



GRADO EN MATEMÁTICA COMPUTACIONAL

ESTANCIA EN PRÁCTICAS Y PROYECTO FINAL DE GRADO

Algoritmos de aprendizaje automatizado para el meta compresor de datos Blosc

Autor:

Alberto SABATER MORALES

Supervisor:

Francesc ALTED ABAD

Tutor académico:

Amelia SIMÓ VIDAL

Fecha de lectura: 8 de mayo de 2017
Curso académico 2016/2017

Resumen

Este documento recopila los detalles y procedimientos más importantes del Proyecto de Final de Grado realizado a partir de la Estancia en Prácticas en la empresa de Francesc Alted. El principal objetivo fue el desarrollo de algoritmos de aprendizaje automatizado para el compresor de datos *Blosc*.

Actualmente, el compresor *Blosc* dispone de tantas opciones a configurar para el usuario que resulta difícil conseguir la óptima para cada caso de uso y además requiere tener conocimientos sobre el mismo para utilizarlo de forma eficaz. Con el objetivo de reducir la complejidad de uso, durante la estancia en prácticas se desarrollaron algoritmos de clasificación supervisada para que escogieran las opciones óptimas por el usuario, según el resultado que éste quisiera obtener.

Además de los procedimientos seguidos en el desarrollo de estos algoritmos, también se detallan los fundamentos teóricos en los que se basan y se realiza una comparativa entre los mismos en cuanto a precisión y rendimiento. Las técnicas de clasificación supervisada que se han utilizado son: análisis discriminante, regresión multinomial, máquinas de vector soporte, vecinos más próximos y bosques aleatorios.

Palabras clave

Compresión, Aprendizaje automático, Clasificación supervisada

Keywords

Compression, Machine learning, Supervised classification.

Índice general

1. Introducción	9
1.1. Contexto y motivación del proyecto	9
2. Estancia en prácticas	11
2.1. Introducción	11
2.2. Software utilizado	12
2.2.1. Blosc	12
2.2.2. Git	13
2.2.3. Python	13
2.2.4. HDF5	14
2.2.5. Jupyter Notebook	15
2.3. Objetivos	15
2.4. Metodología y tareas realizadas	16
2.4.1. Generación de datos de pruebas de compresión con Blosc	16
2.4.2. Análisis de los datos recogidos	18
2.4.3. Generación de datos de entrenamiento	19

2.4.4. Análisis de las técnicas de aprendizaje automatizado	21
2.5. Planificación temporal de las tareas	22
2.6. Grado de consecución de los objetivos propuestos	24
2.7. Conclusiones	24
3. Algoritmos clasificadores de aprendizaje automatizado	25
3.1. Motivación y objetivos	25
3.2. Métricas de puntuación	26
3.3. Análisis discriminante lineal	28
3.3.1. Clasificación entre dos poblaciones	28
3.3.2. Generalización para varias poblaciones	31
3.4. Regresión multinomial	33
3.4.1. Regresión logística	33
3.4.2. Generalización para G poblaciones: regresión multinomial	36
3.5. Árboles de decisión	37
3.5.1. Algoritmo CART	38
3.5.2. Bosques aleatorios	39
3.6. Vecinos más próximos	41
3.7. Máquinas de vector soporte	41
4. Análisis de los Resultados	45
4.1. Análisis de los datos de pruebas de compresión	45
4.2. Generación de los datos de entrenamiento	48

4.3.	Análisis de los algoritmos de clasificación	52
4.3.1.	Análisis individual: Bosques aleatorios	52
4.3.2.	Comparativa de algoritmos	58
5.	Conclusiones	65
A.	Generador de datos de las pruebas de compresión	69
A.1.	Código test_data_generator.py	69
B.	Análisis descriptivo de las pruebas de compresión	77
B.1.	Código custom_plots.py	77
B.2.	Cuaderno blosc_test_analysis.ipynb	87
C.	Generador de los datos de entrenamiento	109
C.1.	Cuaderno training_data_generator.ipynb	110
D.	Análisis de los algoritmos de clasificación	115
D.1.	Programas Python	115
D.2.	Cuaderno lda_logit_analysis.ipynb	129
D.3.	Cuaderno SVM_analysis.ipynb	134
D.4.	Cuaderno KNeig_analysis.ipynb	139
D.5.	Cuaderno RFC_analysis.ipynb	143
D.6.	Cuaderno classifiers_comparison.ipynb	150

Capítulo 1

Introducción

1.1. Contexto y motivación del proyecto

Este Proyecto de Final de Grado, junto a la Estancia en Prácticas forma parte del plan de formación establecido por el Grado en Matemática Computacional. El objetivo consistió en profundizar en las técnicas de aprendizaje automatizado o clasificación supervisada y su aplicación a la mejora de un compresor de datos denominado *Blosc*.

A lo largo de los años se ha empleado la compresión para superar limitaciones físicas de la informática. Desde conseguir transmitir información más rápido cuando las conexiones a Internet no alcanzaban ni para descargar las noticias de la localidad, hasta acelerar el proceso de entrenamiento de un algoritmo de aprendizaje automático [9]. Para casos como estos resulta fundamental el uso de librerías de compresión ultra rápidas como *Blosc*, que permiten acelerar procesos de entrada/salida que a día de hoy soportan enormes cantidades de tráfico, gracias a la enorme cantidad de datos que se generan, tanto por redes sociales, como por dispositivos inteligentes conectados a Internet.

Este proyecto nace motivado por la necesidad de simplificar el uso del meta compresor de datos *Blosc*, una librería desarrollada por Francesc Alted que permite compresión y descompresión muy rápida de datos sin pérdida de información. A la hora de utilizar *Blosc* el usuario debe estar familiarizado con el mismo y las opciones que ofrece, con el objetivo de superar esta barrera, se aplicarán diversas técnicas de aprendizaje automatizado para desarrollar un algoritmo que decida por el usuario las opciones de *Blosc* según los resultados que quiere obtener. Estos algoritmos básicamente consisten en técnicas de clasificación supervisada donde a partir de unas variables descriptivas o características $x_i = (x_{i1}, \dots, x_{ip})$ se infiere la variable respuesta o valor objetivo y_i . En este proyecto las características son los resultados de la compresión que

desea el usuario y las características de los datos; y las variables objetivo son las opciones de *Blosc*.

En el Capítulo 2, se detallan todos los procedimientos seguidos durante la estancia en prácticas, desde la generación de los datos de pruebas de compresión, hasta los análisis y comparativas de algoritmos de aprendizaje automatizado. En el Capítulo 3, se presentan los fundamentos teóricos de las técnicas utilizadas. El análisis de las técnicas y los resultados se detallan en el Capítulo 4 y por último en el Capítulo 5 se presentan las conclusiones.

Capítulo 2

Estancia en prácticas

2.1. Introducción

Francesc Alted es un consultor y desarrollador de software independiente con más de 15 años de experiencia en los lenguajes de programación *C* y *Python*, y casi 25 años de especialización en el uso de técnicas de compresión para la aceleración de los procesos de comunicación entre sistemas informáticos de entrada/salida (I/O).

Durante los últimos años ha desarrollado *Blosc*, un meta-compresor multihilo de altas prestaciones optimizado para datos binarios. *Blosc* permite comprimir conjuntos de datos con distintos compresores (códigos), filtros de precompresión y niveles de compresión, lo cual permite elegir las condiciones más óptimas ante cualquier escenario. A parte de *Blosc*, también es el autor principal de otras dos librerías, *PyTables* y *bcolz*, que complementan a *Blosc* ayudando a gestionar y estructurar grandes conjuntos de datos.

Durante la estancia en prácticas se propuso elaborar un estudio del meta-compresor de datos *Blosc* y mejorarlo por medio de sofisticadas técnicas de aprendizaje automatizado (*Machine Learning*).

Este proyecto consistió en desarrollar un algoritmo basado en técnicas de aprendizaje automatizado que permite utilizar *Blosc* de forma eficiente y sencilla. El algoritmo escoge todas las opciones disponibles al utilizar *Blosc* según los requisitos que pide el usuario. De tal forma, el usuario sólo tiene que elegir entre unas pocas opciones según los resultados que quiere obtener, evitando tener que probar todas las opciones de *Blosc* hasta encontrar las que se adecuan a su caso.

2.2. Software utilizado

Para desarrollar el proyecto se ha utilizado el lenguaje de programación *Python*, concretamente la distribución proporcionada por Anaconda, una plataforma libre que incluye los paquetes más populares de *Python* para la ciencia de datos.

2.2.1. Blosc

Como ya se ha descrito en la introducción, *Blosc* es un meta-compresor de datos de altas prestaciones sin pérdida de información. Los algoritmos de compresión sin pérdida se caracterizan por buscar redundancias en los datos para poderlos comprimir, esto implica que datos muy parecidos entre sí se pueden comprimir fácilmente mientras que para datos muy diferentes se complica la cosa. Actualmente, para utilizar *Blosc* de forma eficiente hace falta dedicarle tiempo, tanto al aprendizaje de su funcionamiento, como para configurar las distintas opciones que ofrece. Para comprimir, *Blosc* recibe un vector de datos que pueden ser de cualquier tipo, ya que él los tratará a nivel de bytes, y comprimirá según las opciones proporcionadas. Para configurar *Blosc* hay que determinar las siguientes opciones:

- **Número de hilos:** al soportar compresión multihilo, hay que decidir cuántos hilos utilizará en la compresión. La opción por defecto es utilizar el máximo proporcionado por el procesador, pero en los experimentos realizados se ha limitado a 4 ya que es el número más habitual en el mercado actual.
- **Tamaño de tipo:** este es el tamaño en bytes del tipo de datos a comprimir. Aunque se puede especificar de manera totalmente independiente, lo normal es establecer el tamaño en bytes del tipo de datos, por ejemplo: 4 bytes para números de 32 bits, 8 bytes para números de 64 bits, 24 bytes para cadenas de texto *ASCII*, etc.
- **Códec:** este es el algoritmo de compresión/descompresión a utilizar, probablemente la opción más importante a la hora de utilizar *Blosc*. Los algoritmos disponibles son: *BloscLZ*, *LZ4*, *LZ4HC*, *Snappy*, *Zstd* y *Zlib*. Cada algoritmo suele ser óptimo en distintos casos de uso por lo que conviene estudiarlos y probarlos para poder decidir.
- **Filtro:** esto son filtros realizados sobre los datos antes de realizar la compresión. Básicamente reorganizan los bytes o bits del bloque de datos a comprimir de manera que a la izquierda se acumulan los bytes o bits más significativos de cada dato, un dato es un bloque de bytes del tamaño de tipo, y a la derecha los bytes o bits menos significativos. En la Fig. 2.1 se puede observar el esquema de esta reorganización. Este filtro es útil puesto que, por ejemplo, con enteros de 32 bits que sean menores de 256 se acumularían 7

bytes por entero a la izquierda del bloque con todo ceros lo que incrementa la redundancia y consecuentemente la compresión. *Blosc* proporciona tres opciones para el filtro: no utilizarlo (*noshuffle*), filtrar a nivel de byte (*shuffle*) o filtrar a nivel de bit (*bitshuffle*).

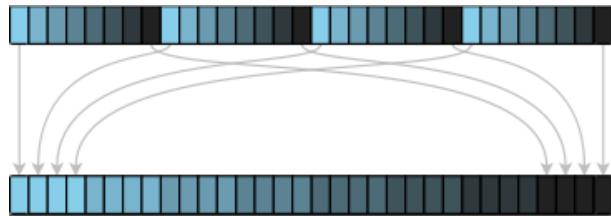


Figura 2.1: Esquema del filtro, arriba 4 datos de 8 bytes de tamaño, abajo el bloque de datos remezclado

- **Nivel de compresión:** esta opción regula la cantidad de compresión a utilizar por el algoritmo seleccionado. Cada algoritmo ofrece distintas escalas para seleccionar la cantidad de compresión a utilizar, *Blosc* ha normalizado esas escalas entre 1 y 9.
- **Tamaño de bloque:** es el tamaño del bloque de datos que utiliza *Blosc* a nivel interno para realizar la compresión. Generalmente un tamaño menor implica que comprimirá más rápido puesto que los datos cabrán dentro de la caché del procesador, sin embargo el ratio de compresión se reduce porque busca redundancias en un tamaño menor de datos.

2.2.2. Git

Es el software de control de versiones utilizado para gestionar el código desarrollado, junto al repositorio en línea www.bitbucket.org nos ha permitido realizar el seguimiento del proyecto. Por medio de *Git* se realizaban actualizaciones del código del programa (*commits*) que eran almacenadas en *bitbucket*, además permite comentar el código en la web mostrando las diferencias entre versiones de forma que establece un buen canal de comunicación sobre el código.

2.2.3. Python

Es un lenguaje de programación interpretado cuya filosofía enfatiza la legibilidad del código. Se ha escogido este lenguaje dada la popularidad adquirida en el sector de la ciencia de los datos durante los últimos años. Este éxito se debe en parte a iniciativas como *PyData*, una comunidad de desarrolladores y usuarios de herramientas de software libre centradas en la ciencia de los datos para *Python*, y *NumFOCUS*, una organización sin ánimo de lucro que da apoyo y promueve proyectos científicos de software libre.

A continuación se listan y describen las librerías más importantes empleadas:

- **python-blosc**: permite utilizar el meta compresor *Blosc* desde *Python*. Se ha utilizado para realizar las pruebas de compresión con las distintas opciones disponibles en Blosc.
- **PyTables**: es una librería para la gestión de grandes cantidades de datos de forma eficiente en forma de bases de datos jerárquicas. Ha permitido el acceso a los datos utilizados para realizar las pruebas de compresión.
- **NumPy**: es la base para la computación científica en **Python**. Proporciona una potente estructura de datos de tipo matricial y capacidades del álgebra lineal, transformaciones de Fourier y números aleatorios.
- **pandas**: es la librería fundamental para el análisis de datos en **Python** proporciona la estructura de datos **DataFrame** que permite tratar los datos de forma eficaz con facilidad. Ha permitido almacenar, analizar y tratar los datos de las pruebas de compresión.
- **matplotlib**: es la librería por excelencia para la visualización de los datos. Permite realizar gráficas con todo lujo de detalles al estilo de *MATLAB*. Se ha empleado para visualizar los datos durante el análisis.
- **scikit-learn**: es una librería orientada al aprendizaje automatizado. Se ha empleado durante el análisis y desarrollo de los algoritmos de aprendizaje automatizado.

2.2.4. HDF5

Es un formato de ficheros diseñado para organizar y guardar grandes conjuntos de datos, las siglas HDF significan Formato de Datos Jerárquico(Hierarchical Data Format). Originalmente desarrollado por el National Center of Supercomputing Applications, ahora lo mantiene The HDF Group, una organización sin ánimo de lucro con el objetivo de asegurar un desarrollo continuo en las tecnologías de *HDF5*.

Para extraer datos de las pruebas de compresión se han utilizado ficheros en este formato por lo que resulta interesante describir la estructura de un fichero *HDF5*, la cual está formada mayoritariamente por dos tipos de objetos:

- **Conjuntos de datos**: estos son matrices de datos.
- **Grupos**: son estructuras contenedores que pueden tener conjuntos de datos y otros grupos en su interior.

2.2.5. Jupyter Notebook

Es una aplicación web libre que permite crear y compartir documentos que contienen bloques de código con sus correspondientes salidas por pantalla y bloques de texto enriquecido con lenguaje *Markdown*, soportando *LaTex* y *HTML*. Resulta de especial utilidad a la hora de desarrollar el análisis de los datos llevando un registro de las técnicas empleadas y además permitiendo la generación de informes tanto en *HTML* como en *pdf*.

Dado que el formato de los cuadernos solo se puede visualizar mientras estas ejecutando la aplicación de *jupyter* se decidió guardarlos también en formato *HTML* y *Python*, utilizando el código proporcionado por Jonathan Whitmore [13].

Para facilitar el desarrollo se creó una carpeta llamada *notebooks* donde guardar todo lo relacionado con los cuadernos *jupyter* y basándose en las recomendaciones de Jonathan Whitmore [14] se estableció la siguiente estructura:

- **data:** aquí se almacenan todos los ficheros de datos, generalmente fichero *csv*.
- **deliver:** este directorio contiene los cuadernos *jupyter* importantes, es decir, que están listos para entregar o presentar como resultados del análisis.
- **develop:** aquí se guardan el resto de cuadernos a modo de registro diario de los experimentos, el objetivo no es tener cuadernos limpios sino establecer un registro de las pruebas realizadas de forma que se puedan recopilar después en un cuaderno limpio.
- **src:** en caso de que el código de algún cuaderno sea muy extenso conviene recopilarlo aquí en forma de paquetes y así mejorar la legibilidad del análisis.
- **figures:** esta carpeta recopila las figuras y gráficas relevantes para así poder consultar un histórico de los cambios en las imágenes.

2.3. Objetivos

El principal objetivo de este proyecto es desarrollar un algoritmo que, según las necesidades del usuario final, decida automáticamente entre las opciones del meta-compresor *Blosc* el conjunto óptimo. A parte también se pretende:

- Estudiar el comportamiento de las distintas opciones de *Blosc* sobre distintos conjuntos de datos.

- Extraer características que relacionen los datos con los resultados de la compresión.
- Automatizar en la medida de lo posible el análisis de los datos para adaptar los datos de entrenamiento del algoritmo bajo demanda.
- Realizar un estudio de las distintas técnicas de aprendizaje automatizado.

2.4. Metodología y tareas realizadas

Para el desarrollo del proyecto se optó por una metodología de desarrollo de software ágil, se dedicaban cinco minutos a diario para comentar el estado del proyecto y además una reunión a la semana para la refactorización del código y la planificación de la próxima semana. Dado que el cliente final es el propio Francesc, tenía una realimentación continua de calidad sobre el código.

Para la planificación del proyecto se ha optado por dividirlo en cuatro partes: la generación de datos de pruebas de compresión con *Blosc*, el análisis de los datos recolectados, la generación de los datos de entrenamiento y finalmente, la aplicación y análisis de las distintas técnicas de aprendizaje automatizado.

2.4.1. Generación de datos de pruebas de compresión con *Blosc*

El objetivo de esta tarea era el de generar datos con ficheros de datos reales para después tratarlos y prepararlos para las técnicas de aprendizaje automatizado. Para ello había que familiarizarse con *Blosc* y preparar un programa en *Python* que extrajera datos de ficheros en formato *hdf5*, después les aplicase las distintas pruebas de compresión y descompresión, y finalmente guardara los datos de las pruebas en un fichero *csv*.

Para realizar las pruebas se partió originalmente del programa *compress_ptr.py* incluido en *python-blosc* [2] y se modificó hasta desarrollar el programa final que se encuentra en el Anexo A. A continuación se detalla el flujo del programa.

En primer lugar el programa comprueba si ya existe el fichero *csv* final, de no ser así lo crea vacío con los nombres de las distintas columnas. A continuación recorre la lista de ficheros en formato *hdf5* especificada, para cada fichero recorre los distintos conjuntos de datos (que en la práctica son vectores o tablas de datos de un tipo determinado) y los divide en fragmentos de datos (en adelante, *chunks*) de 16 megabytes, de los cuales se extraerán características globales. La elección de tamaño de *chunk* de 16 megabytes se debe a que como muestra Alistair Miles en

su estudio sobre *Blosc* [10], a partir de dicho tamaño apenas hay mejora en las velocidades de compresión y descompresión.

Una vez se van generando los *chunks* se extrae de cada uno las características estudiadas que son las de la Tabla 2.1. Se han seleccionado estas características puesto que sirven para determinar la dispersión, varianza o rango de los datos lo cual está relacionado con la redundancia la cual es la base de la compresión sin pérdida de información.

Característica	Descripción
Filename	Nombre del fichero del que proviene.
DataSet	Nombre del conjunto de datos dentro del fichero del que proviene.
Chunk_Number	Número de chunk dentro del conjunto de datos.
Chunk_Size	Tamaño del chunk.
Table	Variable categórica que indica el tipo de estructura de la que provienen los datos: - 0: vector - 1: tabla - 2: tabla columnar
DType	Especifica el tipo de los datos en formato <i>numpy.dtype</i> .
Mean	Media de los datos.
Median	Mediana de los datos.
Sd	Desviación típica de los datos.
Skew	Coeficiente de asimetría de los datos.
Kurt	Coeficiente de apuntamiento de los datos.
Min	Mínimo absoluto de los datos.
Max	Máximo absoluto de los datos.
Q1	Primer cuartil de los datos.
Q3	Tercer cuartil de los datos.
N_Streaks	Número de rachas consecutivas por encima o por debajo de la mediana.

Tabla 2.1: Características de *chunk* extraídas

Seguidamente para cada *chunk* se procede a realizar las pruebas de compresión y descompresión con cada combinación de opciones posibles en *Blosc*, que son las descritas en el apartado 2.2.1. Conforme se van realizando las pruebas se extraen las características descritas en la Tabla 2.2 y se van añadiendo filas a una estructura *DataFrame* auxiliar del paquete *pandas*. Finalmente al terminar las pruebas se escriben todos los datos del *chunk* al fichero *csv*.

Característica	Descripción
Codec	Nombre del algoritmo compresor.
Filter	Nombre del filtro.
CL	Nivel de compresión.
Block_Size	Tamaño de bloque.
CRate	Ratio de compresión obtenido.
CSpeed	Velocidad de compresión en GB/s.
DSpeed	Velocidad de descompresión en GB/s.

Tabla 2.2: Características extraídas en las pruebas de compresión

2.4.2. Análisis de los datos recogidos

Esta tarea consiste en analizar los datos recogidos en la anterior. Por tanto el objetivo es obtener un análisis descriptivo de los datos, de forma que posteriormente se pueda generar análisis bajo demanda para otros ficheros de datos. Además también se pretende familiarizarse con los paquetes de *pandas* y *matplotlib*, así como realizar algunas comprobaciones y observaciones sobre los datos.

