.30	pp
329	TESA_ECOLI	0.69	0.66	0.48	0.5	0.41	0.50	0.25	pp
330	TOLB_ECOLI	0.69	0.65	0.48	0.5	0.63	0.48	0.41	pp
331	TORA_ECOLI	0.43	0.59	0.48	0.5	0.52	0.49	0.56	pp
332	TREA_ECOLI	0.74	0.56	0.48	0.5	0.47	0.68	0.30	pp
333	UGPB_ECOLI	0.71	0.57	0.48	0.5	0.48	0.35	0.32	pp
334	USHA_ECOLI	0.61	0.60	0.48	0.5	0.44	0.39	0.38	pp
335	XYLF_ECOLI	0.59	0.61	0.48	0.5	0.42	0.42	0.37	pp
336	YTFQ_ECOLI	0.74	0.74	0.48	0.5	0.31	0.53	0.52	pp

Glosario

ALOM: Predice si ese segmento es un segmento transmembrana (INTEGRAL) o no (PERIFÉRICO) que compara la puntuación discriminante (nombrada como “puntuación ALOM”) con un parámetro umbral.

Aminoácidos: Son compuestos orgánicos que se combinan para formar proteínas. Se conforman de un grupo amino (-NH₂) y un grupo carboxilo (-COOH).

Bacteria Gram-positiva: En microbiología, se denomina bacteria gram positiva aquellas bacterias que se tiñen de azul oscuro o violeta por la tinción de Gram. Presentan solo una membrana lipídica y la pared de peptidoglicano es mucho más gruesa.

Bacteria Gram-negativa: En microbiología, se denominan bacterias gram negativas aquellas que no se tiñen de azul oscuro o de violeta por la tinción de Gram, y lo hacen de un color rosado tenue. Pues presenta doble membrana celular (una externa y la otra citoplasmática).

Bulbo: Órgano vegetal, generalmente subterráneo, que está formado por una yema gruesa o brote redondeado y en cuyas hojas se acumulan las sustancias de reserva.

C-terminal: Se refiere al extremo de una proteína o polipéptido es la región final de la cadena de aminoácidos que termina en un grupo carboxilo (-COOH).


Enlace peptídico: Es un enlace químico que se establece entre el grupo carboxilo de un aminoácido y e grupo amino de otro aminoácido. Esta clase de enlace donde se pierded una molécula de agua permite la formación de los mencionados peptídos y de las proteínas.

Enzimas: Una enzima es una proteína que cataliza las reacciones bioquímicas del metabolismo. Las enzimas actúan sobre las moléculas conocidas como sustratos y permiten en desarrollo de los diversos procesos celulares.

Hidrofobicidad: Ocurre cuando la molécula en cuestión no es capaz de interaccionar con las moléculas de agua ni por interacciones ión-dipolo ni mediante puentes de hidrógeno. Tal es el caso de los hidrocarburos saturados.

Inflorescencia: Disposición que toman y orden en que aparecen y se desarrollan las flores en una planta cuyos brotes florales se ramifican.

Grupo Carboxilo: Es un grupo de la forma



(donde R es un hidrógeno o grupo orgánico)

Lípidos: Son un conjunto de moléculas organicas (la mayoría biomoléculas), que están constituidas principalmente por carbono e hidrógeno y en menor medida por oxígeno.

Lipoproteínas: Son complejos macromoleculares compuestos por proteínas y lípidos que transportan masivamente las grasas por todo el organismo.

Membrana Celular: Es la pared que poseen las células permitiendo mantenerse independientes del medio externo. Está compuesta por: una bicapa fosfolipídica (25%), proteínas (55%), colesterol (13%), hidratos de carbono (3%) y otros lípidos (4%)

Método McGeoch: Predice la presencia de secuencias de señales, una puntuación discriminante se calcula a partir de tres valores: longitud de UR (la región hidrofóbica central), valor máximo de UR y carga neta de CR (carga básica).

Método Von Heijne: Método para el reconocimiento de secuencias de señales. Se puede usar para detectar secuencias de señales no divisibles.

N-terminal: Se refiere al extremo de una proteína o polipéptido que finaliza con un aminoácido que posee un grupo amino libre.

Patotipo: Una población de parásito en la que todos los individuos tienen una capacidad parasitaria en común.

Peptidasas: Son enzimas que rompen los enlaces peptídicos de las proteínas. Para ello, utilizan una molécula de agua por lo que se clasifican como hidrolasas.

Proteínas: Son moléculas formadas por aminoácidos que están unidos por un tipo de enlaces conocidos como enlaces peptídicos. Las proteínas integrales que nadan dentro de la membrana son clasificadas en tres tipos:

*Las que funcionan como canales (canales proteicos) para el paso de moléculas específicas.

*Las transportadoras que llevan una determinada molécula al interior de la célula.

*Las receptoras que desencadenan respuestas según la función de cada célula.

Serología: Estudio de los sueros biológicos.

Serotipo: Un microorganismo que puede causar una infección.