Con respecto al análisis se estructuró de la siguiente manera:

- **Descripción general:** aquí se describe la muestra y se realizan descripciones generales de los datos. Principalmente se describen los conjuntos de datos extraídos y se observan datos de las pruebas de compresión generales para un códec, filtro, nivel de compresión y tamaño de bloque en concreto.
- **Correlaciones del tamaño de bloque:** en este apartado se muestran gráficos de líneas relacionando el tamaño de bloque con los ratios y velocidades de compresión, además también se comparan estas curvas según el nivel de compresión.
- **Comportamiento del nivel de compresión:** muy parecido al anterior pero para el nivel de compresión.

- **Comparativa de tablas:** en esta sección se comparan las pruebas de compresión según si se han extraído los datos en forma de tabla o tabla columnar.
- **Correlación entre códecs rápidos y el resto:** aquí se pretende observar si la correlación entre los algoritmos de compresión más rápidos como: *BloscLZ* y *LZ4* con nivel de compresión 1 y el resto de algoritmos es buena.
- **Correlación entre características de chunk y de pruebas de compresión:** finalmente se realiza un gráfico personalizado enfrentando características de chunk con los ratios y velocidades de compresión. El objetivo es ver si a primera vista se observa alguna correlación fuerte.

Para observar con más detalle el análisis realizado, en el Anexo B se encuentra el informe final obtenido.

2.4.3. Generación de datos de entrenamiento

Una vez ya familiarizados con los datos de las pruebas hay que extraer de ellos unos datos que nos sirvan para entrenar posteriormente el algoritmo de aprendizaje. Cabe destacar que en este caso se busca aprendizaje supervisado, por tanto a las características extraídas anteriormente hay que añadir las opciones que tendría el usuario final para así poder extraer entre todas las pruebas las óptimas para dichas opciones. Además, considerando la velocidad de extracción y la correlación de las medidas de compresión de *BloscLZ* y *LZ4* con nivel de compresión uno y el resto de medidas de compresión se decide añadir éstas como características.

Tras estudiar el caso se plantearon las opciones y codificaciones de la Tabla 2.3. Donde **IN_CR** hace referencia al ratio de compresión, **IN_CS** a la velocidad de compresión y **IN_DS** a la velocidad de descompresión

La codificación se corresponde con si el usuario le da importancia o no a la medida en cuestión. Para cada opción se extrae una combinación de valores objetivo: **Codec**, **Filter**, **CL**, **Block_Size** siguiendo el procedimiento detallado en el Capítulo 4. En la Fig. 2.2 se aprecia el esquema de clasificación descrito.

Tras extraer los valores objetivo se comprobó la cantidad de clases distintas resultantes y se observó que el compresor *Zlib* nunca era elegido y *Snappy* solo aparecía a en dos ocasiones, por tanto se descartaron y el número de opciones de CÓDEC pasó de seis a cuatro. A continuación se comprobó la eficiencia del tamaño de bloque automático y las opciones seleccionadas con bloque automático, se sustituyeron por su valor real para simplificar la cantidad de tamaños de bloque resultantes.

Codificación			Descripción
IN_CR	IN_CS	IN_DS	
1	0	0	Máximo ratio de compresión.
0	1	0	Máxima velocidad de compresión.
0	0	1	Máxima velocidad de descompresión.
0	1	1	Equilibrio entre velocidad de compresión y descompresión.
1	1	0	Equilibrio entre ratio y velocidad de compresión.
1	0	1	Equilibrio entre ratio de compresión y velocidad de descompresión.
1	1	1	Equilibrio entre las tres medidas.

Tabla 2.3: Opciones de usuario y su codificación.



Figura 2.2: Esquema de clasificación

Seguidamente se tratan las características categóricas **Table** y **DType**, transformando la primera en dos variables binarias: **is_Table** e **is_Columnar**; y la segunda en tres variables binarias: **is_Int**, **is_Float** e **is_String**, y una continua **Type_Size** indicando el tamaño en bytes del tipo.

Finalmente se transforman las variables objetivo categóricas **Códec**, **Filter**, **CL** y **Block_Size** de forma que se convierten todas en variables binarias de las cuales, **cinco** son para **Códec**, **tres** para **Filter**, **nueve** para **CL** y otras **nueve** para **Block_Size**.

2.4.4. Análisis de las técnicas de aprendizaje automatizado

Finalmente con los datos de entrenamiento se ha procedido al estudio de los algoritmos de aprendizaje automatizado. El objetivo de este análisis es obtener el algoritmo final que se integrará internamente en la librería de *Blosc* y que permitirá utilizarla eligiendo tres simples parámetros **IN_CR**, **IN_CS** e **IN_DS**.

Para este análisis se han comparado los siguientes tipos de algoritmos de clasificación supervisada ofrecidos por la librería de *scikit-learn*: **análisis discriminante**, **regresión multinomial**, **bosques aleatorios**, **vecinos más próximos** y **máquinas de vector soporte**. Además cada uno de estos clasificadores aceptan distintos parámetros que se detallan a lo largo del capítulo 3.

Dado que la clasificación a realizar es de cuatro variables (**Codec**, **Filter**, **CL** y **Block_Size**) y cada variable representa una elección entre distintas opciones o **clases**, se trata de un problema de clasificación de múltiples clases y salidas (conocido como **multioutput-multiclass** dentro de *scikit-learn*). A pesar de que varios métodos de los escogidos no soportan de forma nativa **multioutput-multiclass**, *scikit-learn* proporciona métodos para adaptarlos, realizando las múltiples clasificaciones de forma secuencial y reutilizando los resultados de cada clasificación para la siguiente.

Scikit-learn proporciona varias **métricas de puntuación** para medir la precisión de las clasificaciones pero ninguna de ellas funciona para **multioutput-multiclass**, excepto la predeterminada, que para este problema no se adapta del todo. La métrica de precisión por defecto considera únicamente los aciertos totales, es decir cuando acierta todas las variables: **Codec**, **Filter**, **CL** y **Block_Size**. Esto es demasiado restrictivo ya que acertar el nivel de compresión y tamaño de bloque con total precisión resulta imposible pues la diferencia entre niveles y tamaños cercanos es poco significativa. Por tanto para puntuar las clasificaciones y analizar los distintos algoritmos se utilizaron las siguientes métricas: una métrica **personalizada**, la puntuación de **Brier** y la **predeterminada** de *scikit-learn*. En la sección 3.2 se puede encontrar toda la información detallada de las distintas métricas.

Una vez decididas las puntuaciones a emplear para evaluar los algoritmos se realiza un estudio de cada uno siguiendo los siguientes pasos:

1. **Curvas de aprendizaje**: primero de todo se dibujan las curvas de aprendizaje de cada clasificador para así observar si se beneficia o no de añadir más datos de entrenamiento y decidir una cantidad de datos a utilizar posteriormente.
2. **Curvas de validación**: mediante el uso de curvas de validación sobre los parámetros del clasificador que no dependen de otros se escogen los más adecuados evitando el sobreajuste (overfitting) y el sesgo (underfitting).

3. **Validación cruzada:** cuando múltiples parámetros del clasificador influyen entre ellos en la clasificación se realiza una validación cruzada anidada basada en el ejemplo de *scikit-learn* [6]. Al realizar la validación se exploran los distintos parámetros del clasificador posibles y se busca la combinación de todos ellos que optimiza tanto la métrica personalizada como la puntuación de Brier.
4. **Interpretación de resultados:** tras obtener los datos de la validación cruzada se comparan y se escogen los mejores parámetros del clasificador para extraer las puntuaciones finales.
5. **Reducción del número de características:** ya con el clasificador decidido se estudia la reducción del número de características. Se determina la importancia de las mismas basándose en la velocidad de extracción y en la importancia para el clasificador (en caso de que la proporcione).

Para finalizar se comparan los distintos algoritmos clasificadores teniendo en cuenta tanto la velocidad de predicción como la precisión del mismo. Todos estos análisis se pueden encontrar en el Anexo D.

2.5. Planificación temporal de las tareas

En cuanto al coste temporal del proyecto se estableció una primera estimación de las tareas a realizar durante cada quincena. Aunque surgieron contratiempos debido a la falta de experiencia en el ámbito de la minería de datos y *Python*, se solventaron con facilidad gracias a aplicar metodologías de desarrollo ágil.

En principio se pretendía repartir las tareas en las seis quincenas de la siguiente manera:

- **Primera quincena:** adaptación a *Python* y aprendizaje de las librerías de minería de datos a emplear como *numpy*, *pandas* y *scikit-learn*. Además aprender los detalles de funcionamiento de *Blosc* y su paquete para *Python*.
- **Segunda quincena:** desarrollo del programa generador de datos de las pruebas de compresión con *Blosc* sobre distintos ficheros.
- **Tercera quincena:** análisis descriptivo de los datos de compresión obtenidos para automatizar la generación de informes para ficheros específicos bajo demanda y familiarizarse con las librerías de *pandas* y *matplotlib*.
- **Cuarta quincena:** generación de los datos de entrenamiento finales a utilizar por los distintos algoritmos de aprendizaje automatizado.

- **Quinta y sexta:** análisis de los distintos algoritmos de aprendizaje automatizado y comparación entre ellos teniendo en cuenta la efectividad de los mismos y la velocidad de predicción.

Durante el desarrollo se mantuvo la planificación originalmente estimada, pero se realizaron pequeñas modificaciones de manera constante sobre tareas que ya se habían realizado. Esto se debió a que en muchas ocasiones al hacer las tareas de análisis de los datos generados se observaban detalles que no se habían considerado anteriormente, por lo que se refinaban y repetían las generaciones de datos de manera constante cada semana. Por ejemplo, al realizar el análisis descriptivo se plantearon nuevas características a extraer en las pruebas de compresión, como el número de rachas y el tipo de los datos, por lo que se tuvieron que generar los datos de nuevo.

Cabe destacar que la generación de datos de las pruebas de compresión era un proceso costoso, por lo que para evitar retrasar el proyecto se seguía avanzando con los datos anteriores y durante el fin de semana se lanzaba el programa generador de datos en una máquina remota, para a principios de semana tener los datos actualizados.

2.6. Grado de consecución de los objetivos propuestos

Con respecto a los objetivos propuestos se han cumplido casi en su totalidad, a excepción de la implementación final del algoritmo dentro de la librería *Blosc*. Por una parte se ha desarrollado un proceso de análisis del funcionamiento de *Blosc* consiguiendo determinar características estadísticas influyentes en el proceso de compresión de datos.

Por otro lado se ha comparado el comportamiento de diferentes tipos de algoritmos clasificadores de aprendizaje automatizado evaluándolos según los aspectos más relevantes, que en este caso son la precisión y la velocidad de predicción. A partir de aquí solo queda seleccionar el algoritmo que más se adecue y extraer su fórmula de predicción para su posterior implementación en *Blosc*.

Cabe destacar que se ha aprendido a utilizar diferentes técnicas de minería de datos por medio del lenguaje de programación *Python* y además se ha automatizado todo este proceso de análisis permitiendo que se pueda repetir para otros datos. Finalmente destacar que como el tipo de clasificación es bastante complejo sería recomendable repetir todo el proceso con más datos para evitar el sobreajuste a los datos de entrenamiento utilizados.

2.7. Conclusiones

Como conclusiones de mi estancia en prácticas con el consultor Francesc Alted, he tenido una primera experiencia laboral bastante satisfactoria. He aprendido nuevas técnicas y metodologías de la minería de datos y además, ha sido utilizando herramientas de desarrollo de software punteras en la ciencia de datos. Destacar que en todo momento me he sentido apoyado por mi supervisor y tutor, el primero ayudándome en todos los aspectos relacionados con la programación en *Python* y el segundo orientándome en las metodologías propias de la minería de datos.

En definitiva ha sido una excelente estancia en prácticas donde he desarrollado mis habilidades de programación y de análisis de datos, lo cual se adapta perfectamente al doble grado de Ingeniería Informática y Matemática Computacional.

Capítulo 3

Algoritmos clasificadores de aprendizaje automatizado

3.1. Motivación y objetivos

Durante los últimos años la minería de datos se ha convertido en uno de los campos más demandados dentro de las ciencias aplicadas a los computadores. Esto se debe a la aparición de nuevos dispositivos y conceptos como el Internet de las cosas (*Internet of Things*, abreviado *IoT*) que han aumentado la generación de datos de forma exponencial llegando al punto en que el 90 % de los datos actuales han sido generados en los últimos dos años [12].

Estos datos se han estructurado desde los comienzos de la era digital en dispositivos de almacenamiento de muchas maneras: bases de datos, hojas de cálculo, ficheros de registro, páginas web, etc. Gracias a esto posteriormente se pueden realizar consultas sobre los datos como por ejemplo ”¿Cuántos clientes son mayores de 30 años?”, algo que sin duda alguna resulta útil, pero los datos contienen mucha más información que no se encuentra a simple vista y es aquí donde la minería de datos entra en juego.

El principal objetivo de la minería de datos es extraer información de un conjunto de datos y transformarlo en una estructura interpretable para uso posterior. Esto se consigue mediante la aplicación de técnicas de inteligencia artificial y estadística.

Aunque la minería de datos abarca muchas otras utilidades, este trabajo se centra en la clasificación supervisada o técnicas de aprendizaje automatizado, a través de las cuales se pretende que el ordenador aprenda a reconocer patrones en los datos sin ser explícitamente programado. En los problemas de clasificación supervisada se pretende a partir de las variables descriptivas o

características observadas en los objetos de la muestra, inferir la variable respuesta u objetivo. La muestra queda estructurada de la siguiente manera:

$$X = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} \quad Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

siendo n el tamaño de la muestra, p el número de características, x_{ij} el valor observado de la característica j -ésima en el objeto i -ésimo, $y_i = (y_{i1}, \dots, y_{iR})$ la clase del objeto i -ésimo (multivariante) y R es el número de variables que componen y . A partir de aquí la muestra se divide en dos partes una de validación de tamaño N y otra de entrenamiento de tamaño $n - N$. Las técnicas de aprendizaje automatizado son entrenadas con la muestra de entrenamiento y posteriormente aplican sus reglas para transformar variables $x_{i1}, x_{i2}, \dots, x_{ip}$ en un valor objetivo y_i que se comprueba con la muestra de validación.

A continuación se explican los métodos de clasificación supervisada o de aprendizaje automatizado que se han utilizado a lo largo del proyecto los cuales son: análisis discriminante, regresión multinomial, bosques aleatorios, vecinos más próximos y máquinas de vector soporte. Hay que comentar que de ellos ya se conocía el análisis discriminante estudiado en la asignatura *MT1033 - Fundamentos Estadísticos de la Minería de Datos* y en cuanto al resto, se ha realizado una búsqueda bibliográfica cuyo estudio ha permitido profundizar en ellos.

Los contenidos teóricos relacionados con los métodos de clasificación que se describen a continuación han sido extraídos mayoritariamente del libro de Daniel Peña, *Análisis de Datos Multivariantes* [11] y del libro *The Elements of Statistical Learning* de Trevor Hastie [7].

3.2. Métricas de puntuación

Antes de comenzar a hablar de los métodos de clasificación vamos a comentar un ingrediente importante en la aplicación práctica de estos métodos, se trata de la forma de evaluar la calidad de las predicciones. Aunque en muchos casos puede resultar sencillo, como por ejemplo, en una clasificación binaria se puede contar el porcentaje de aciertos y es fácil de interpretar, en el caso estudiado no es tan fácil. Esto se debe a que son cuatro variables distintas cada una de clasificación múltiple (multiclas) por tanto si se miden los aciertos totales (sobre las 4 variables) el porcentaje de aciertos es muy bajo y no aporta información relevante. Además en el caso de las variables del nivel de compresión y el tamaño de bloque se desea ser más permisivo, errar por una diferencia de 2 en el nivel de compresión no es extremadamente malo. Una **métrica de puntuación** es una función que mide la precisión o el error de un método de clasificación sobre

una muestra de validación. Para mantener el criterio de que una puntuación mayor es mejor, en el caso de medir el error se utilizará el valor en negativo. La siguiente ecuación representa una **métrica de puntuación** genérica:

$$f = \frac{1}{N} \sum_{t=1}^N \sum_{j=1}^R f_j(\hat{y}_{tj}, y_{tj})$$

donde N es el tamaño de la muestra de validación, R el número de variables objetivo, f_j es la función de puntuación de la variable j -ésima, \hat{y}_{tj} es el valor predicho de la variable j -ésima en la observación t e y_{tj} el valor real. Para el estudio realizado se han empleado las siguientes **métricas de puntuación**,

- **Predeterminada:** aunque la **puntuación predeterminada** sea muy restrictiva igualmente se considera a la hora de evaluar los algoritmos de clasificación. Además, también se tiene en cuenta por separado para cada variable objetivo para ayudar a interpretar los resultados finales. Esta métrica es un valor entre 0 y 1 resultado de contar el número de aciertos y dividirlos por el tamaño de la muestra de validación, y obedece la siguiente fórmula:

$$f = \frac{1}{N} \sum_{t=1}^N \delta_t \quad \delta_t = \begin{cases} 1 & \text{si } \hat{y}_t = y_t \\ 0 & \text{resto} \end{cases}$$

- **Métrica personalizada:** se definió una función para puntuar los aciertos de forma que tuviese en cuenta niveles de compresión y tamaños de bloque cercanos casi como aciertos. Básicamente la puntuación es un valor entre 0 y 1 que se calcula de la siguiente forma: si se acierta el códec y el filtro se suma 0,5 y después tanto en el nivel de compresión como en el tamaño de bloque se calcula un valor entre 0 y 0,25 en función de la diferencia entre la predicción y el dato real. La fórmula que define esta métrica se encuentra en la Ec. (3.1)

$$f = \frac{1}{N} \sum_{t=1}^N 0,5 \delta_{ts_1} + f_s(\hat{y}_{ts_2}, y_{ts_2}) + f_s(\hat{y}_{ts_3}, y_{ts_3}) \quad (3.1)$$

donde s_1 representa las clases del códec y filtro, s_2 las clases de los niveles de compresión, s_3 las clases del tamaño de bloque y

$$f_s(\hat{y}_{ts}, y_{ts}) = 0,25 \frac{(8 - |\hat{y}_{ts} - y_{ts}|)^2}{8^2}$$

siendo 8 es la máxima distancia posible entre dos niveles de compresión o tamaños de bloque.

- **Puntuación de Brier:** en este caso se adaptó la función de puntuación propuesta por Glenn W. Brier en 1950 [5] al problema de variable objetivo multidimensional. Esta puntuación pretende medir el error de las probabilidades de clasificación y sólo se puede

aplicar si el método de clasificación lo permite. En la función 3.2 podemos observar dicha adaptación.

$$f = -\frac{1}{N} \sum_{t=1}^N \sum_{k=1}^R \sum_{j=1}^{r_k} (\hat{p}_{tj} - y_{tj})^2 \quad (3.2)$$

donde r_k es el número de clases de la variable k -ésima, \hat{p}_{tj} es la probabilidad predicha de que pertenezca a la clase número j y y_{tj} es el valor real de la variable objetivo, es decir, un 1 o 0 según si pertenece o no a la clase j . Se utiliza el valor en negativo dado que mide el error y se quiere mantener el criterio de que cuanto mayor sea el valor en la puntuación mejor sea resultado.

3.3. Análisis discriminante lineal

El método de clasificación conocido como análisis discriminante lineal puede plantearse desde dos puntos de vista: uno estadístico y otro geométrico. El planteamiento estadístico del problema consiste en considerar una muestra donde cada observación puede venir de dos o más poblaciones distintas. Cada observación se corresponde a una variable aleatoria x de dimensión p , cuya distribución se conoce en los distintos grupos considerados. El análisis discriminante se fundamenta en el supuesto de que las variables de las observaciones siguen el modelo normal multivariante y es óptimo en caso de cumplirse. A continuación se describe el método de clasificación para el caso más sencillo entre dos poblaciones que posteriormente se generalizará para múltiples grupos.

3.3.1. Clasificación entre dos poblaciones

Planteamiento

Sean P_1 y P_2 dos poblaciones distintas de una variable aleatoria vectorial x , p -variante. Donde x es continua y se conocen las funciones de densidad de las poblaciones f_1 , f_2 . Ahora, dado un nuevo elemento x_0 con valores conocidos de sus p variables se pretende clasificar en una de las dos poblaciones. Si se conocen las probabilidades a priori π_1 , π_2 , con $\pi_1 + \pi_2 = 1$, de que el elemento pertenezca a una de las poblaciones, su distribución de probabilidad es

$$f(x) = \pi_1 f_1(x) + \pi_2 f_2(x)$$

y conocido x_0 se pueden calcular las probabilidades de que haya sido generado por cada una de las poblaciones por medio del teorema de Bayes. Estas son:

$$P(1|x_0) = \frac{f_1(x_0)\pi_1}{\pi_1f_1(x_0) + \pi_2f_2(x_0)} \quad P(2|x_0) = \frac{f_2(x_0)\pi_2}{\pi_1f_1(x_0) + \pi_2f_2(x_0)}$$

Se clasificará x_0 en la población más probable, por tanto se clasificará en P_2 si:

$$\pi_2f_2(x_0) > \pi_1f_1(x_0)$$

Además si se puede cuantificar el coste de errar al clasificar en la población contraria, nombrando este coste como $c(2|1)$ y $c(1|2)$, donde $c(i|j)$ es el coste de clasificación en P_i de una unidad que pertenece a P_j . Para minimizar el error se cambia la regla de clasificación anterior de la siguiente manera, se clasificará en P_2 si:

$$\frac{\pi_2f_2(x_0)}{c(2|1)} > \frac{\pi_1f_1(x_0)}{c(1|2)} \quad (3.3)$$

Ahora la desigualdad expresa que, a igualdad del resto de términos, se clasificará en la población P_2 si

- su probabilidad inicial π_2 es más alta
- si la verosimilitud de que x_0 venga de P_2 es más alta
- el coste de error al clasificar en P_2 es menor

Obtención de la función discriminante lineal

Aquí se aplica el planteamiento anterior al caso en que f_1 y f_2 siguen distribuciones normales con distintos vectores de medias pero misma matriz de covarianzas. Por tanto las funciones de densidad para un elemento cualquiera x son:

$$f_i(x) = \frac{e^{-\frac{1}{2}(x-\mu_i)'V^{-1}(x-\mu_i)}}{(2\pi)^{p/2}|V|^{1/2}}$$

Sustituyendo en la Ec. 3.3 se obtiene:

$$\begin{aligned} \frac{e^{-\frac{1}{2}(x-\mu_2)'V^{-1}(x-\mu_2)}}{(2\pi)^{p/2}|V|^{1/2}c(2|1)}\pi_2 &> \frac{e^{-\frac{1}{2}(x-\mu_1)'V^{-1}(x-\mu_1)}}{(2\pi)^{p/2}|V|^{1/2}c(1|2)}\pi_1 \implies \\ \log \frac{e^{-\frac{1}{2}(x-\mu_2)'V^{-1}(x-\mu_2)}}{c(2|1)}\pi_2 &> \log \frac{e^{-\frac{1}{2}(x-\mu_1)'V^{-1}(x-\mu_1)}}{c(1|2)}\pi_1 \end{aligned}$$

Por tanto, clasificamos x en P_2 si

$$-\frac{1}{2}(x - \mu_2)'V^{-1}(x - \mu_2) + \log \frac{\pi_2}{c(2|1)} > -\frac{1}{2}(x - \mu_1)'V^{-1}(x - \mu_1) + \log \frac{\pi_1}{c(1|2)} \quad (3.4)$$

Nombrando D_i^2 a la distancia de Mahalanobis entre x y la media de la población i , μ_i :

$$D_i^2 = (x - \mu_i)'V^{-1}(x - \mu_i)$$

se reescribe la regla de clasificación como: clasificar x en P_2 si

$$D_i^2 - \log \frac{\pi_1}{c(1|2)} > D_2^2 - \log \frac{\pi_2}{c(2|1)} \quad (3.5)$$

Destacar que en el caso en que costes de error y probabilidades a priori son las mismas, $c(1|2) = c(2|1)$; $\pi_1 = \pi_2$, la regla se reduce a: **clasificar en P_2 si $D_1^2 > D_2^2$** . Es decir clasificar en la población más cercana midiendo con la distancia de Mahalanobis. Además si $V = I\sigma^2$, la regla equivale a utilizar la **distancia euclídea**.

Interpretación geométrica

Para poder interpretar geométricamente la regla de clasificación anterior, se reescribe la Ec. 3.5 eliminando el término en común $x'V^{-1}x$, que no depende de la población, de las distancias de Mahalanobis.

$$\cancel{\frac{1}{2}x'V^{-1}x} - \mu_i'V^{-1}x + \frac{1}{2}\mu_i'V^{-1}\mu_i - \log \frac{\pi_i}{c(i|j)}$$

Por tanto la frontera de separación en la clasificación es:

$$-\mu_1'V^{-1}x + \frac{1}{2}\mu_1'V^{-1}\mu_1 = -\mu_2'V^{-1}x + \frac{1}{2}\mu_2'V^{-1}\mu_2 - \log \frac{c(1|2)\pi_2}{c(2|1)\pi_1}$$

que, reescrita como función de x se convierte en:

$$(\mu_2 - \mu_1)'V^{-1}x = (\mu_2 - \mu_1)'V^{-1}\left(\frac{\mu_2 + \mu_1}{2}\right) - \log \frac{c(1|2)\pi_2}{c(2|1)\pi_1}$$

Para simplificar definimos

$$w = V^{-1}(\mu_2 - \mu_1) \quad (3.6)$$

de forma que la frontera queda como

$$w'x = w'\left(\frac{\mu_2 + \mu_1}{2}\right) - \log \frac{c(1|2)\pi_2}{c(2|1)\pi_1}$$

que es la **ecuación del hiperplano** que tiene como vector normal a w .

En el caso de que $c(1|2)\pi_2 = c(2|1)\pi_1$ x se clasificará en P_2 si

$$w'x > w'\left(\frac{\mu_2 + \mu_1}{2}\right) \iff w'x - w'\mu_1 > w'\mu_2 - w'x$$

Dividiendo a ambos lados por la norma de w , obtenemos $u = w/\|w\|$, el vector unitario, de forma que $u'x$ es la proyección de x en la recta de dirección u y $u'\mu_i$ las proyecciones de las medias. Como se observa en la Fig. 3.1 el hiperplano divide las poblaciones de forma que las proyecciones en la recta están lo más separadas posibles.

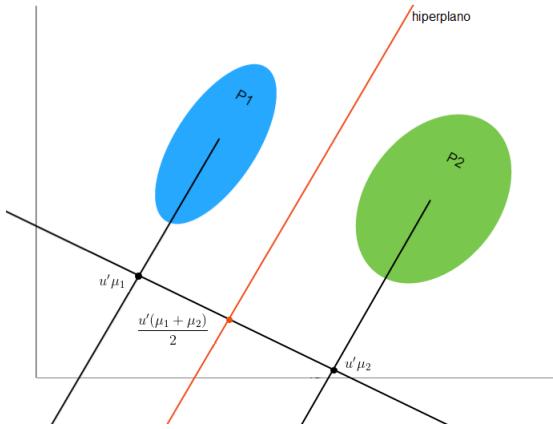


Figura 3.1: Representación del hiperplano y proyecciones que dividen dos poblaciones

3.3.2. Generalización para varias poblaciones

El objetivo ahora es dividir el espacio E_x en G regiones $A_1, \dots, A_g, \dots, A_G$ tales que si x pertenece a A_i el punto se clasifica en la población P_i . Entonces, A_g queda definida por los puntos con máxima probabilidad de ser generados por P_g :

$$A_g = \{x \in E_x | \pi_g f_g(x) > \pi_i f_i(x) \quad \forall i \neq g\}$$

Esto en el caso de que las probabilidades π_i sean iguales, y las distribuciones $f_i(x)$ sean normales con misma matriz de varianzas, equivale a calcular la distancia de Mahalanobis del punto a clasificar al centro de cada población y asignarle la población más cercana. Para minimizar las

distancia de Mahalanobis $(\mathbf{x} - \boldsymbol{\mu}_g)' \mathbf{V}^{-1} (\mathbf{x} - \boldsymbol{\mu}_g)$, se elimina el termino $\mathbf{x}' \mathbf{V}^{-1} \mathbf{x}$ que aparece en todas las ecuaciones y se minimiza el indicador lineal

$$L_g(x) = -2\boldsymbol{\mu}_g' \mathbf{V}^{-1} x + \boldsymbol{\mu}_g' \mathbf{V}^{-1} \boldsymbol{\mu}_g$$

definiendo $\mathbf{w}_g = \mathbf{V}^{-1} \boldsymbol{\mu}_g$, la regla se queda en

$$\min_g (\mathbf{w}_g' \boldsymbol{\mu}_g - 2\mathbf{w}_g' x)$$

Para interpretarla se observa la frontera entre dos poblaciones (i, j)

$$\begin{aligned} A_{ij}(x) &= L_i(x) - L_j(x) = 0 \quad \Rightarrow \\ A_{ij}(x) &= 2(\boldsymbol{\mu}_i - \boldsymbol{\mu}_j)' \mathbf{V}^{-1} x + (\boldsymbol{\mu}_i - \boldsymbol{\mu}_j)' \mathbf{V}^{-1} (\boldsymbol{\mu}_i + \boldsymbol{\mu}_j) = 0 \end{aligned}$$

llamando $\mathbf{w}_{ij} = \mathbf{V}^{-1}(\boldsymbol{\mu}_i - \boldsymbol{\mu}_j) = \mathbf{w}_i - \mathbf{w}_j$, se puede escribir la frontera que separa las poblaciones P_i, P_j como:

$$\mathbf{w}_{ij}' x = \mathbf{w}_{ij}' \left(\frac{\boldsymbol{\mu}_i + \boldsymbol{\mu}_j}{2} \right)$$

La interpretación es la misma que con dos poblaciones.

Además para G poblaciones basta con encontrar

$$r = \min(G - 1, p)$$

direcciones de proyección. Aunque se pueden construir $G(G - 1)/2$ vectores \mathbf{w}_{ij} a partir de las G medias con $G - 1$ vectores los demás son linealmente dependientes de estos. Sean los $G - 1$ vectores $\mathbf{w}_{i,i+1}$, para $i = 1, \dots, G - 1$ a partir de estos se puede definir cualquier $\mathbf{w}_{i,j}$. Por ejemplo

$$\mathbf{w}_{i,i+2} = \mathbf{V}^{-1}(\boldsymbol{\mu}_i - \boldsymbol{\mu}_{i+2}) = \mathbf{V}^{-1}(\boldsymbol{\mu}_i - \boldsymbol{\mu}_{i+1}) - \mathbf{V}^{-1}(\boldsymbol{\mu}_{i+1} - \boldsymbol{\mu}_{i+2}) = \mathbf{w}_{i,i+1} - \mathbf{w}_{i+1,i+2}$$

Por tanto, si $p > G - 1$ el número máximo de vectores w es $G - 1$ ya que el resto se deducen de estos y cuando $p \leq G - 1$ como son vectores de \mathbb{R}^p el máximo número de vectores linealmente independientes es p .

En el libro de Peña [11] podemos ver que esto es equivalente a utilizar los vectores propios u_k ; $k = 1, \dots, r$ de la matriz $\mathbf{W}^{-1} \mathbf{B}$, donde

$$\mathbf{W} = \frac{\sum_{g=1}^G \sum_{i=1}^{n_g} (x_i^{(g)} - \boldsymbol{\mu}_g)(x_i^{(g)} - \boldsymbol{\mu}_g)'}{n - G} \quad \mathbf{B} = \frac{\sum_{g=1}^G n_g (\boldsymbol{\mu}_g - \boldsymbol{\mu})(\boldsymbol{\mu}_g - \boldsymbol{\mu})'}{G - 1}$$

n_g es el tamaño del grupo g -ésimo y $x_i^{(g)}$ es la observación i -ésima del grupo g -ésimo. Con los vectores propios se construye la matriz U que contiene en columnas los vectores propios de $\mathbf{W}^{-1} \mathbf{B}$ y se calculan las proyecciones de cada $\boldsymbol{\mu}_g$; $g = 1, \dots, G$ como $z_{\boldsymbol{\mu}_g} = U' \boldsymbol{\mu}_g$. Finalmente para clasificar una observación x_0 se calcula $z_0 = U' x_0$ y se clasifica en el grupo g cuya distancia entre z_0 y $z_{\boldsymbol{\mu}_g}$ sea mínima.

3.4. Regresión multinomial

En la anterior sección se ha mostrado como el análisis discriminante permite clasificar adecuadamente datos cuando la distribución conjunta de las observaciones es normal multivariante. Sin embargo, en muchos casos los datos no son normales, por lo que no hay garantías de que el análisis discriminante funcione correctamente. En este apartado introducimos un método alternativo que considera la variable objetivo y , como variable respuesta binaria y aplica un modelo de regresión sobre la misma.

3.4.1. Regresión logística

Como en la anterior sección abordaremos el problema de clasificación entre dos poblaciones y posteriormente lo extenderemos para múltiples. Para este modelo definimos pues la variable de clasificación y , que será 0 cuando pertenece a la primera población P_1 y 1 cuando pertenece a la segunda P_2 . Por tanto, la muestra estará formada por n elementos del tipo (x_i, y_i) , siendo x_i el vector de características e y_i la variable binaria objetivo. Como primera idea se podría formular un modelo de regresión lineal:

$$y = \beta_0 + \beta'_1 x + \varepsilon \quad \varepsilon \sim N(0, 1)$$

que como se puede observar en el Apéndice 13.2 del libro de Daniel Peña [11], equivaldría a la función lineal discriminante con $c(1|2) = c(2|1); \pi_1 = \pi_2$ Ec. 3.5.

Tomando esperanzas para $x = x_i$:

$$E[y|x_i] = \beta_0 + \beta'_1 x_i \quad (3.7)$$

si p_i es la probabilidad de que y tome el valor 1 cuando $x = x_i$:

$$p_i = P(y = 1|x_i)$$

como la variable y es de Bernoulli, con probabilidades p_i y $1 - p_i$ para los valores uno y cero, respectivamente, su esperanza será:

$$E[y|x_i] = p_i \cdot 1 + (1 - p_i) \cdot 0 = p_i \quad (3.8)$$

e igualando 3.7 con 3.8 se obtiene:

$$p_i = \beta_0 + \beta'_1 x_i \quad (3.9)$$

Sin embargo, al estimar el modelo lineal 3.7, las predicciones de \hat{y}_i (es decir, \hat{p}_i por Ec. 3.9) no se garantiza que estén entre cero y uno, lo cual supone un problema para interpretar la regla

de clasificación. Para que el modelo proporcione directamente la probabilidad de pertenecer a cada población se debe transformar la variable de respuesta para limitarla entre cero y uno. Escribiendo:

$$p_i = F(\beta_0 + \beta'_1 x_i)$$

como se busca p_i entre cero y uno se busca F que sea no decreciente y acotada entre cero y uno, esto se corresponde con las funciones de distribución. Aunque se puede escoger entre varias funciones de distribución viables se detallará únicamente el modelo utilizando la función de distribución logística F dada por:

$$p_i = \frac{1}{1 + e^{-\beta_0 - \beta'_1 x_i}}$$

Esta función es muy ventajosa por la continuidad y por la siguiente propiedad:

$$\begin{aligned} 1 - p_i &= \frac{e^{-\beta_0 - \beta'_1 x_i}}{1 + e^{-\beta_0 - \beta'_1 x_i}} = \frac{1}{1 + e^{\beta_0 + \beta'_1 x_i}} \quad \Rightarrow \\ g_i &= \log \frac{p_i}{1 - p_i} = \beta_0 + \beta'_1 x_i \end{aligned} \tag{3.10}$$

la variable *Logit* g , representa en escala logarítmica la diferencia entre las probabilidades de pertenecer a ambas poblaciones. Además al ser una función lineal de las variables explicativas facilita la estimación e interpretación del modelo.

Estimación del modelo por MV

Como la variable y es de tipo Bernoulli, la función de probabilidad para y_i cualquiera es:

$$P(y_i) = p_i^{y_i} (1 - p_i)^{1-y_i}$$

y para la muestra:

$$P(y_1, \dots, y_n) = f(y_1) \cdot f(y_2) \cdot \dots \cdot f(y_n) = \prod_{i=1}^n p_i^{y_i} (1 - p_i)^{1-y_i}$$

A continuación se toman logaritmos y se simplifica:

$$\begin{aligned} \log P(y_1, \dots, y_n) &= \log \left(\prod_{i=1}^n p_i^{y_i} (1-p_i)^{1-y_i} \right) = \sum_{i=1}^n \log(p_i^{y_i} (1-p_i)^{1-y_i}) = \\ \sum_{i=1}^n (y_i \log p_i + (1-y_i) \log(1-p_i)) &= \sum_{i=1}^n (y_i \log p_i + \log(1-p_i) - y_i \log(1-p_i)) = \\ \sum_{i=1}^n \left[y_i \log \left(\frac{p_i}{1-p_i} \right) + \log(1-p_i) \right] \end{aligned}$$

Teniendo en cuenta 3.10 y la siguiente igualdad

$$1 - p_i = \frac{1}{1 + e^{\beta_0 + \beta_1' x_i}}$$

se deja la expresión en función de los parámetros de interés β :

$$L(\beta) = \sum_{i=1}^n y_i \mathbf{x}_i' \beta - \log(1 - p_i)^{-1} = \sum_{i=1}^n y_i \mathbf{x}_i' \beta - \sum_{i=1}^n \log(1 + e^{\mathbf{x}_i' \beta})$$

Ahora con la función soporte $L(\beta)$, puesto que la función de verosimilitud es siempre cóncava, para obtener los estimadores de máxima verosimilitud se deriva e iguala a cero para buscar el máximo:

$$\begin{aligned} \frac{\partial L(\beta)}{\partial \beta} &= \sum_{i=1}^n y_i \mathbf{x}_i - \sum_{i=1}^n \mathbf{x}_i \left(\frac{e^{\mathbf{x}_i' \beta}}{1 + e^{\mathbf{x}_i' \beta}} \right) = \sum_{i=1}^n \mathbf{x}_i \left(y_i - \frac{1}{1 + e^{-\mathbf{x}_i' \beta}} \right) = 0 \implies \\ \sum_{i=1}^n y_i \mathbf{x}_i &= \sum_{i=1}^n \mathbf{x}_i \hat{p}_i \implies \sum_{i=1}^n \mathbf{x}_i (y_i - \hat{p}_i) = 0 \end{aligned} \tag{3.11}$$

Como no se puede obtener una solución analítica para el valor de $\hat{\beta}_{MV}$ se recurre a un algoritmo tipo *Newton-Raphson*. Desarrollando el vector $(\partial L(\beta)/\partial \beta)$ alrededor de un punto β_a , se tiene

$$\frac{\partial L(\beta)}{\partial \beta} = \frac{\partial L(\beta_a)}{\partial \beta} + \frac{\partial^2 L(\beta_a)}{\partial \beta \partial \beta'} (\beta - \beta_a)$$

para que el punto β_a , corresponda al máximo de verosimilitud su primera derivada debe anularse. Con la condición $\partial L(\beta_a)/\partial \beta = 0$, se tiene que

$$\beta_a = \beta + \left(\frac{\partial^2 L(\beta_a)}{\partial \beta \partial \beta'} \right)^{-1} \left(\frac{\partial L(\beta)}{\partial \beta} \right) \tag{3.12}$$

esta expresión muestra como obtener el punto máximo β_a , a partir de un punto próximo cualquiera β . Esta depende de la matriz de segundas derivadas que, en el óptimo, es la inversa de la matriz de covarianzas asintótica de los estimadores MV. Su expresión se obtiene derivando la expresión 3.11:

$$\hat{M}^{-1} = \left(\frac{\partial^2 L(\beta_a)}{\partial \beta \partial \beta'} \right) = \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i w_i \quad (3.13)$$

donde

$$w_i = \frac{e^{\mathbf{x}'_i \beta}}{(1 + e^{\mathbf{x}'_i \beta})^2} = p_i(1 - p_i)$$

Reemplazando en 3.12 con las expresiones de 3.13 y 3.11 se obtiene el siguiente método para obtener un nuevo estimador $\hat{\beta}_{k+1}$ a partir de un estimador inicial $\hat{\beta}_k$

$$\hat{\beta}_{k+1} = \hat{\beta}_k + \left(\sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i \hat{w}_i \right)^{-1} \left(\sum_{i=1}^n \mathbf{x}_i (y_i - \hat{p}_i) \right)$$

donde \hat{p}_i y \hat{w}_i se calculan con el estimador inicial $\hat{\beta}_k$. El método puede reescribirse como:

$$\hat{\beta}_{k+1} = \hat{\beta}_k + \left(X' \hat{W} X \right)^{-1} X' (Y - \hat{Y}) \quad (3.14)$$

donde \hat{W} es una matriz diagonal con términos $\hat{p}_i(1 - \hat{p}_i)$. A partir de aquí se escoge un valor inicial $\hat{\beta}_0$ y se itera hasta que el método converge aunque no está garantizado.

3.4.2. Generalización para G poblaciones: regresión multinomial

Para este caso se plantea el modelo *logit* para G poblaciones, entonces p_{ig} es la probabilidad de que la observación i pertenezca a la clase g , se puede escribir:

$$p_{ig} = \frac{e^{\beta_{0g} + \beta'_{1g} \mathbf{x}_i}}{1 + \sum_{j=1}^{G-1} e^{\beta_{0j} + \beta'_{1j} \mathbf{x}_i}} \quad j = 1, \dots, G-1$$

y

$$p_{iG} = \frac{1}{1 + \sum_{j=1}^{G-1} e^{\beta_{0j} + \beta'_{1j} \mathbf{x}_i}} \quad j = 1, \dots, G-1$$

con esto se garantiza que $\sum_{g=1}^G p_{ig} = 1$. La comparación entre dos categorías se realiza de la manera esperada

$$\frac{p_{ig}}{p_{ij}} = \frac{e^{\beta_{0g} + \beta'_{1g} \mathbf{x}_i}}{e^{\beta_{0j} + \beta'_{1j} \mathbf{x}_i}} = e^{(\beta_{0g} - \beta_{0j})} e^{(\beta'_{1g} - \beta'_{1j}) \mathbf{x}_i}$$

Por lo que respecta a la estimación de estos modelos son extensiones del desarrollo del anterior apartado y no se entrará en detalles.

3.5. Árboles de decisión

Los árboles de decisión son un modelo predictivo en forma de grafo tipo árbol donde se transforman las variables observadas de un objeto $x_i = (x_{i1}, \dots, x_{ip})$ (representadas por las ramas del árbol) a conclusiones sobre el valor de la variable objetivo y_i a predecir del objeto (representado en las hojas del árbol). Cuando la variable objetivo puede tomar un número finito de valores se les llama árboles de clasificación, las ramas representan decisiones sobre las características y las hojas son clases. Por el contrario cuando la variable objetivo puede tomar valores continuos (números reales) se les llama árboles de regresión. En la Fig. 3.2 se muestra un ejemplo de árbol de decisión.

Basándose en árboles de decisión también se han desarrollado otras técnicas conocidas como métodos de conjuntos (*ensemble methods*) que utilizan varios árboles de decisión internamente. Algunas de estas técnicas son: árboles mejorados (*Boosted Trees*), empaquetado (*Bagging*) y bosques aleatorios (*Random Forest*). En este trabajo se ha experimentado únicamente con los bosques aleatorios.

Además existen varios algoritmos para la construcción de árboles de decisión, siendo los más notables: ID3, C4.5 y CART (Classification And Regression Tree). Dado que los árboles de decisión implementados en *scikit-learn* están basados en CART, a continuación se describe el funcionamiento de dicho algoritmo.

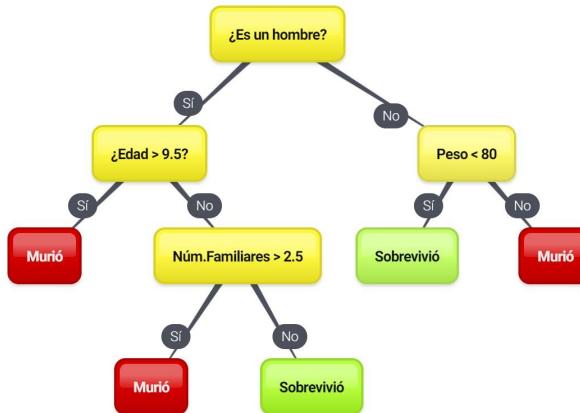


Figura 3.2: Ejemplo de árbol de decisión

3.5.1. Algoritmo CART

Este algoritmo de construcción de árboles de decisión fue introducido por primera vez en 1984 de la mano de Breiman [4]. El procedimiento no se basa en ningún modelo estadístico formal, sino que realiza particiones binarias por medio de los valores de las variables y por tanto se asemeja más al comportamiento de toma de decisiones de un humano.

A partir de los datos de entrenamiento el algoritmo comienza seleccionando una variable x_i para la cual obtiene un punto de corte c , de tal modo que separa los datos según si $x_i \leq c$ o $x_i > c$. De este nudo inicial saldrán dos ramas para cada cual se repetirá el proceso de selección de variables y punto de corte, volviendo a dividir los datos en dos en cada rama. El procedimiento se repite hasta que se hayan clasificado todas las observaciones en su grupo o cuando se cumplan las condiciones de corte. Para construir el árbol hay que tener en cuenta las siguientes decisiones.

1. Selección de variables y puntos de corte

Para seleccionar la variable que se utilizará para hacer la partición en el nudo actual se calcula primero la proporción de observaciones que pasan por el nudo para cada grupo.

Sea G el número de grupos y $p(g|t)$ las proporciones de las observaciones que llegan al nudo t pertenecientes a cada una de las clases, se define la **impureza** o **entropía** del nudo t como:

$$I(t) = - \sum_{g=1}^G p(g|t) \log p(g|t) \quad (3.15)$$

Esta medida es no negativa y mide la diversidad. Por ejemplo, para $G = 2$ sería:

$$I(t) = -p \log p - (1-p) \log(1-p)$$

El valor que maximizaría la función sería $p = 0,5$ y cuando p se acerca a 0 o a 1 la función se aproxima a 0. Para el caso de G grupos la función se acercará a 0 cuando para algún g , $p(g|t) \approx 1$, por otro lado la función alcanzará su máximo cuando $p(g|t) = \frac{1}{G} \quad \forall g \in G$.

A continuación se considera el conjunto formado por todas las preguntas q posibles del tipo: $\text{¿Es } x_i < a? \quad \forall i = 1, \dots, p$ y $a \in (-\infty, \infty)$. Es decir, el conjunto de todas las posibles divisiones para todas las variables. Para cada pregunta q , en el nodo t , llamamos t_S y t_N a los nudos que surgen de t como consecuencia de responder a la pregunta q con un "Sí" o con un "No", respectivamente se consideran como p_S y p_N las proporciones de observaciones del nudo t resultantes. Llamando $I(t_N)$ e $I(t_S)$ a las correspondientes impurezas, se define el **cambio de entropía** producido tras el nudo t por la pregunta q como:

$$\Delta I(t, q) = I(t) - p_S I(t_S) - p_N I(t_N)$$

Se escoge para cada nodo la pregunta que maximiza el cambio de entropía, es decir, aquella pregunta que maximiza la homogeneidad y por tanto minimiza la entropía en los nudos resultantes (t_S y t_N) tras la partición.

Otra posibilidad, menos utilizada en la práctica, pero que lleva implementada *scikit-learn* es utilizar como medida de impureza Ec. 3.15 el indice de Gini.

$$I_{gini}(t) = \sum_{g=1}^G p(g|t)(1 - p(g|t))$$

2. Determinación de nudos terminales

El proceso anterior debería continuar hasta que se hayan clasificado todas las observaciones correctamente en su grupo, sin embargo, esto puede generar muchos nudos cuando el número de variables es grande y se pueden plantear métodos para simplificar o "podar" el árbol resultante. Un método podría ser establecer un número mínimo de observaciones en el nudo para realizar la división o establecer que pare al alcanzar cierto grado de homogeneidad en el grupo (sin que todas las observaciones sean del mismo grupo). Otra posibilidad es simplemente parar por **máxima profundidad** del árbol, que consiste simplemente en "podar" el árbol a una altura determinada o más bien dejar de entrenarlo más allá de esa altura y establecer la clase de esos últimos grupos por mayoría. Este último método ha sido el utilizado en nuestros análisis.

3. Asignación de grupos a los nudos terminales

Una vez alcanzado el nudo terminal, para determinar su valor, se escoge aquel del que hayan más observaciones que pasen por ese nudo, es decir, $\max p(g|t)$.

3.5.2. Bosques aleatorios

Uno de los principales problemas de los árboles de decisión es el sobreajuste a los datos de entrenamiento. En particular si no se establecen criterios de corte, el árbol siempre se entrena de forma que se adapta perfectamente a los datos de entrenamiento, lo que implica que las predicciones sean sensibles a datos distintos de la muestra de entrenamiento. Por esto surgen los bosques aleatorios que corrigen este tipo de errores y mejoran significativamente la precisión de los árboles.

Los bosques aleatorios son una combinación de árboles de decisión de forma que cada árbol

es generado de forma aleatoria siguiendo el siguiente procedimiento. Cada árbol del bosque formado por B árboles se construye de la siguiente manera:

1. Para cada nudo t del árbol:
 - a) Seleccionar m variables al azar de las p variables.
 - b) Escoger el mejor punto de corte entre las m variables.
 - c) Dividir el nudo en dos.
2. El árbol resultante construido T_b se añade al conjunto de árboles $\{T_b\}_1^B$.

Sea $\hat{C}_b(x)$ la predicción del b -ésimo árbol del bosque aleatorio para la variable objetivo y . Se define la predicción del bosque aleatorio como

$$\hat{C}^B(x) = \text{voto por mayoría}\{\hat{C}_b(x)\}_1^B,$$

de este mismo modo la probabilidad predicha de que x pertenezca a la clase r se define como

$$\hat{P}_r^B(x) = \frac{\text{card}\{T_b \text{ t.q. } \hat{C}_b(x) = r\}_1^B}{B}$$

Otra posibilidad que lleva implementada *scikit-learn* es utilizar una muestra **bootstrap** para construir cada árbol. Una muestra **bootstrap** se obtiene realizando muestreo aleatorio con reemplazamiento de toda la muestra hasta obtener el tamaño de la muestra original.

En el artículo de Breiman, *Random Forests* [3], se demuestra que el error de generalización converge hasta cierto límite al aumentar el número de árboles que forman el bosque, lo cual, explica porque no se sobreajustan a los datos. Finalmente destaca que con este método se consiguen resultados comparables con los métodos de mejora adaptativa (*AdaBoost*), puesto que:

1. Tienen una precisión muy similar o incluso mejor.
2. Es robusto contra el ruido y datos atípicos.
3. Es más rápido que la mejora adaptativa y el empaquetado (*Bagging*).
4. Proporciona estimaciones con probabilidades, útiles para calcular errores, correlaciones e importancia de las características.
5. Es simple y fácil de paralelizar los cálculos.

3.6. Vecinos más próximos

El método de clasificación de los vecinos más próximos destaca por su simplicidad y buenos resultados en poblaciones no normales. El método consiste en:

1. Establecer una medida de distancia entre puntos de la muestra.
2. Calcular las distancias entre el punto que se pretende clasificar, x_0 y el resto de puntos de la muestra.
3. Seleccionar los k puntos (**vecinos**) más próximos de la muestra.
4. Calcular la proporción de los k puntos que pertenece a cada una de las clases.
5. Clasificar el punto x_0 en la clase que tenga mayor proporción de vecinos.

Este método se conoce como k -vecinos más próximos, en el caso de $k = 1$ simplemente se le asigna a cada elemento la clase del vecino más próximo, lo que implica sobreajuste en la clasificación. Por el contrario, si se elige un valor de k excesivamente grande la clasificación estará sobregeneralizada y no acertará en sus predicciones. Por ello el problema clave de este método es encontrar un valor adecuado de k para ello se suele utilizar $k = \sqrt{n_g}$ donde n_g es el tamaño de grupo medio o también se puede probar distintos valores de k dentro de un rango y elegir el que obtenga menor error de clasificación. En la Fig. 3.3 se puede observar la diferencia en las fronteras de los grupos al clasificar con $k = 1$ o $k = 15$.

3.7. Máquinas de vector soporte

Las máquinas de vector soporte, en adelante SVM (Support Vector Machines), es un método que al igual que el análisis discriminante, busca fronteras lineales para separar los datos pero en lugar de buscar una reducción del espacio de los datos para resolver el problema, busca un espacio de dimensión mayor donde los puntos se puedan separar linealmente.

Sea una muestra de n elementos descritos por $x_i \in \mathbb{R}^p$ las características de la observación i e y_i la variable binaria de clasificación con posibles valores -1 y +1 en vez de los habituales cero y uno. El conjunto de n datos será separable de forma lineal si se puede encontrar un vector $w \in \mathbb{R}^p$ que genere un hiperplano que separe perfectamente las observaciones. Por ejemplo, las observaciones de la clase $y_i = -1$ verificarán que $w'x_i + b < -1$, para un determinado escalar b , mientras que las de clase $y_i = 1$ obedecen a $w'x_i + b > 1$. Las dos igualdades presentadas pueden escribirse conjuntamente como:

$$y_i(w'x_i + b) \geq 1 \quad \text{para } i = 1, \dots, n \tag{3.16}$$

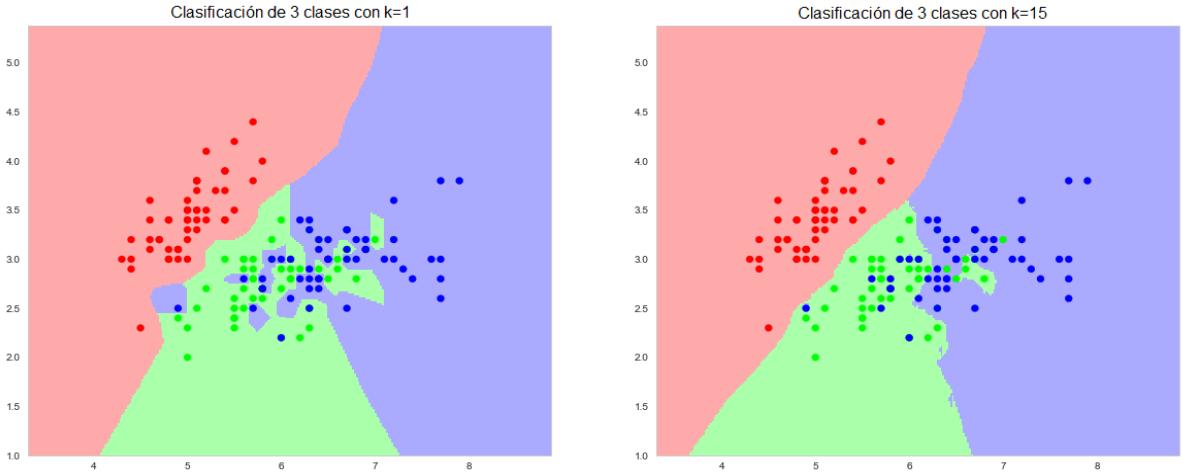


Figura 3.3: Ejemplo de vecinos más próximos con distintos valores de k

Sea

$$f(x_i) = w'x_i + b$$

el valor del hiperplano de separación óptima entre los dos grupos para un punto x_i . La distancia entre un punto x_i y el hiperplano se obtiene mediante la proyección del punto en la dirección w y se calcula mediante $w'x_i/\|w\|$. Como los puntos cumplen $y_i(w'x_i + b) \geq 1$ faltaría maximizar las distancias de los puntos al plano por lo que se busca el máximo de

$$\frac{y_i(w'x_i + b)}{\|w\|} \quad \text{para } i = 1, \dots, n$$

Para que se cumpla esto el numerador tendrá que ser positivo y el denominador mínimo, lo que conduce al siguiente problema de optimización:

$$\begin{aligned} & \text{minimizar } \|w\|^2 \\ & \text{sujeto a } y_i(w'x_i + b) \geq 1, \quad i = 1, \dots, n \end{aligned}$$

En este caso particular el resultado de esta maximización es el mismo vector w de la Ec. 3.6.

Para extender esta idea al caso en que los datos no son separables linealmente (ver Fig. 3.4), se introduce una serie de variables ξ_i en las restricciones que se convierten en:

$$\begin{aligned} w'x_i + b &\geq 1 - \xi_i, \quad \text{para } y_i = 1 \\ w'x_i + b &\geq -1 + \xi_i, \quad \text{para } y_i = -1 \\ \xi_i &\geq 0 \quad \forall i. \end{aligned}$$

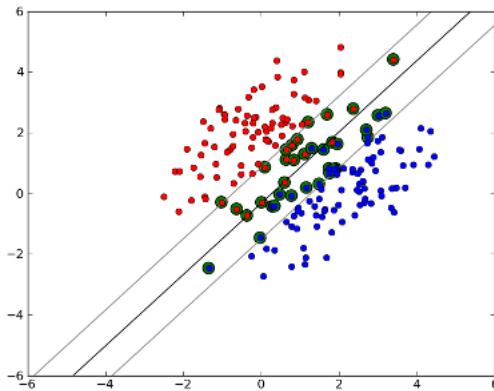


Figura 3.4: Ejemplo clasificador SVM con datos no separables linealmente

Entonces, para que se produzca un error, el correspondiente ξ_i debe exceder la unidad y por tanto $\sum_{i=1}^n \xi_i$ es un límite superior del número total de errores de entrenamiento. De esta forma se modifica la función objetivo a minimizar sumando $C(\sum_{i=1}^n \xi_i)^k$, donde C es un parámetro escogido por el usuario, que se corresponde con la penalización de los errores. Entonces el problema de optimización se transforma en:

$$\begin{aligned} & \text{minimizar } \|w\|^2 + C \left(\sum_{i=1}^n \xi_i \right)^k \\ & \text{sujeto a } y_i(w'x_i + b) \geq 1 - \xi_i \text{ y } \xi_i \geq 0 \quad \forall i. \end{aligned}$$

donde el parámetro C determina el equilibrio entre el tamaño del margen y asegurar que x_i caiga en el lado correcto del margen. Para valores de C lo suficientemente pequeños se comportará igual que en el caso de ser linealmente separables, pero en caso de no poder separarse de forma lineal igualmente aprende una regla de clasificación viable.

Con este planteamiento, se trata de un problema de programación convexa para cualquier entero positivo k ; para $k = 2$ y $k = 1$ es además un problema de programación cuadrática con la particularidad de que con $k = 1$ resolviendo por la dualidad de Lagrange se obtiene el problema simplificado

$$\begin{aligned} & \text{maximizar } f(\alpha_1 \dots \alpha_n) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i \alpha_i (x_i x_j) y_j \alpha_j \quad (3.17) \\ & \text{sujeto a } \sum_{i=1}^n \alpha_i y_i = 0, \text{ y } 0 \leq \alpha_i \leq C \quad \forall i \end{aligned}$$

como el problema es una función cuadrática de α_i sujeta a restricciones lineales se puede resolver por medio de algoritmos de programación cuadráticos. Las variables α_i se definen de forma que

$$w = \sum_{i=1}^n \alpha_i y_i x_i$$

además, $\alpha_i = 0$ cuando x_i cae en el lado correcto del margen y $0 \leq \alpha_i \leq C$ cuando x_i cae en el margen. El valor de b se puede recuperar encontrando un x_i en el margen y resolviendo

$$y_i(w'x_i + b) = 1$$

Finalmente destacar que aunque se trata de un clasificador de tipo lineal, se pueden aplicar trucos *kernel* (originalmente propuestos por Aizerman [1]) para realizar clasificaciones no lineales. Para ello se sustituye la función lineal que define la frontera por una función en un espacio de Hilbert con núcleo reproductor $f(x) = \sum_{i=1}^n \alpha_i K(x, x_i)$, usando por ejemplo la función de núcleo gaussiana $K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}$ para $\gamma > 0$. La complejidad matemática de este procedimiento excede de los objetivos de aprendizaje de este Trabajo de Final de Grado y por ello nos limitamos a comentar que la Ec. 3.17 se convierte en:

$$\text{maximizar } f(\alpha_1 \dots \alpha_n) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i \alpha_i K(x_i, x_j) y_j \alpha_j$$

Capítulo 4

Análisis de los Resultados

En este capítulo se presentan y discuten los métodos utilizados para el análisis de los resultados de los diferentes procedimientos. Los informes realizados a destacar son: el análisis de los datos de pruebas de compresión, la generación de los datos de entrenamiento, el análisis de cada algoritmo clasificador de aprendizaje automatizado y finalmente la comparativa de algoritmos clasificadores.

4.1. Análisis de los datos de pruebas de compresión

El objetivo de este análisis es describir en términos generales el comportamiento de las pruebas de compresión a grandes rasgos. Aunque el informe presentado se ha realizado para todo el conjunto de ficheros, este análisis se puede filtrar por fichero y conjuntos de datos específicos del mismo, esto puede resultar útil para el estudio en detalle de un tipo de fichero en particular. Este análisis se encuentra en el Anexo B.

Los objetivos de este análisis son:

- Relacionar el tamaño de bloque con las medidas de compresión y decompresión.
- Comprobar el comportamiento de los niveles de compresión sobre las pruebas.
- Comparar los datos de compresión de tablas normales y columnares.
- Determinar si existe correlación entre los algoritmos compresores *BloscLZ* o *LZ4* con nivel de compresión 1 y el resto.

- Observar si existe correlación directa entre las características extraídas de cada conjunto de datos y las medidas de compresión y descompresión.

Tamaño de bloque

El tamaño de bloque es una de las opciones de *Blosc* que determina el tamaño del bloque de datos que utilizará a nivel interno. A grandes rasgos un tamaño inferior implica que los datos caben en la caché del procesador y por tanto *Blosc* trabaja sobre ellos más rápido, por el contrario cuando el tamaño aumenta los datos no caben en caché y ralentiza el proceso. Además, cuánto más grande es el tamaño de bloque significa también que los algoritmos compresores buscan redundancias en espacios mayores por lo que consiguen comprimir más.

Para observar el comportamiento del tamaño de bloque se hacen las gráficas de las medias de las medidas de compresión: ratio de compresión, velocidad de compresión y velocidad de descompresión; para cada tamaño de bloque, para codec y filtro con nivel de compresión cinco (Ver pág. 90-96 Anexo B).

A partir de estas gráficas se comprueba que: el nivel de compresión es proporcional al tamaño de bloque, la velocidad de compresión se beneficia más de un tamaño de bloque intermedio y la velocidad de descompresión es inversamente proporcional al tamaño de bloque. Además parece que los algoritmos compresores *Snappy* y *Zlib* tienen peores resultados que el resto.

Finalmente se comparan estos gráficos en 4 niveles distintos de compresión, se observa que el comportamiento es el esperado y que el tamaño de bloque automático aumenta con el nivel de compresión, que es lo esperado.

Nivel de compresión

El nivel de compresión de *Blosc* permite regular la compresión del algoritmo compresor, aunque no todos los códigos tienen las mismas escalas, en *Blosc* se han adaptado todas en una escala del 1 al 9.

Como en el anterior caso se realizan gráficas de las medias de las medidas de compresión para cada nivel de compresión y para cada codec y filtro con tamaño de bloque fijo a 256 KB (Ver pág. 96-100 Anexo B).

El comportamiento observado en las gráficas es el esperado salvo para *Zstd* que en los niveles de compresión más altos pierde ratio de compresión. Además, vuelve a destacar el rendimiento de *Snappy* y *Zlib* que se sitúa por debajo del de sus competidores, *LZ4* y *Zstd*, respectivamente

Tablas columnares

A la hora de trabajar con tablas o vectores multidimensionales los datos se pueden almacenar de dos maneras por filas o por columnas. Sea n el número de datos y k el número de columnas o dimensiones de los datos, los datos almacenados normalmente tienen la forma (n, k) , sin embargo al almacenarlos por columnas (k, n) se aumenta la redundancia puesto que los datos de una misma columna se parecen más entre sí. Esto se tuvo en cuenta a la hora de generar los datos de las pruebas de compresión y en el caso que los datos eran tablas se hicieron las pruebas para su forma original y para la forma columnar.

Por tanto se realizó una comparativa de estas tablas (Ver pág. 100-101 Anexo B), en ella se observa que aunque las velocidades de compresión y descompresión no varían para el ratio de compresión si que hay diferencias significativas. El ratio de compresión se llega a doblar en algunos casos para las tablas normales y aunque en algunos casos no hay mejora, nunca empeora.

Correlaciones entre BloscLZ, LZ4 y el resto

Considerando características de los datos, se consideró utilizar los códecs de *Blosc* más rápidos, *BloscLZ* y *LZ4* para calcular su ratio y velocidad de compresión y utilizar éstos como caracterización de la complejidad de compresión de los datos. Aunque parece obvio que debe de haber correlación con el resto de algoritmos compresores tampoco es trivial pues cada algoritmo tiene diferencias significativas entre ellos. Para confirmar la correlación se extrajeron los datos de cada códec y filtro con tamaño de bloque fijo y con niveles de compresión uno y nueve, posteriormente se calcularon los coeficientes de Pearson entre los códecs más rápidos y el resto. El coeficiente de Pearson entre dos muestras se define como:

$$\rho_{X,Y} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

donde X e Y serían las muestras, x_i es una observación de la muestra X y \bar{x} es la media de X . Este coeficiente expresa la correlación lineal entre las muestras, escala entre -1 y 1 interpretándose respectivamente como correlación lineal negativa y positiva. Cuánto más cercano a cero significa que no hay correlación.

En las gráficas realizadas (Ver pág. 102-104 Anexo B) se observa que las correlaciones en el ratio de compresión son muy buenas, por encima de 0.7 en datos numéricos y de 0.5 en cadenas de texto para el códec *BloscLZ*. Por otro lado en las velocidades de compresión la correlación no es tan fuerte, por encima de 0.6 en datos numéricos y por encima de 0.3 en texto, aún así se considera buen resultado dado que indica una ligera correlación y serán los algoritmos clasificadores los que determinen finalmente si esta medida caracteriza bien los datos o no. Finalmente destacar que con *LZ4* los datos son muy parecidos e incluso un poco mejores.

Correlaciones entre características de los datos y pruebas de compresión

Teniendo en cuenta el funcionamiento general de los algoritmos compresores, básicamente, buscan datos parecidos y repetidos para comprimir esa información. Se escogieron características estadísticas de los datos que informasen sobre la cantidad de repeticiones y variabilidad, estas fueron: la media, la desviación típica, el coeficiente de asimetría, el coeficiente de apuntamiento, el mínimo, el máximo, los tres cuartiles y el número de rachas (se define una racha como valores consecutivos que se encuentran por encima o por debajo de la mediana).

Con el objetivo de poder observar correlaciones entre estas características y las medidas de compresión se realizaron gráficas de pares enfrentándolas, en el caso de mínimos y cuartiles se utilizó el rango total y el rango intercuartílico. Para estas gráficas se filtro con el códec *LZ4*, filtro *shuffle*, nivel de compresión 5 y tamaño de bloque de 256 KB (Ver pág. 104-105 Anexo B), de no ser así la variabilidad arruinaría los gráficos.

Aunque en algunos casos como para los coeficientes de apuntamiento y asimetría parecen estar bastante correlacionados con el ratio de compresión, del resto de características no se pueden extraer conclusiones claras. Por esto se dejará que sean los propios algoritmos de aprendizaje automatizado los que informen de la influencia e importancia de estas características.

4.2. Generación de los datos de entrenamiento

En esta sección se detalla todo el proceso seguido para la generación de los datos de entrenamiento. El objetivo del aprendizaje automatizado es que, a partir de las características de los datos y las opciones que decida el usuario, el algoritmo escoja la opción más adecuada de códec, filtro, nivel de compresión y tamaño de bloque. Por tanto para cada fragmento de datos (*chunk*), que queda identificado por: el nombre de fichero, el conjunto de datos dentro del fichero y el número de *chunk* dentro del conjunto; se tiene que escoger de entre todas las pruebas realizadas sobre él, las más adecuadas a las opciones de usuario.

Opciones de usuario

Cada usuario tiene unas necesidades específicas a la hora de utilizar el compresor *Blosc*, por ejemplo, las necesidades más comunes serían obtener la máxima compresión posible, la máxima velocidad de compresión o la máxima velocidad de descompresión. Sin embargo, el usuario puede necesitar opciones más complejas, como por ejemplo máxima velocidad con un mínimo de compresión o buscar máxima compresión y velocidad de descompresión. Además para asegurar que las opciones son viables se eliminaron todos los datos en los que el ratio de

compresión era inferior a 1.1, se espera comprimir al menos un 10% y si no es posible lo más conveniente será no comprimir.

Para escoger las opciones que no son simplemente el máximo de un valor se plantea la siguiente función de distancia para cada prueba de compresión realizada :

$$f(x, y, z) = C_1(x - x_{max})^2 + C_2(y - y_{max})^2 + C_3(z - z_{max})^2 \quad (4.1)$$

donde x, y, z son respectivamente el valor del ratio de compresión, de la velocidad de compresión y de la velocidad de descompresión, mientras que los máximos son los mayores valores de cada métrica dentro del *chunk*. Mientras tanto los coeficientes C_1, C_2, C_3 toman los valores 0 o 1 según si se le da importancia o no a la métrica que le corresponde. Como cada métrica sigue unas escalas, para evitar que las de mayor escala influyan más en el valor de la función se normalizan todas las métricas aplicando:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

de esta manera quedan todas entre el rango $[0, 1]$ y la fórmula de distancia 4.1 se convierte en:

$$f(x', y', z') = C_1(x' - 1)^2 + C_2(y' - 1)^2 + C_3(z' - 1)^2 \quad (4.2)$$

donde x', y', z' son los valores de las métricas normalizados.

Ahora solo queda extraer el mínimo de dicha función dentro de todas las pruebas realizadas en el *chunk* para las 7 combinaciones posibles de los valores de C_1, C_2 y C_3 (serían 8 combinaciones pero la opción (0, 0, 0) no tiene sentido). Ejemplos: para los coeficientes (0, 1, 0) que significan que al usuario solo le interesa la velocidad de compresión, la función es $f(y') = (y' - 1)^2$ y buscar el mínimo es equivalente a coger el máximo. Para los coeficientes (1, 1, 1) que significan que al usuario le importan todas las métricas por igual, la función es $f(x', y', z') = (x' - 1)^2 + (y' - 1)^2 + (z' - 1)^2$ y minimizarla implica escoger la opción con las métricas más equilibradas.

Una vez extraído el mínimo de la función solo hay que extraer el códec, filtro, nivel de compresión y tamaño de bloque que serán las variables objetivo para ese *chunk* con las opciones de usuario correspondientes que son los coeficientes C_1, C_2 y C_3 . Estos coeficientes se añadirán como las opciones de usuario tras renombrarlos como **IN_CR**, **IN_CS** y **IN_DS** en la Tabla 4.1 se aprecian la codificación de las distintas opciones y su descripción.

Por tanto cada fila de los datos de entrenamiento estará formada por: las variables identificativas de *chunk*, las opciones de usuario, las características de *chunk* y las variables objetivo. Además se añaden también como características las métricas de compresión obtenidas con *BloscLZ* y *LZ4* con nivel de compresión uno, en la Fig. 4.1 se recopila la información guardada en cada fila de los datos de entrenamiento.

Codificación			Descripción
IN_CR	IN_CS	IN_DS	
1	0	0	Máximo ratio de compresión.
0	1	0	Máxima velocidad de compresión.
0	0	1	Máxima velocidad de descompresión.
0	1	1	Equilibrio entre velocidad de compresión y descompresión.
1	1	0	Equilibrio entre ratio y velocidad de compresión.
1	0	1	Equilibrio entre ratio de compresión y velocidad de descompresión.
1	1	1	Equilibrio entre las tres medidas.

Tabla 4.1: Opciones de usuario y su codificación.

Chunk ID Filename, DataSet, Chunk_Number	Características Opciones de usuario, Características de chunk, Métricas blosclz-lz4	Variables objetivo Codec, Filter, CL, Block_Size
---	--	---

Figura 4.1: Esquema de las filas de los datos de entrenamiento

Eliminación de *Zlib* y *Snappy*

Tras haber extraído las opciones óptimas para cada opción se realizaron comprobaciones sobre las variables objetivo seleccionadas. Rápidamente se detectó que el códec *Zlib* nunca era seleccionado, pues como se había detectado con anterioridad *Zstd* le ganaba en todas las ocasiones. Por otro lado *Snappy* solo era seleccionado 2 veces y se le consideró como un dato atípico, por tanto después de observar que la opción justo por detrás de *Snappy* era muy parecida se eliminó. Finalmente considerando 4 códecs se observó que aparecían seleccionadas 488 combinaciones posibles de 1080 totales (combinaciones de códec, filtro, nivel de compresión y tamaño de bloque) que, sin contar el tamaño de bloque (puesto que tiene correlación con el nivel de compresión) son 97 combinaciones de 108, por lo que los datos están bastante completos y equilibrados.

Tamaño de bloque automático

A continuación se comprobó cuantas veces el tamaño de bloque automático se correspondía con el de la mejor opción, lo cual se producía en un 27 % de las ocasiones, nada mal, teniendo en cuenta que es un algoritmo simple que se basa apenas en el nivel de compresión seleccionado y cuyo rango de tamaños es más limitado que el considerado en esta ocasión. Tras esta comprobación se cambian los valores del tamaño de bloque automático por el tamaño de bloque real utilizado, para ello basta buscar el tamaño de bloque con el mismo ratio de compresión.

Procesamiento de las variables categóricas

Los algoritmos de clasificación supervisada de *scikit-learn* sólo admiten variables binaria, por ello, hay que procesar las variables categóricas para que puedan ser utilizadas. Con respecto a las características de *chunk* se transforman las variables:

- **Table:** que era una categórica de 3 valores, 0 para datos en forma de vector, 1 para tablas y 2 para tablas columnares. Esta variable se transforma en dos binarias: **is_Table** indicando si es una tabla o no, e **is_Columnar** indicando si está en forma columnar o no.
- **DType:** que indica el tipo de los datos y su tamaño, se divide en 4 variables. Tres variables binarias **is_Float**, **is_Int** e **is_String**, indicando respectivamente si son datos de coma flotante, enteros o cadenas de texto. La última variable es numérica **Type_Size** y se corresponde con el tamaño del tipo en bytes.

Finalmente las variables objetivo se transforman en variables binarias de la siguiente manera:

- **Codec:** se transforma en 4 variables binarias una para cada códec: **BloscLZ**, **LZ4**, **LZ4HC** y **Zstd**.
- **Filter:** una variable para cada filtro: **Noshuffle**, **Shuffle** y **Bitshuffle**.
- **CL:** para cada nivel se hace una variable binaria: **CL1**, **CL2**, **CL3**, **CL4**, **CL5**, **CL6**, **CL7**, **CL8** y **CL9**.
- **Block_Size:** al igual que en la anterior se transforma en 9 variables binarias: **Block_8**, **Block_16**, **Block_32**, **Block_64**, **Block_128**, **Block_256**, **Block_512**, **Block_1024** y **Block_2048**.

4.3. Análisis de los algoritmos de clasificación

Para realizar el análisis final de los algoritmos de clasificación se realizaron dos tipos de análisis. El primer tipo de análisis consiste en comprobar el funcionamiento del algoritmo de clasificación y ajustar los parámetros que ofrece *scikit-learn*. Se realizaron cuatro informes de este tipo: uno para análisis discriminante y regresión multinomial, otro para máquinas de vector soporte, para vecinos más próximos y finalmente para bosques aleatorios. Dado que son muy parecidos entre sí solo se detallará el procedimiento seguido con los bosques aleatorios ya que es el informe más completo, el resto se pueden encontrar en el Anexo D.

El segundo tipo de análisis se corresponde con la comparativa final del rendimiento de los algoritmos, en él se compara tanto las puntuaciones obtenidas como las velocidades de predicción.

4.3.1. Análisis individual: Bosques aleatorios

En este análisis se exploran las opciones que ofrece el paquete *scikit-learn* para el algoritmo de aprendizaje automático de bosques aleatorios, que dentro del paquete se llama *RandomForestClassifier*, en adelante **RFC**. El informe se compone de cuatro partes que se detallarán en las próximas secciones y son: las curvas de aprendizaje, las curvas de validación, la validación cruzada de parámetros y los resultados obtenidos.

Curvas de aprendizaje

La curva de aprendizaje muestra la puntuación obtenida por la muestra de entrenamiento y por la de validación en función del tamaño de muestra de entrenamiento escogido. Esta herramienta permite saber si el algoritmo se beneficia de aumentar el tamaño de la muestra de entrenamiento y si sufrirá problemas de **sobreajuste** o **sesgo**.

El **sobreajuste** (**variance** en inglés) es el error introducido en el algoritmo debido a fluctuaciones en la muestra de entrenamiento (por ejemplo: datos atípicos o muestras homogéneas) y provoca que el algoritmo se ajuste a esas fluctuaciones y falle al predecir otros datos. Cuando se produce **sobreajuste** la puntuación con la muestra de entrenamiento es alta y con la muestra de validación es baja.

El **sesgo** (**bias** en inglés) es el error introducido por suposiciones del algoritmo de aprendizaje (por ejemplo: uso de distancias en datos no normalizados o suponer que los datos siguen cierta distribución cuando no es así) y provoca que no se ajuste para nada a los datos y falle. Esto

se detecta cuando las puntuaciones con la muestra de entrenamiento y con la de validación son bajas.

En la Fig. 4.2, podemos observar las curvas de entrenamiento para RFC. Simplemente destaca, que en este caso el algoritmo se beneficia al aumentar el tamaño de la muestra, sin embargo, se observa que hay cierto sobreajuste ya que la puntuación obtenida con la muestra de entrenamiento es casi perfecta y, sin embargo, la obtenida con la muestra de validación no consigue pasar de 0,8.

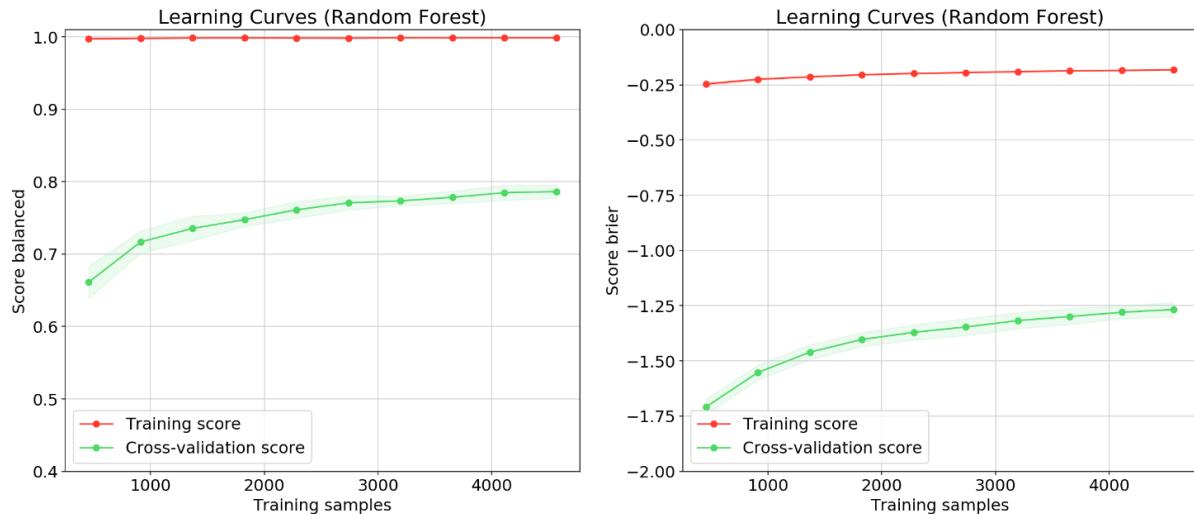


Figura 4.2: Curvas de entrenamiento de RFC con la puntuación personalizada a la izquierda y la de brier a la derecha. En rojo la puntuación con la muestra de entrenamiento y en verde la puntuación con la muestra de validación.

Curvas de validación

La curva de validación representa las puntuaciones de las muestras de entrenamiento y validación en función de un parámetro del algoritmo de aprendizaje. Aunque para validar los parámetros del algoritmo se utilice la validación cruzada con *GridSearch* una herramienta de *scikit-learn* que se detalla en la siguiente sección, en ocasiones resulta interesante utilizar curvas de validación en parámetros continuos para ajustar el sobreajuste y el sesgo que producen sobre el algoritmo.

En la Fig. 4.3 se observan las curvas de validación para el parámetro **max_depth** de RFC.

Este parámetro, como se comentó en la Sección 3.5.2, sirve para cortar, o más bien limitar, el tamaño de los árboles de decisión dentro del bosque, al alcanzar el valor de **max_depth** los árboles no se siguen ramificando. En la gráfica se observa que para valores pequeños de **max_depth** se produce sesgo y conforme aumenta el valor se produce sobreajuste. Para evitarlo se escogerá un valor intermedio como 10 o 12.

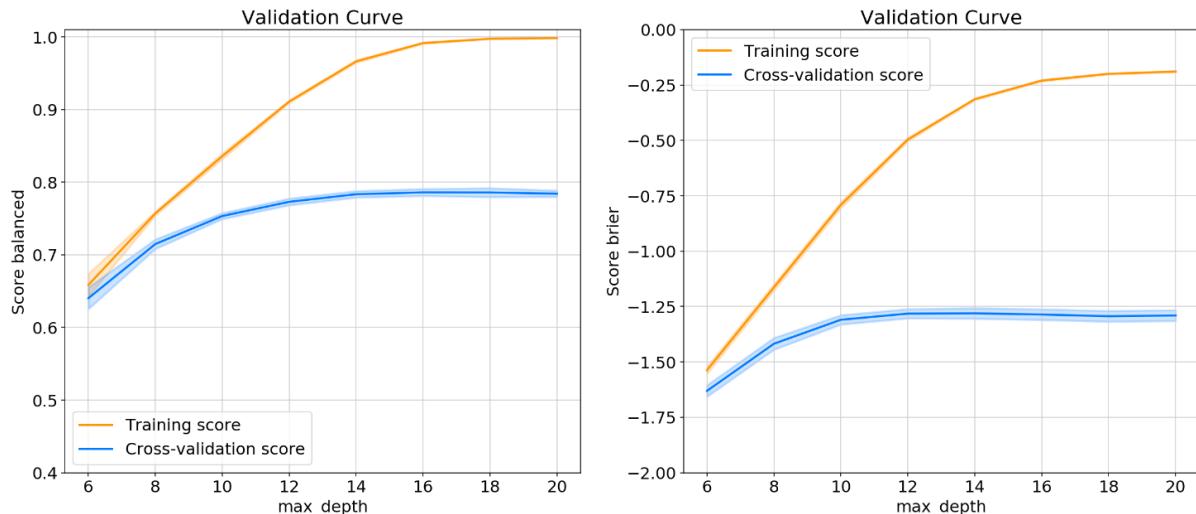


Figura 4.3: Curvas de validación de RFC para el parámetro *max_depth* con la puntuación personalizada a la izquierda y la de brier a la derecha. En amarillo la puntuación para la muestra de entrenamiento y en azul la puntuación para la muestra de validación.

Además del parámetro **max_depth** también se han realizado curvas de validación para **n_estimators** y **max_features**, que son respectivamente el número de árboles dentro del bosque y el número de características a considerar como mínimo para ramificar. Las curvas de estos parámetros son crecientes pero no mejoran apenas por lo que se escogieron valores pequeños para evitar un aumento en el tiempo de predicción y entrenamiento del algoritmo. Para **n_estimators** se escogió 20 y para **max_features** 10.

Validación cruzada de parámetros

La mejor manera de validar los parámetros de un algoritmo en *scikit-learn* es mediante la herramienta **GridSearch**. Para utilizarla hay que proporcionarle el nombre de los parámetros y el rango de valores que se quieren probar en cada uno, de esta manera **GridSearch** prueba todas las combinaciones posibles hasta dar con la óptima. Para encontrar la óptima hay que

especificarle la métrica de puntuación a utilizar y las divisiones de la muestra de entrenamiento y validación a emplear, para las cuales se utilizó **ShuffleSplit** otra herramienta de *scikit-learn* que realiza las divisiones de forma aleatoria. Ya que la validación de todas las combinaciones de parámetros puede resultar costosa, se realizó en un programa *Python* aparte (ver Anexo D), guardando los resultados para ser mostrados posteriormente en el informe.

En el informe se muestran los resultados de la validación cruzada que en el caso de RFC se utilizó sobre tres parámetros: **criterion** (valores *gini* o *entropy*), **bootstrap** (valores *True* o *False*) y **class_weight** (valores *None* o *Balanced*). El **criterion** es la regla de ramificación a seguir por los árboles de decisión, **bootstrap** indica si utiliza o no la técnica de muestreo para entrenar los árboles y **class_weight** permite asignar pesos a las variables objetivo según la cantidad de veces que aparecen en la muestra. Aunque se realizó la validación cruzada para las dos métricas propuestas (brier y la personalizada) y cada una decidía un **criterion** y **bootstrap** distinto. Para desempatar se utilizó la métrica por defecto de *scikit-learn* que resultó ser mayor para los parámetros escogidos por la métrica personalizada.

En la Fig. 4.4 se muestran las puntuaciones de la validación cruzada, tanto por la métrica personalizada como por la de Brier. Finalmente se escogieron los parámetros de la personalizada: **criterion** *entropy*, **bootstrap** *False* y **class_weight** *None*.

Validación con métrica personalizada
Report

Name	Score
balanced	0.8196 +/- (0.0072)
brier	-1.2470 +/- (0.0435)
normal	0.2987 +/- (0.0140)
codec	0.9508 +/- (0.0041)
filter_	0.9503 +/- (0.0064)
codec_filter	0.9131 +/- (0.0075)
c_level	0.4917 +/- (0.0176) ~ 0.7143 +/- (0.0151)
block	0.4611 +/- (0.0155) ~ 0.7395 +/- (0.0054)
cl_block	0.3029 +/- (0.0135) ~ 0.7277 +/- (0.0096)

Validación con la métrica de Brier
Report

Name	Score
balanced	0.8062 +/- (0.0067)
brier	-1.2402 +/- (0.0332)
normal	0.2775 +/- (0.0136)
codec	0.9490 +/- (0.0056)
filter_	0.9482 +/- (0.0054)
codec_filter	0.9104 +/- (0.0077)
c_level	0.4638 +/- (0.0182) ~ 0.6922 +/- (0.0131)
block	0.4350 +/- (0.0142) ~ 0.7132 +/- (0.0096)
cl_block	0.2795 +/- (0.0158) ~ 0.7017 +/- (0.0096)

Figura 4.4: Comparativa de puntuaciones para las dos validaciones de parámetros. Balanced es la puntuación personalizada, normal la predeterminada de *scikit-learn*. El resto son puntuaciones separadas por variable objetivo.

Selección de características

En la Fig. 4.4 se encuentran las puntuaciones obtenidas con el algoritmo RFC utilizando todas las características. En esta sección se utiliza RFC para la selección de características puesto que para el algoritmo final interesa extraer únicamente las necesarias para no ralentizar el proceso de predicción. En la Fig. 4.5 se puede observar las características ordenadas por su influencia en el algoritmo RFC. De las cuales se escogieron las que tenían puntuación mayor a 0,02 y se eliminaron **BLZ_DSpeed**, **LZ4_CRate**, **LZ4_CSspeed** y **LZ4_DSpeed**. Las características de velocidad de descompresión se eliminaron para no cargar la extracción del ratio y la velocidad de compresión con otro espacio de memoria para la descompresión y las de LZ4 porque es más fácil adaptar el código de *BloscLZ*. Hay que destacar que aunque las características de LZ4 y *BloscLZ* tenga mucha importancia en el algoritmo, al estar muy correlacionadas, cuando se elimina una, la otra "hereda" el peso de la eliminada.

Ranking de características	
IN_CS	--> 0.137211464106
IN_CR	--> 0.131111625479
IN_DS	--> 0.0974040195938
Sd	--> 0.0725884746762
BLZ_CRate	--> 0.0650706591705
LZ4_CRate	--> 0.0577350273716
LZ4_CSspeed	--> 0.0478638587605
N_Streaks	--> 0.0472820616428
BLZ_CSspeed	--> 0.0406333720582
LZ4_DSpeed	--> 0.0396800663834
Max	--> 0.0344295790066
Mean	--> 0.0342350747248
Kurt	--> 0.0313547351925
BLZ_DSpeed	--> 0.0285255993956
Skew	--> 0.027954199065
Min	--> 0.0210788529098
Q3	--> 0.0190268628242
is_Float	--> 0.0155081537992
is_Int	--> 0.0133159625712
Q1	--> 0.0100059230634
Median	--> 0.00909992360608
Chunk_Size	--> 0.0089115679826
Type_Size	--> 0.00504329884318
is_String	--> 0.00199125161123
is_Table	--> 0.00159127362086
is_Columnar	--> 0.00134711254228

Figura 4.5: Ranking de características según el algoritmo RFC.

Debido a que una de las principales características de *Blosc* es la velocidad, el tiempo de extracción de las características no puede ser excesivamente alto. Por ello se consideraron tres conjuntos de características según las veces que era necesario recorrer los datos para extraerlas. En la Tabla 4.2 se observan las características añadidas en cada recorrido.

Primer recorrido				
IN_CR	IN_CS	IN_DS	BLZ_CRate	BLZ_CSspeed
Segundo recorrido				
Sd	Mean	Kurt	Skew	Max
Tercer recorrido				
N_Streaks				

Tabla 4.2: Características por recorrido.

Tres recorridos Report		Dos recorridos Report	
Name	Score	Name	Score
balanced	0.8240 +/- (0.0055)	balanced	0.8165 +/- (0.0062)
brier	-1.3573 +/- (0.0464)	brier	-1.4211 +/- (0.0498)
normal	0.3038 +/- (0.0118)	normal	0.2998 +/- (0.0096)
codec	0.9496 +/- (0.0067)	codec	0.9417 +/- (0.0072)
filter_	0.9415 +/- (0.0064)	filter_	0.9380 +/- (0.0059)
codec_filter	0.9061 +/- (0.0075)	codec_filter	0.8966 +/- (0.0065)
c_level	0.4999 +/- (0.0172) ~ 0.7293 +/- (0.0160)	c_level	0.4965 +/- (0.0193) ~ 0.7273 +/- (0.0118)
block	0.4658 +/- (0.0137) ~ 0.7531 +/- (0.0073)	block	0.4636 +/- (0.0102) ~ 0.7527 +/- (0.0089)
cl_block	0.3096 +/- (0.0152) ~ 0.7418 +/- (0.0091)	cl_block	0.3045 +/- (0.0123) ~ 0.7402 +/- (0.0080)

Un recorrido Report	
Name	Score
balanced	0.7767 +/- (0.0087)
brier	-1.6566 +/- (0.0500)
normal	0.2655 +/- (0.0073)
codec	0.9187 +/- (0.0112)
filter_	0.8832 +/- (0.0091)
codec_filter	0.8292 +/- (0.0116)
c_level	0.4586 +/- (0.0116) ~ 0.7117 +/- (0.0076)
block	0.4307 +/- (0.0116) ~ 0.7317 +/- (0.0094)
cl_block	0.2801 +/- (0.0118) ~ 0.7233 +/- (0.0078)

Figura 4.6: Puntuaciones por cantidad de recorridos.

En la Fig. 4.6 se muestran las puntuaciones obtenidas con cada uno de los 3 conjuntos de características. Para el caso de RFC la diferencia entre tres o dos recorridos no es muy significativa, sin embargo, con un único recorrido ya pierde un 0,03 en la puntuación personalizada y la por defecto. Destacar que también se probó como conjunto de primer recorrido el formado por **IN_CR**, **IN_CS**, **IN_DS** y las características del segundo recorrido pero las puntuaciones eran mucho peores, algo esperable teniendo en cuenta que las del primer recorrido tienen una posición más alta en el ranking de características.

Finalmente se utilizó una variante de la herramienta **MultiOutputClassifier** proporcionada por *scikit-learn*, esta variante se hizo a partir del programa original de *scikit-learn*, *multioutput.py* [8]. La variante **multioutput_chained.py** se encuentra en el Anexo D y permite utilizar el objeto **ChainedMultiOutputClassifier**, que al pasarle un clasificador como RFC, se encarga de que las predicciones de cada variable objetivo se utilicen para predecir la siguiente de forma que si éstas tienen correlación los resultados mejoran. En la Fig. 4.7 se observan los resultados para el conjunto de características de tres recorridos, aunque los resultados mejoran significativamente 0,03 hay que tener en cuenta que las predicciones son más lentas.

ChainedMultiOutput Report	
Name	Score
balanced	0.8518 +/- (0.0047)
brier	0.0000 +/- (0.0000)
normal	0.3385 +/- (0.0091)
codec	0.9532 +/- (0.0047)
filter_	0.9504 +/- (0.0060)
codec_filter	0.9123 +/- (0.0076)
c_level	0.5563 +/- (0.0147) ~ 0.7867 +/- (0.0095)
block	0.5107 +/- (0.0059) ~ 0.8002 +/- (0.0072)
cl_block	0.3432 +/- (0.0111) ~ 0.7920 +/- (0.0053)

Figura 4.7: Puntuaciones con **ChainedMultiOutputClassifier**, la puntuación de Brier es cero porque no se implementaron las predicciones probabilísticas

4.3.2. Comparativa de algoritmos

Tras haber estudiado individualmente cada algoritmo se realiza un informe donde se compara el rendimiento de los distintos algoritmos empleados. Para ello se realizan comparativas de las puntuaciones en distintos casos de uso y las velocidades de predicción de los distintos algoritmos.

Comparativa por fichero

En esta primera comparación se escogen todos los datos menos los de un fichero como muestra de entrenamiento y el resto, los de un sólo fichero, como muestra de validación. En la Fig. 4.8 se muestran las puntuaciones de cada algoritmo para cada fichero. Como se puede observar no son nada esperanzadoras, y es que cada fichero es un mundo aparte.

Cada fichero tiene un número diferente de conjuntos de datos (**DataSets**), que a su vez se dividen en fragmentos (**chunks**) de 16 MB, o menos si son más pequeños, sobre los que se realizan las pruebas. Como comprobaremos en las siguientes secciones la clave está en los **DataSets**, pues son los que cargan con la mayor variabilidad entre las clasificaciones. Por ejemplo un **DataSet** puede contener datos de la temperatura en una ciudad, que son número pequeños y fáciles de comprimir, mientras que otro puede contener información de rayos cósmicos, que son números muy grandes y difíciles de comprimir. Sin embargo, en un fichero pueden haber 50 **DataSets** o tan sólo uno como el caso del fichero *GSSTF_NCEP* el cuál consigue las mejores puntuaciones.

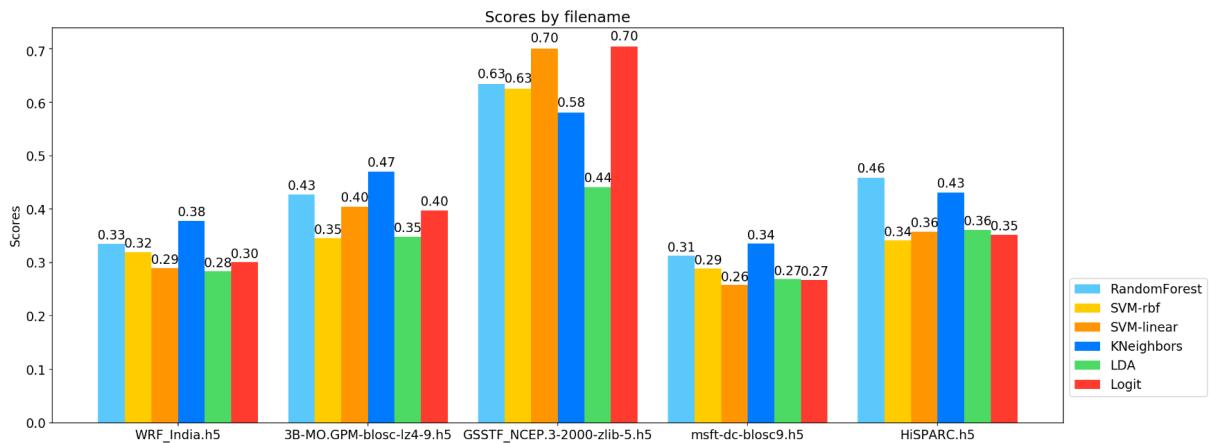


Figura 4.8: Puntuaciones de la comparativa por fichero. *RandomForest* son los bosques aleatorios, *SVM* máquinas de vector soporte lineales o con la función de base radial gaussiana, *KNeighbors* vecinos más próximos, *LDA* análisis discriminante y *Logit* regresión multinomial.

Comparativa por grupos de DataSets

Para esta comparativa se mezclan los **DataSets** por igual y se dividen en 5 grupos, después se coge un grupo como muestra de validación y el resto como muestra de entrenamiento. Esta comparativa pretende ilustrar el comportamiento que tendría el algoritmo en casos genéricos

fuera de la muestra de entrenamiento, si se realizase un estudio para escoger cuidadosamente los **DataSets** de entrenamiento. En la Fig. 4.9 se muestran las puntuaciones obtenidas, donde se aprecia que los algoritmos más precisos son bosques aleatorios y vecinos más próximos. Sin embargo, conviene tener en cuenta la anterior sección, que aunque era un único caso, los ganadores eran máquinas de vector soporte lineales y regresión logística, por lo que en caso de ampliar el estudio se deberían seguir considerando.

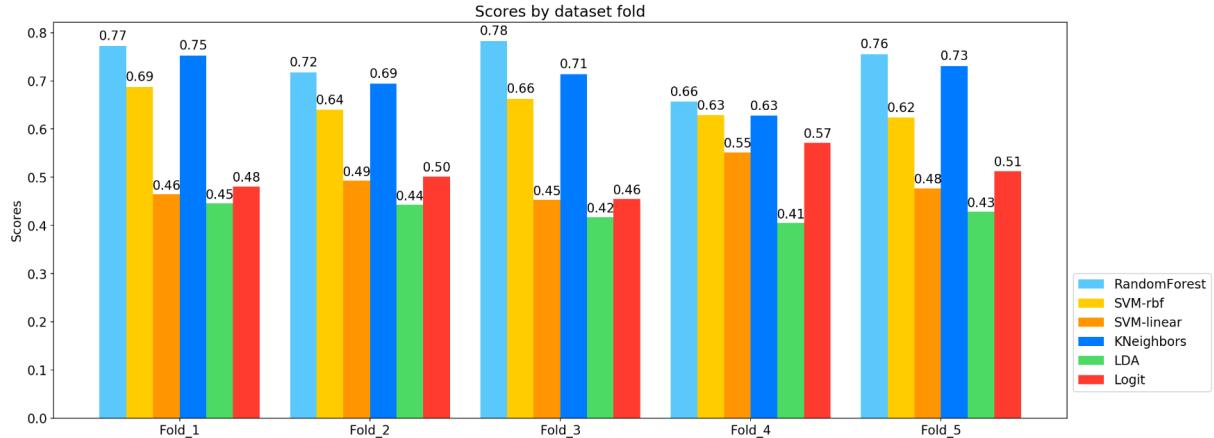


Figura 4.9: Puntuaciones de la comparativa por grupos equilibrados de **DataSets**.

Para finalizar en la Fig. 4.10 se muestra en detalle un desglose de las puntuaciones por variables objetivo: **Codec**, **Filter**, **CL** y **Block_Size** para el tercer grupo; además de la puntuación al utilizar el **ChainedMultiOutputClassifier**. Conviene tener en cuenta la enorme mejora que supone aplicar las predicciones de forma encadenada en el análisis discriminante, la regresión logística y las máquinas de vector soporte, donde se aprecian mejoras en las puntuaciones de 0, 1 e incluso 0, 2 para análisis discriminante.

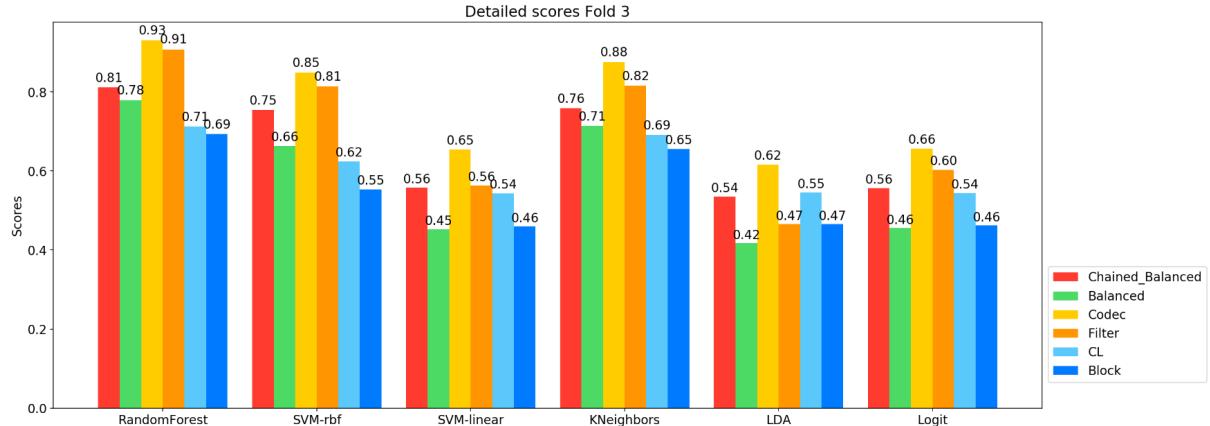


Figura 4.10: Puntuaciones detalladas para el tercer grupo.

Comparativa por *chunks*

Después de evaluar la precisión de los algoritmos sobre datos muy distintos de los de entrenamiento, se plantea estudiar la precisión cuando se sabe que los datos a predecir son parecidos a los de entrenamiento. En concreto interesa saber si a partir de un primer *chunk* se pueden realizar buenas predicciones del resto de *chunks* de un **DataSet**, de esta manera se puede estimar lo bien que se comportaría el algoritmo al aplicarlo en flujos de datos. En la Fig. 4.11 se observa los resultados de entrenar los algoritmos con el primero del **DataSet** y validarlos con el resto de *chunks*. El claro ganador para este caso son los bosques aleatorios, aun así también destacan las puntuaciones de las máquinas de vector soporte y vecinos más próximos.

Para la última comparativa de precisión se realizó una división equilibrada de *chunks*, ésta es muy parecida a la realizada con los grupos de **DataSets** pero con la particularidad de que se escogen muy pocos datos de entrenamiento. Para ello de todos los **DataSets** se escogen únicamente los formados por un único *chunk* y estos se dividen por la mitad para entrenar y validar. En la Fig. 4.12 se muestran los resultados, donde los claros ganadores vuelven a ser bosques aleatorios, vecinos más próximos y máquinas de vector soporte.

280 train --- 4256 test

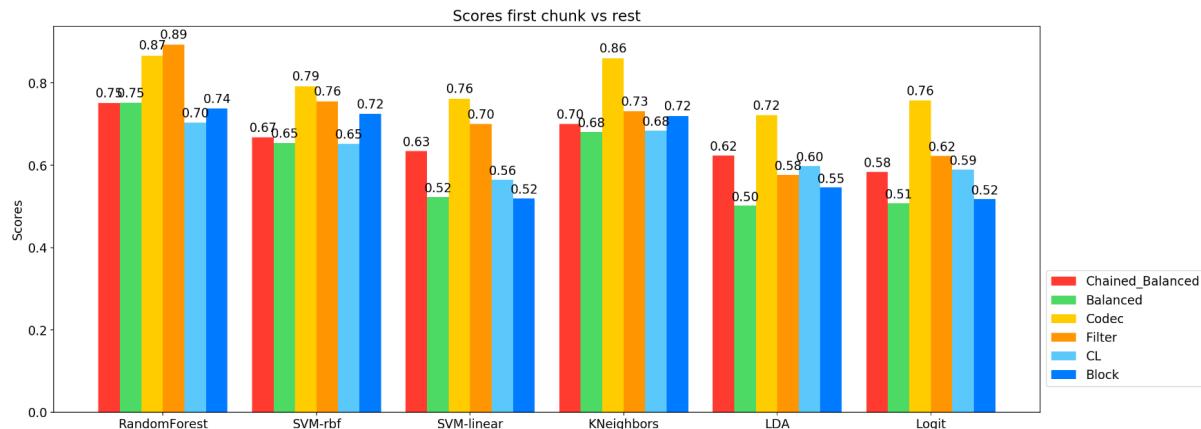


Figura 4.11: Puntuaciones detalladas para el primer *chunk* contra el resto.

273 train --- 266 test

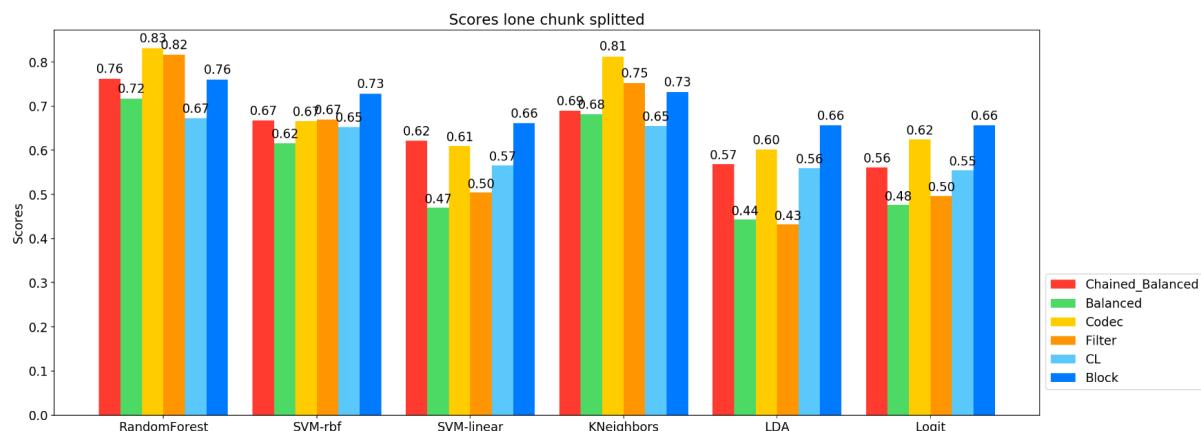


Figura 4.12: Puntuaciones detalladas para la mitad de *chunks*.

Comparativa de velocidad

Finalmente se realiza una prueba de velocidad de predicción, donde simplemente se mide el tiempo medio de una predicción para cada algoritmo. Como se observa en la Fig. 4.13 el más lento con diferencia son los bosques aleatorios, seguido de máquinas de vector soporte con función de base radial gaussiana. Por otro lado máquinas de vector soporte lineales, análisis discriminante y regresión multinomial están igualado; y el ganador es vecinos más próximos.

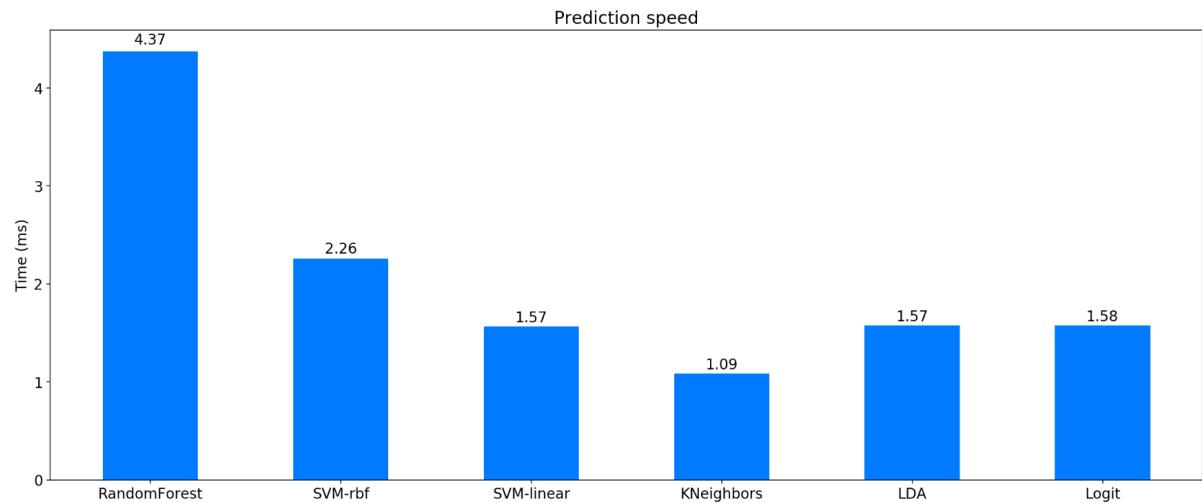


Figura 4.13: Puntuaciones detalladas para el tercer grupo.

Capítulo 5

Conclusiones

El objetivo principal del proyecto era desarrollar un algoritmo de aprendizaje automatizado que fuese capaz de determinar todas las opciones (**códec**, **filtro**, **nivel de compresión** y **tamaño de bloque**) del meta compresor de datos *Blosc*, según las características de los datos a comprimir y el objetivo del usuario.

Para ello se ha desarrollado un proyecto de minería de datos que ha implicado desde la generación de los datos hasta la construcción de algoritmos de clasificación supervisada y su comparación de rendimiento en distintos casos de uso. Para poder llevar a cabo estas tareas ha sido necesario un estudio teórico previo de las técnicas de clasificación supervisada, así como la práctica de las mismas, para poder escoger de entre todas ellas las más adecuadas al caso. Los algoritmos de clasificación utilizados han sido análisis discriminante, regresión multinomial, máquinas de vector soporte, vecinos más próximos y bosques aleatorios, que se han detallado en el Capítulo 3.

Con respecto a los casos de uso a considerar en el desarrollo del algoritmo clasificador se han considerado dos: el primero un algoritmo genérico para cualquier tipo de datos y el segundo un algoritmo ajustado a un tipo de datos en concreto. Para ambos casos habría que continuar con el estudio iniciado en este proyecto para terminar de refinar y producir el algoritmo final a incluir dentro de *Blosc*.

Con respecto al primer caso de uso, los ficheros que se disponen actualmente para generar datos de pruebas de compresión son insuficientes. Cuando lo que se pretende caracterizar son cualquier tipo de datos en sí, la variabilidad es casi infinita, en este estudio la mayoría de los datos eran numéricos pero también pueden aparecer datos en forma de texto por ejemplo. Para proseguir dentro de este caso de uso, habría que decidir el conjunto de características a extraer de los datos e implementar dentro de *Blosc* la extracción para poder aplicarla de forma

efectiva sobre cualquier tipo de datos a nivel de bytes. Por el momento se han considerado tres conjuntos de características los cuales se ha demostrado que funcionan relativamente bien en el Capítulo 4. Una vez implementado en *Blosc* la extracción de características habría que ampliar la cantidad de ficheros de datos y realizar un estudio en profundidad de los tipos de conjuntos de datos, probablemente con técnicas de clasificación no supervisada. Finalmente habría que utilizar los resultados de este estudio para construir una muestra de datos de entrenamiento lo más equilibrada posible y comparar el rendimiento de los algoritmos de clasificación ya estudiados.

Por otro lado en el caso de ajustar el algoritmo a un tipo en concreto de datos, ya se ha demostrado en el Capítulo 4 que la precisión es bastante buena, entorno al 75 % con la puntuación personalizada y acertando el **códec** y **filtro** en aproximadamente un 90 % de los casos. Por tanto aquí se vislumbran dos posibilidades: producir algoritmos adaptados bajo demanda de clientes a un tipo en concreto de datos y producir un sistema de compresión orientado a flujos de datos. El primer caso sería muy sencillo de realizar y se ha demostrado la eficiencia en este proyecto. En el segundo caso habría que continuar la investigación, tanto en la optimización del tiempo de predicción como en la elaboración de un sistema de entrenamiento continuo para el algoritmo clasificador.

Bibliografía

- [1] M. A. Aizerman, E. A. Braverman y L. Rozonoer. «Theoretical foundations of the potential function method in pattern recognition learning.» En: *Automation and Remote Control*, Automation and Remote Control, 25. 1964, págs. 821-837.
- [2] Francesc Alted. *Blosc benchmark example*. 2014. URL: https://github.com/Blosc/python-blosc/blob/master/bench/compress_ptr.py.
- [3] L. Breiman. «Random Forests». En: *Machine Learning* 45 (octubre de 2001), págs. 5-32. DOI: 10.1023/A:1010933404324.
- [4] L. Breiman y col. *Classification and Regression Trees*. The Wadsworth and Brooks-Cole statistics-probability series. Taylor & Francis, 1984. ISBN: 9780412048418. URL: <https://books.google.es/books?id=JwQx-WOmSyQC>.
- [5] Glenn W. Brier. *Verification of forecasts expressed in terms of probability*. Enero de 1950. URL: <https://docs.lib.noaa.gov/rescue/mwr/078/mwr-078-01-0001.pdf>.
- [6] scikit-learn developers. «Nested versus non-nested cross-validation». En: *scikit-learn user guide*. Diciembre de 2016, págs. 1010-1013. URL: http://scikit-learn.org/stable/_downloads/scikit-learn-docs.pdf.
- [7] T. Hastie, R. Tibshirani y J. Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition*. Springer Series in Statistics. Springer New York, 2009. ISBN: 9780387848587. URL: <https://books.google.es/books?id=tVIjmNS30b8C>.
- [8] Tim Head. *multioutput.py*. 2016. URL: <https://github.com/scikit-learn/scikit-learn/blob/14031f6/sklearn/multioutput.py>.
- [9] Fengnan Li y col. «When Lempel-Ziv-Welch Meets Machine Learning: A Case Study of Accelerating Machine Learning using Coding». En: *CoRR* abs/1702.06943 (2017). URL: <http://arxiv.org/abs/1702.06943>.
- [10] Alistair Miles. *Genotype compressor benhcmark*. Septiembre de 2016. URL: <http://alimanfoo.github.io/2016/09/21/genotype-compression-benchmark.html>.
- [11] D. Pena. *Analisis de datos multivariantes*. S.A. MCGRAW-HILL, 2002. ISBN: 9788448136109. URL: <https://books.google.es/books?id=TrVlAAAACAAJ>.

- [12] SINTEF. *Big Data, for better or worse: 90 % of world's data generated over last two years*. Mayo de 2013. URL: <https://www.sciencedaily.com/releases/2013/05/130522085217.htm>.
- [13] Jonathan Whitmore. *Jupyter Notebook post save hook for .py and .html files*. 2015. URL: <https://gist.github.com/jbwhit/881bdeaae3e4128947c/>.
- [14] Jonathan Whitmore. *Jupyter Notebook Tips and Tricks*. 2015. URL: <https://github.com/jbwhit/jupyter-tips-and-tricks>.

Anexo A

Generador de datos de las pruebas de compresión

En este anexo se presenta el código realizado en *Python* que realiza las pruebas de compresión sobre los datos dentro de un fichero *hdf5* y escribe los resultados en un fichero *csv*. El fichero del código se llama **test_data_generator.py** que incluye el programa principal y las funciones auxiliares que utiliza.

A.1. Código test_data_generator.py

```
1 from __future__ import print_function
2 import functools
3 import os.path
4 from queue import Queue
5 from sys import platform
6 import blosc
7 import tables
8 import numpy as np
9 import scipy.stats as stats
10 import pandas as pd
11 if platform == 'win32':
12     from time import clock as time
13 else:
14     from time import time as time
15
16 SPEED_UNIT = 2**30
17 CHUNK_SIZE = 2**24
18 MINIMUM_SIZE = 2**13
19 KB32, KB128, MB = 2**15, 2**17, 2**20
```

```

20 KB64, KB256, MB2 = 2**16, 2**18, 2**21
21 KB16, KB512 = 2**14, 2**19
22
23
24 def test_codec(chunk, codec, filter_name, clevel):
25     """
26         Compress the chunk and return tested data.
27
28     Parameters
29
30     chunk: bytes-like object (supporting the buffer interface)
31         The data to be compressed.
32     codec : string
33         The name of the compressor used internally in Blosc. It can be
34         any of the supported by Blosc ('blosclz', 'lz4', 'lz4hc',
35         'snappy', 'zlib', 'zstd' and maybe others too).
36     filter_name : int
37         The shuffle filter to be activated. Allowed values are
38         blosc.NOSHUFFLE, blosc.SHUFFLE and blosc.BITSHUFFLE.
39     clevel : int
40         The compression level from 0 (no compression) to 9
41         (maximum compression).
42
43     Returns
44
45     out: tuple
46         The associated compression rate, compression speed and
47         decompression speed (in GB/s).
48
49     Raises
50
51     TypeError
52         If bytesobj doesn't support the buffer interface.
53     ValueError
54         If bytesobj is too long.
55         If typesize is not within the allowed range.
56         If clevel is not within the allowed range.
57         If cname is not a valid codec.
58
59     """
60     t0 = time()
61     c = blosc.compress_ptr(chunk.__array_interface__['data'][0],
62                           chunk.size, chunk.dtype.itemsize,
63                           clevel=clevel, shuffle=filter_name, cname=codec)
64     tc = time() - t0
65     out = np.empty(chunk.size, dtype=chunk.dtype)
66     times = []
67     for i in range(3):
68         t0 = time()
69         blosc.decompress_ptr(c, out.__array_interface__['data'][0])
70         times.append(time() - t0)
71     chunk_byte_size = chunk.size * chunk.dtype.itemsize
72     rate = chunk_byte_size / len(c)
73     c_speed = chunk_byte_size / tc / SPEED_UNIT
74     d_speed = chunk_byte_size / min(times) / SPEED_UNIT

```

```

72     # print("  *** %8s, %-10s, CL%d *** %6.4f s / %5.4f s " %
73     #       ( codec, blosc.filters[filter], clevel, tc, td), end='')
74     # print("\tCompr. ratio: %5.1fx" % rate)
75     return rate, c_speed, d_speed
76
77
78 def chunk_generator(buffer):
79     """
80     Generate data chunks of 16 MB in `buffer`.
81
82     Parameters
83     -----
84     buffer : numpy.array
85         Buffer array of data
86
87     Returns
88     -----
89     out : numpy.array
90         A chunk of 16 MB extracted from the original buffer.
91     """
92     mega = int(CHUNK_SIZE / buffer.dtype.itemsize)
93     max_, r = divmod(buffer.size, mega)
94     for i in range(max_):
95         yield buffer[i * mega: (i + 1) * mega]
96     if r != 0:
97         yield buffer[max_ * mega: buffer.size]
98
99
100 def dataset_extractor(dataset):
101     """
102     Extracts the data inside hdf5 `dataset` node.
103
104     Parameters
105     -----
106     dataset : dataset node
107         An hdf5 dataset node
108
109     Returns
110     -----
111     out : tuple
112         A tuple with the path to the data, the dtype, a number 0 (not a table),
113         1 (table) or 2 (column wise table) and the numpy array with the data.
114     """
115     if hasattr(dataset, 'colnames'):
116         for col_name in dataset.colnames:
117             col = dataset.col(col_name)
118             if col.size * col.dtype.itemsize > MINIMUM_SIZE:
119                 yield dataset._v.pathname + '.' + col_name, col.dtype, 1, \
120                     col[:,].reshape(funcitools.reduce(
121                         lambda x, y: x * y, col.shape))
122             col_shape = dataset.description.__getattribute__(col_name).shape

```

```

124         if (len(col_shape) > 1 or
125             (len(col_shape) > 0 and col_shape[0] > 1)):
126             yield dataset._v.pathname + '.' + col_name, col.dtype, 2,
127             np.moveaxis(col, 0, -1)[:,].reshape(functools.reduce(
128                 lambda x, y: x * y, col.shape))
129     else:
130         yield dataset._v.pathname, dataset.dtype, 0,
131         dataset[:,].reshape(functools.reduce(lambda x, y: x * y, dataset.shape))
132
133
134 def file_reader(filename):
135     """
136     Generate the buffers of data in `filename`.
137
138     Parameters
139     -----
140     filename : str
141         The name of the HDF5 file.
142
143     Returns
144     -----
145     out : tuple
146         A tuple with the path to the data, the dtype, a number 0 (not a table),
147         1 (table) or 2 (column wise table) and the numpy array with the data.
148     """
149     with tables.open_file(filename) as f:
150         group_queue = Queue()
151         group_queue.put(f.root)
152         while not group_queue.empty():
153             try:
154                 for child in group_queue.get():
155                     if hasattr(child, 'dtype'):
156                         if child.size_in_memory > MINIMUM_SIZE:
157                             yield from dataset_extractor(child)
158                         elif hasattr(child, '_v_children'):
159                             group_queue.put(child)
160             except TypeError:
161                 pass
162             except tables.HDF5ExtError:
163                 pass
164
165
166 def calculate_nchunks(type_size, buffer_size):
167     """
168     Calculate the number of chunks.
169
170     Parameters
171     -----
172     type_size : int
173         The type size in bytes.
174     buffer_size : int
175         The buffer size in number of elements.

```

```

176
177     Returns
178
179     out : int
180         The number of chunks associated with the buffer and chunk size.
181     """
182     chunks_aux = int(CHUNK_SIZE / type_size)
183     q, r = divmod(buffer_size, chunks_aux)
184     n_chunks = q
185     if r != 0:
186         n_chunks += 1
187     return n_chunks
188
189
190 def extract_chunk_features(chunk):
191     """
192         Extract the statistics features in `chunk`.
193
194     Parameters
195
196     chunk : numpy.array
197         An array of numbers.
198
199     Returns
200
201     out : tuple
202         A tuple containing the mean, median, standard deviation, skewness,
203         kurtosis, minimum, maximum and quartiles.
204     """
205     if np.isnan(chunk).any():
206         return np.nanmean(chunk), np.nanmedian(chunk), np.nanstd(chunk),
207         stats.skew(chunk, nan_policy='omit'),
208         stats.kurtosis(chunk, nan_policy='omit'), np.nanmin(chunk),
209         np.nanmax(chunk), np.nanpercentile(chunk, 25),
210         np.nanpercentile(chunk, 75)
211     else:
212         return np.mean(chunk), np.median(chunk), np.std(chunk),
213         stats.skew(chunk), stats.kurtosis(chunk), np.min(chunk), np.max(chunk),
214         np.percentile(chunk, 25), np.percentile(chunk, 75)
215
216
217 def calculate_streaks(chunk, median):
218     """
219         Calculate number of streaks.
220
221     Parameters
222
223     chunk : numpy.array
224         An array of numbers.
225     median : number
226         The median of the chunk.
227

```

```

228 Returns
229
230 out : int
231     Number of streaks above/below median of the chunk.
232 """
233 streaks = 1
234 above = chunk[0] > median
235 for number in chunk[1:]:
236     if above != (number > median):
237         streaks += 1
238         above = not above
239 return streaks
240
241
242 FILENAMES = ('HiSPARC.h5',)
243 PATH = '/home/francesc/datasets/tests/'
244 BLOCK_SIZES = (0, MINIMUM_SIZE, KB16, KB32, KB64, KB128, KB256, KB512, MB, MB2)
245 CLEVELS = range(1, 10)
246 COLS = ['Filename', 'DataSet', 'Table', 'DType', 'Chunk_Number', 'Chunk_Size',
247          'Mean', 'Median', 'Sd', 'Skew', 'Kurt', 'Min', 'Max', 'Q1', 'Q3',
248          'N_Streaks', 'Block_Size', 'Codec', 'Filter', 'CL', 'CRate', 'CSpeed',
249          'DSpeed']
250 blosc.set_nthreads(4)
251
252 if not os.path.isfile('blosc_test_data.csv'):
253     pd.DataFrame(columns=COLS).to_csv(
254         'blosc_test_data.csv', sep='\t', index=False)
255
256 for filename in FILENAMES:
257     for path, d_type, table, buffer in file_reader(PATH + filename):
258         n_chunks = calculate_nchunks(buffer.dtype.itemsize, buffer.size)
259         print("Starting tests with %s %s t%s" % (filename, path, table))
260         if buffer.dtype.kind in ('S', 'U'):
261             is_string = True
262             filters = (blosc.NOSHUFFLE,)
263         else:
264             is_string = False
265             filters = (blosc.NOSHUFFLE, blosc.SHUFFLE, blosc.BITSHUFFLE)
266         for i, chunk in enumerate(chunk_generator(buffer)):
267             chunk_id = (filename, path, table, d_type, i + 1,
268                         chunk.size * chunk.dtype.itemsize / MB)
269             if is_string:
270                 chunk_features = (0, 0, 0, 0, 0, 0, 0, 0, 0, 0)
271             else:
272                 chunk_features = extract_chunk_features(chunk)
273                 chunk_features += (calculate_streaks(chunk,
274                                         chunk_features[1]),)
275         df = pd.DataFrame()
276         for block_size in BLOCK_SIZES:
277             blosc.set_blocksize(block_size)
278             for codec in blosc.compressor_list():
279                 for filt in filters:

```

```

280     for clevel in C_LEVELS:
281         row_data = chunk_id + chunk_features \
282                     + (block_size / 2**10, codec,
283                         blosc.filters[filt], clevel) \
284                     + test_codec(chunk, codec, filt, clevel)
285         df = df.append(
286             dict(zip(COLS, row_data)), ignore_index=True)
287         print("%5.2f %%-%s %s chunk %d completed" %
288               ((i + 1) / n_chunks * 100, filename, path, (i + 1)))
289         with open('blosc_test_data.csv', 'a') as f:
290             df = df[COLS]
291             df.to_csv(f, sep='\t', index=False, header=False)
292         print('CHUNK WRITED')

```


Anexo B

Análisis descriptivo de las pruebas de compresión

El informe realizado de análisis descriptivo de los datos extraídos en las pruebas de compresión se hizo en *jupyter notebook*. Además para que el informe fuese más legible se extrajo la mayor parte del código a un modulo *Python* que contiene todas las funciones auxiliares utilizadas para realizar gráficas personalizadas. A continuación se presenta el modulo *Python* **custom_plots.py** con las funciones auxiliares mencionadas y el informe con el análisis descriptivo **blosc_test_analysis.ipynb**.

B.1. Código custom_plots.py

```
1 import itertools
2 import numpy as np
3 import matplotlib.pyplot as plt
4 import matplotlib.lines as mlines
5 from scipy.stats.stats import pearsonr
6
7 # DICTIONARIES FOR BUILDING PERSONALIZED GRAPHS
8 COLOR_PALETTE = {'blosclz': '#5AC8FA', 'lz4': '#4CD964', 'lz4hc': '#FF3B30',
9                   'snappy': '#FFCC00', 'zlib': '#FF9500', 'zstd': '#5856D6'}
10 MARKER_DICT = {'noshuffle': 'o', 'shuffle': 'v', 'bitshuffle': 's'}
11
12 # DIFFERENT COLUMN LISTS FROM THE DATAFRAME FOR SELECTING SPECIFIC INFO
13 COLS = ['Filename', 'DataSet', 'Table', 'DType', 'Chunk_Number', 'Chunk_Size',
14          'Mean', 'Median', 'Sd', 'Skew', 'Kurt', 'Min', 'Max', 'Q1', 'Q3',
15          'N_Streaks', 'Block_Size', 'Codec', 'Filter', 'CL', 'CRate', 'CSpeed',
16          'DSpeed']
```

```

18 DESC_SET = ['DataSet', 'DType', 'Table', 'Chunk_Size']
19 CHUNK_FEATURES = ['Chunk_Size', 'Mean', 'Median', 'Sd',
20                   'Skew', 'Kurt', 'Min', 'Max', 'Q1', 'Q3', 'N_Streaks']
21 TEST_FEATURES = ['CRate', 'CSpeed', 'DSpeed']
22 ALLFEATURES = CHUNKFEATURES + TESTFEATURES
23
24 # AUX LIST FOR SELECTING DATAFRAMES
25 TYPES = ['float', 'int', 'str']
26 BLOCK_SIZES = [8, 16, 32, 64, 128, 256, 512, 1024, 2048]
27
28 # PATH TO FIGURES
29 FIG_PATH = '../figures/Blosc-test-analysis—'
30
31
32 # AUX FUNCTIONS
33 def outlier_lim(data):
34     """Return the outliers limits."""
35
36     q1 = np.percentile(data, 25)
37     q3 = np.percentile(data, 75)
38     dif = q3 - q1
39
40     return q1 - 1.5 * dif, q3 + 1.5 * dif, dif
41
42
43 # PLOTTING FUNCTIONS
44 def custom_boxplot(ax, y, title='', ylabel=''):
45     """Customized boxplot style."""
46
47     meanpointprops = dict(marker='D', markeredgecolor='black',
48                           markerfacecolor='#FF3B30', markersize=8)
49     medianprops = {'color': '#4CD964', 'linewidth': 3}
50     boxprops = {'edgecolor': 'black', 'linestyle': '--', 'facecolor': '#EFEFF4'}
51     whiskerprops = {'color': 'black', 'linestyle': '-'}
52     capprops = {'color': 'black', 'linestyle': '-'}
53     flierprops = {'color': 'black', 'marker': 'o'}
54
55     ax.boxplot(y,
56                 medianprops=medianprops,
57                 boxprops=boxprops,
58                 whiskerprops=whiskerprops,
59                 capprops=capprops,
60                 flierprops=flierprops,
61                 meanprops=meanpointprops,
62                 meanline=False,
63                 showmeans=True,
64                 widths=0.5,
65                 patch_artist=True)
66
67     ax.set_title(title)
68     ax.set_ylabel(ylabel)
69

```

```

70     return ax
71
72
73 def custom_centered_scatter(ax, x, y):
74     """Customized scatter plot ignoring outliers."""
75
76     x_lim = outlier_lim(x)
77     y_lim = outlier_lim(y)
78     x_, y_ = [], []
79     for i in range(len(x)):
80         if (x_lim[0] <= x.iloc[i] <= x_lim[1] and
81             y_lim[0] <= y.iloc[i] <= y_lim[1]):
82             x_.append(x.iloc[i])
83             y_.append(y.iloc[i])
84     ax.scatter(x_, y_, color="#007AFF", marker='.', linewidth=3)
85     if x_lim[2] > 0 and y_lim[2] > 0:
86         ax.set_xlim(x_lim[0:2])
87         ax.set_ylim(y_lim[0:2])
88         fit = np.polyfit(x_, y_, deg=1)
89         x_ = np.sort(x_)
90         ax.plot(x_, fit[0] * x_ + fit[1], color="#FF3B30", linewidth=3)
91     ax.spines['top'].set_visible(False)
92     ax.spines['right'].set_visible(False)
93
94     return ax
95
96
97 def custom_pearson_scatter(ax, x_, y_, c_, m_, title, dtype):
98     """Customized scatter plot for correlations."""
99
100    for x, y, c, m, size in zip(x_, y_, c_, m_, np.asarray(
101        list(itertools.repeat([10, 16], len(c_))))).flatten()):
102        ax.plot(x, y, alpha=0.8, c=c, marker=m, linewidth=3, markersize=size)
103    ax.set_axisbelow(True)
104    ax.yaxis.grid(color="#CECED2")
105    ax.xaxis.grid(color="#CECED2")
106    ax.set_xlabel('Pearson C. Rates')
107    ax.set_ylabel('Pearson C. Speeds')
108    ax.set_title(title + ' - PEARSON - ' + dtype.upper())
109    ax.spines['top'].set_visible(False)
110    ax.spines['right'].set_visible(False)
111
112    return ax
113
114
115 def custom_sc_legend(fig):
116     """Customized legend for the correlation plots."""
117
118     handles = [mlines.Line2D([], [], color=color, marker='o', linestyle=' ', 
119                             markersize=10, label=label)
120               for label, color in COLOR_PALETTE.items()]
121     handles += [mlines.Line2D([], [], color='k', marker='o', linestyle=' ',
```

```

122                         markersize=10, label='NOSHUFFLE') ,
123     mlines.Line2D([], [], color='k', marker='v', linestyle=' ' ,
124                           markersize=10, label='SHUFFLE') ,
125     mlines.Line2D([], [], color='k', marker='s', linestyle=' ' ,
126                           markersize=10, label='BITSHUFFLE') ,
127     mlines.Line2D([], [], color='k', marker='o', linestyle=' ' ,
128                           markersize=10, label='Compression Level 1') ,
129     mlines.Line2D([], [], color='k', marker='o', linestyle=' ' ,
130                           markersize=16, label='Compression Level 9')] )
131 labels = [label for label in COLOR_PALETTE.keys()]
132 labels += ['NOSHUFFLE', 'SHUFFLE', 'BITSHUFFLE',
133             'Compression Level 1', 'Compression Level 9']
134 fig.legend(handles=handles, labels=labels, loc='lower left',
135             ncol=2, bbox_to_anchor=(1, 0.05))
136 fig.tight_layout()
137
138 return fig
139
140
141 def custom_lineplot_tests(ax, x, rates, c_speeds, d_speeds, title='',
142                           cl_mode=False):
143     """Customized line plot for blosc test data."""
144
145     ax.plot(x, rates, color='#007AFF', marker='o', markersize=8, linewidth=3)
146     ax.set_axisbelow(True)
147     ax.yaxis.grid(color='#CECED2')
148     ax.xaxis.grid(color='#CECED2')
149     ax.set_ylabel('Compression Rate', color='#007AFF')
150     ax.tick_params('y', colors='#007AFF')
151     blue_line = mlines.Line2D([], [], color='#007AFF', marker='o',
152                               markersize=8, label='Compression ratio')
153     plt.legend(handles=[blue_line], loc=2, bbox_to_anchor=(0., 1.01, 0., .102))
154     ax2 = ax.twinx()
155     ax2.plot(x, c_speeds, color='#FF3B30',
156               marker='o', markersize=8, linewidth=3)
157     ax2.plot(x, d_speeds, color='#4CD964',
158               marker='o', markersize=8, linewidth=3)
159     ax2.set_ylabel('Speed (GB/s)', color='k')
160     ax.set_yticks(np.linspace(ax.get_ybound()[0], ax.get_ybound()[1], 6))
161     ax2.set_yticks(np.linspace(ax2.get_ybound()[0], ax2.get_ybound()[1], 6))
162     red_line = mlines.Line2D([], [], color='#FF3B30', marker='o',
163                             markersize=8, label='Compression')
164     green_line = mlines.Line2D([], [], color='#4CD964', marker='o',
165                               markersize=8, label='Decompression')
166     plt.legend(handles=[red_line, green_line], loc=1,
167                bbox_to_anchor=(0., 1.01, 1., .102))
168 if not cl_mode:
169     ax.set_xscale('log', basex=2)
170     ax.set_xticks(x)
171     ax.set_xticklabels(['Auto', '8K', '16K', '32K', '64K',
172                        '128K', '256K', '512K', '1MB', '2MB'])
173     ax.set_xlabel('Block Size')

```

```

174     else:
175         ax.set_xticks(x)
176         ax.set_xlabel('Compression level')
177     ax.set_title(title)
178     ax.spines['top'].set_visible(False)
179     ax2.spines['top'].set_visible(False)
180
181     return ax
182
183
184 def boxplot_data_builder(df):
185     """Build data for the boxplots."""
186
187     rates = []
188     c_speeds = []
189     d_speeds = []
190     indices = []
191     for i in range(3):
192         if i == 2:
193             dfaux = df[df.DType.str.contains('U') | df.DType.str.contains('S')]
194         else:
195             dfaux = df[df.DType.str.contains(TYPES[i])]
196         if dfaux.size > 0:
197             rates.append([dfaux['CRate']])
198             c_speeds.append([dfaux['CSpeed']])
199             d_speeds.append([dfaux['DSpeed']])
200             indices.append(i)
201     return rates, c_speeds, d_speeds, indices
202
203
204 def paint_dtype_boxplots(df):
205     """Paint boxplots structured by dtype."""
206
207     rates, c_speeds, d_speeds, indices = boxplot_data_builder(df)
208     n = len(rates)
209     if n > 1:
210         fig = plt.figure(figsize=(20, 24))
211         for i in range(n * 3):
212             aux = 300 + n * 10 + i + 1
213             pos = i % n
214             ax = fig.add_subplot(aux)
215             if i < n:
216                 custom_boxplot(ax, rates[pos],
217                                 'C.Rates-' + TYPES[indices[pos]],
218                                 'Compression Rates')
219             elif i < n * 2:
220                 custom_boxplot(ax, c_speeds[pos],
221                                 'C.Speeds-' + TYPES[indices[pos]],
222                                 'Compression Speeds (GB/s)')
223             else:
224                 custom_boxplot(ax, d_speeds[pos],
225                                 'D.Speeds-' + TYPES[indices[pos]],
```

```

226                                     'Decompression Speeds (GB/s)')
227
228     else:
229         fig = plt.figure(figsize=(20, 8))
230         custom_boxplot(fig.add_subplot(131), rates[0],
231                         'C.Rates-' + TYPES[indices[0]], 'Compression Rates')
232         custom_boxplot(fig.add_subplot(132), c_speeds[0],
233                         'C.Speeds-' + TYPES[indices[0]],
234                         'Compression Speeds (GB/s)')
235         custom_boxplot(fig.add_subplot(133), d_speeds[0],
236                         'D.Speeds-' + TYPES[indices[0]],
237                         'Decompression Speeds (GB/s)')
238     fig.suptitle('Test features boxplots')
239     plt.savefig(FIG.PATH + 'Test features boxplots' +
240                 '.png', bbox_inches='tight')
241
242 def block_cor_data_builder(df, onlystr, cl_mode):
243     """Build data for the block correlation graphs"""
244
245     rates = []
246     c_speeds = []
247     d_speeds = []
248     indices = []
249     block_values = [0] + BLOCK_SIZES
250     if onlystr:
251         options = [2]
252     else:
253         options = range(3)
254     for i in options:
255         if i == 2:
256             dfaux = df[df.DType.str.contains('U') | df.DType.str.contains('S')]
257         else:
258             dfaux = df[df.DType.str.contains(TYPES[i])]
259         if dfaux.size > 0:
260             if not cl_mode:
261                 rates.append([dfaux[dfaux.Block_Size == size]
262                               [ 'CRate'].mean() for size in block_values])
263                 c_speeds.append([dfaux[dfaux.Block_Size == size]
264                               [ 'CSpeed'].mean() for size in block_values])
265                 d_speeds.append([dfaux[dfaux.Block_Size == size]
266                               [ 'DSpeed'].mean() for size in block_values])
267                 indices.append(i)
268             else:
269                 rates.append([dfaux[dfaux.CL == cl][ 'CRate'].mean()
270                               for cl in list(range(10))[1:]])
271                 c_speeds.append([dfaux[dfaux.CL == cl][ 'CSpeed'].mean()
272                               for cl in list(range(10))[1:]])
273                 d_speeds.append([dfaux[dfaux.CL == cl][ 'DSpeed'].mean()
274                               for cl in list(range(10))[1:]])
275                 indices.append(i)
276
277     return rates, c_speeds, d_speeds, indices

```

```

278
279
280 def paint_block_cor(df, title='', onlystr=False, cl_mode=False):
281     """Paint custom lineplots structured by dtype."""
282
283     rates, c_speeds, d_speeds, indices = block_cor_data_builder(
284         df, onlystr, cl_mode)
285     if not cl_mode:
286         x = [1] + BLOCK_SIZES
287     else:
288         x = list(range(10))[1:]
289     n = len(rates)
290     fig = plt.figure(figsize=(20, 8))
291     sup_title = 'Block Size'
292     if cl_mode:
293         sup_title = 'Compression Level'
294     fig.suptitle(sup_title + ' comparison with ' + title, fontsize=16)
295     for i in range(n):
296         pos = 100 + n * 10 + i + 1
297         ax = fig.add_subplot(pos)
298         custom_lineplot_tests(ax, x, rates=rates[i], c_speeds=c_speeds[i],
299                               d_speeds=d_speeds[i],
300                               title='dtype - ' + TYPES[indices[i]],
301                               cl_mode=cl_mode)
302     if n > 1:
303         fig.tight_layout()
304     plt.subplots_adjust(top=0.85)
305     plt.savefig(FIG_PATH + sup_title + ' comparison with ' +
306                 title + '.png', bbox_inches='tight')
307
308
309 def paint_all_block_cor(df, filter_name, c_level=5, cl_mode=False,
310                         block_size=0):
311     """Paint all custom lineplots for filter."""
312
313     if filter_name == 'noshuffle':
314         onlystr = True
315     else:
316         onlystr = False
317     for codec in df.drop_duplicates(subset=['Codec'])['Codec']:
318         if codec == 'blosclz' and filter_name == 'shuffle':
319             if not cl_mode:
320                 paint_block_cor(df[(df.CL == c_level) & (df.Codec == codec) &
321                                     (df.Filter == 'bitshuffle')],
322                                 codec.upper() + '-BITSHUFFLE-CL' +
323                                 str(c_level), onlystr, cl_mode)
324             else:
325                 paint_block_cor(
326                     df[(df.Block_Size == block_size) & (
327                         df.Codec == codec) & (df.Filter == 'bitshuffle')],
328                     codec.upper() + '-BITSHUFFLE-BLOCK' + str(block_size),
329                     onlystr, cl_mode)

```

```

330     if not cl_mode:
331         paint_block_cor(df[(df.CL == c_level) & (df.Codec == codec) &
332                           (df.Filter == filter_name)],
333                           codec.upper() + '-' + filter_name.upper() + '-CL' +
334                           str(c_level), onlystr, cl_mode)
335     else:
336         paint_block_cor(
337             df[(df.Block_Size == block_size) & (
338                 df.Codec == codec) & (df.Filter == filter_name)],
339                 codec.upper() + '-' + filter_name.upper() + '-BLOCK' +
340                 str(block_size), onlystr, cl_mode)
341
342 def paint_cl_comparison(df, filter_name, codec):
343     """Paint custom plots comparing compression levels and block sizes."""
344
345     data = []
346     c_levels = [1, 3, 6, 9]
347     for c_level in c_levels:
348         data.append(block_cor_data_builder(df[(df.CL == c_level) &
349                                           (df.Codec == codec) &
350                                           (df.Filter == filter_name)],
351                                           False, False))
352
353     block_sizes = [1] + BLOCK_SIZES
354     n = len(data[0][0])
355     for i in range(n):
356         fig = plt.figure(figsize=(20, 16))
357         fig.suptitle('Compression Level and block size comparison ' +
358                      codec.upper() + '-' +
359                      TYPES[data[0][3][i]].upper(), fontsize=16)
360         for j in range(4):
361             pos = 200 + 20 + j + 1
362             ax = fig.add_subplot(pos)
363             custom_lineplot_tests(ax, block_sizes, data[j][0][i],
364                                   data[j][1][i], data[j][2][i],
365                                   title='C-Level ' + str(c_levels[j]))
366         if n > 1:
367             fig.tight_layout()
368         plt.subplots_adjust(top=0.9, hspace=0.2)
369         plt.savefig(FIG_PATH + 'Compression Level and block size comparison ' +
370                     codec.upper() + '-' +
371                     TYPES[data[0][3][i]].upper() + '.png', bbox_inches='tight')
372
373 def pearson_cor_data_builder(df, cname, clevel):
374     """Build data for codec correlation graphs."""
375
376     pearson_rates = [[], [], []]
377     pearson_c_speeds = [[], [], []]
378     codecs_cl = [[], [], []]
379     colors = [[], [], []]
380     markers = [[], [], []]

```

```

382     for codec in df.drop_duplicates(subset=['Codec'])['Codec']:
383         for filt in ['noshuffle', 'shuffle', 'bitshuffle']:
384             df_b1z1 = df[(df.Codec == cname) & (df.CL == clevel)
385                         & (df.Filter == 'noshuffle')]
386             for c_level in [1, 9]:
387                 df_codec = df[(df.Codec == codec) &
388                               (df.CL == c_level) & (df.Filter == filt)]
389                 for i in range(3):
390                     if i == 2:
391                         dfaux = df_codec[df_codec.DType.str.contains(
392                                         'U') | df_codec.DType.str.contains('S')]
393                         df_b1z_aux = df_b1z1[df_b1z1.DType.str.contains(
394                                         'U') | df_b1z1.DType.str.contains('S')]
395                     else:
396                         dfaux = df_codec[df_codec.DType.str.contains(TYPES[i])]
397                         df_b1z_aux = df_b1z1[df_b1z1.DType.str.contains(
398                                         TYPES[i])]
399                     if dfaux.size > 0:
400                         pearson_rates[i].append(
401                             pearsonr(df_b1z_aux['CRate'], dfaux['CRate']))
402                         pearson_c_speeds[i].append(
403                             pearsonr(df_b1z_aux['CSpeed'], dfaux['CSpeed']))
404                         codecs_cl[i].append(
405                             codec + '-' + filt + '-' + str(c_level) + '-' +
406                             TYPES[i])
407                         colors[i].append(COLOR_PALETTE[codec])
408                         markers[i].append(MARKER_DICT[filt])
409
410     return pearson_rates, pearson_c_speeds, codecs_cl, colors, markers
411
412
413 def paint_codec_pearson_corr(df, cname, clevel):
414     """Paint custom graphs for codec correlation."""
415
416     pearson_rates, pearson_c_speeds, codecs_cl, colors, markers = \
417         pearson_cor_data_builder(df, cname, clevel)
418
419     for i in range(3):
420         if len(pearson_rates[i]) > 0:
421             fig = plt.figure(figsize=(10, 9))
422             ax = fig.add_subplot(111)
423             custom_pearson_scatter(ax, [x[0] for x in pearson_rates[i]],
424                                     [x[0] for x in pearson_c_speeds[i]],
425                                     colors[i], markers[i], cname.upper() +
426                                     '-CL' + str(clevel), TYPES[i])
427             custom_sc_legend(fig)
428             plt.savefig(FIG_PATH + ax.get_title() +
429                         '.png', bbox_inches='tight')
430
431
432 def custom_pairs(df, col_names):
433     """Paint scatter matrix plot."""

```

```

434
435     print('%.d points' % df.shape[0])
436     fig, axs = plt.subplots(3, len(col_names), sharex='col', sharey='row')
437     fig.set_size_inches(20, 12)
438     for j, y in enumerate(['CRate', 'CSpeed', 'DSpeed']):
439         for i, x in enumerate(col_names):
440             custom_centered_scatter(axs[j, i], df[x], df[y])
441             if j == 2:
442                 axs[j, i].set_xlabel(x)
443             if i == 0:
444                 axs[j, i].set_ylabel(y)
445     fig.tight_layout()
446     fig.suptitle(str(col_names) + ' VS Test Features', fontsize=16)
447     plt.subplots_adjust(top=0.95, hspace=0.01, wspace=0)
448     plt.savefig(FIG_PATH + str(col_names) +
449                 'VS Test Features' + '.png', bbox_inches='tight')

```

B.2. Cuaderno blosc_test_analysis.ipynb

Análisis de las pruebas realizadas con Blosc

Objetivos del análisis

- Relacionar el tamaño de bloques con las medidas de compresión y decompresión.
- Comprobar el comportamiento de los niveles de compresión sobre las pruebas.
- Comparar los datos de compresión de tablas normales y columnares.
- ¿Existe correlación entre blosclz o lz4 con nivel de compresión 1 y el resto de codecs?
- [Punto muerto] ¿Existe correlación entre las características del chunk y las medidas de compresión y decompresión?

Descripción de la muestra

El DataFrame en cuestión está formado por las características extraídas de un array de datos al comprimirlo y descomprimirlo mediante blosc. En cada fichero aparecen distintos conjuntos de datos los cuales dividimos en fragmentos de 16 MegaBytes y sobre los cuales realizamos las pruebas de compresión y decompresión. Cada fila se corresponde con los datos de realizar los test de compresión sobre un fragmento (*chunk*) de datos específico con un tamaño de bloque, codec, filtro y nivel de compresión determinados.

Variable	Descripción
<i>filename</i>	nombre del fichero del que proviene.
<i>DataSet</i>	dentro del fichero el conjunto de datos del que proviene.
<i>Table</i>	0 si los datos vienen de un array, 1 si vienen de tablas y 2 para tablas columnares.
<i>DTyPe</i>	indica el tipo de los datos.
<i>Chunk_Number</i>	número de fragmento dentro del conjunto de datos.
<i>Chunk_Size</i>	tamaño del fragmento.
<i>Mean</i>	la media.
<i>Median</i>	la mediana.
<i>Sd</i>	la desviación típica.
<i>Skew</i>	el coeficiente de asimetría.
<i>Kurt</i>	el coeficiente de apuntamiento.
<i>Min</i>	el mínimo absoluto.
<i>Max</i>	el máximo absoluto.
<i>Q1</i>	el primer cuartil.
<i>Q3</i>	el tercer cuartil.
<i>N_Streaks</i>	número de rachas seguidas por encima o debajo de la mediana.
<i>Block_Size</i>	el tamaño de bloque que utilizará Blosc para comprimir.
<i>Codec</i>	el codec de blosc utilizado.
<i>Filter</i>	el filtro de blosc utilizado.
<i>CL</i>	el nivel de compresión utilizado.
<i>CRate</i>	el ratio de compresión obtenido.
<i>CSpeed</i>	la velocidad de compresión obtenida en GB/s.
<i>DSpeed</i>	la velocidad de decompresión obtenida en GB/s.

```
In [1]: %matplotlib inline
%config InlineBackend.figure_format='retina'

%load_ext autoreload
%autoreload 2

%load_ext version_information
%version_information numpy, scipy, matplotlib, pandas
```

Software	Version
Python	3.5.3 64bit (GCC 4.4.7 20120313 (Red Hat 4.4.7-1))
iPython	5.1.0
OS	Linux 4.9.16 gentoo x86_64 with debian stretch sid
numpy	1.12.1
scipy	0.19.0
matplotlib	2.0.0
pandas	0.19.2
	Sat Apr 29 10:46:42 2017 UTC

```
In [2]: import os
import sys
sys.path.append("../src/")

from IPython.display import display
import matplotlib
from matplotlib import pyplot as plt
import pandas as pd

import custom_plots as cst

pd.options.display.float_format = '{:.3f}'.format
matplotlib.rcParams.update({'font.size': 12})
```

Descripción general

Cargamos el csv entero, comprobamos que no faltan campos y mostramos un breve resumen.

```

In [3]: # LOAD WHOLE CSV
my_df = pd.read_csv('../data/bosc_test_data_final.csv.gz', sep='\t')

# SORT COLUMNS
my_df = my_df[cst.COLS]

# CHECK MISSING DATA
if not my_df.isnull().any().any():
    print('No missing data')
else:
    print("Missing data")

```

No missing data

```

In [4]: # SUMMARY OF THE DATFRAME
display(my_df[cst.COLS[5:]].describe())

```

	Chunk_Size	Mean	Median	Sd	Skew	Kurt	Min
count	1,127,520.000	1,127,520.000	1,127,520.000	1,127,520.000	1,127,520.000	1,127,520.000	1,127,520.000
mean	14.384	5,855,203,352,860,118.000	5,855,510,553,455,461.000	3,338,034,656,223,127	12,276	2,960,293	5,849,131,049,179
std	3.965	88,991,425,790,313,680.000	88,996,095,055,340,192.000	50,744,320,308,850,523	40.009	20,641,213	88,899,134,721,54
min	0.015	-996,946	-999,000	0.000	-134,250	-3,000	-999,000
25%	16.000	0.000	0.000	0.183	0.062	-0.888	-14,210
50%	16.000	0.101	0.000	2.679	3.052	12.431	0.000
75%	16.000	3.121	0.001	59.326	9.994	184.219	0.000
max	16.000	1,358,459,542,578,043,904.000	1,358,622,091,149,467,648.000	795,493,396,001,273,125	497,825	316,831,759	1,356,998,404,761

Como se puede observar hay mucha variabilidad en nuestros datos, lo cual es bueno.

Veamos cuantos conjuntos de datos tiene el fichero.

```

In [5]: sets = my_df.drop_duplicates(subset=['DataSet', 'Table'])[[cst.DESC_SET]]
print('First ten datasets')
display(sets.head(n=10))
print('There are %d datasets' % (sets.shape[0]))

```

First ten datasets

	DataSet	DType	Table	Chunk_Size
0	/U	float32	0.000	16.000
85860	/V	float32	0.000	16.000
150660	/Grids/G1/precipAllObs	int32	0.000	0.738
152280	/Grids/G1/surfPrecipLiqRateProb	float32	0.000	0.015
153900	/Grids/G1/surfPrecipLiqRateUn	float32	0.000	0.015
155520	/Grids/G1/surfPrecipTotRateUnurnalAllObs	int32	0.000	1.107
157140	/Grids/G1/surfPrecipTotRateProb	float32	0.000	0.015
158760	/Grids/G1/surfPrecipTotRateUn	float32	0.000	0.015
160380	/Grids/G2/precipAllObs	int32	0.000	16.000
170100	/Grids/G2/surfPrecipLiqRateProb	float32	0.000	5.889

There are 120 datasets

Tablas de referencia de los conjuntos de datos

Procedemos a mostrar un resumen de las características extraídas de cada conjunto de datos.

```

In [6]: for dataset in sets.drop_duplicates(subset=['DataSet']):
    set_info = sets[sets.DataSet == dataset]
    print('SUMMARY')
    print(set_info)
    aux_set = my_df[my_df.DataSet == dataset].drop_duplicates(subset=[cst.CHUNK_NUMBER])
    if aux_set.shape[0] > 1:
        display(aux_set.describe()[cst.CHUNK_FEATURES])
    else:
        display(aux_set[cst.CHUNK_FEATURES])

```

SUMMARY

DataSet	Dtype	Table	Chunk_Size	
0	/U	float32	0.000	16.000

Chunk_Size	Mean	Median	Sd	Skew	Kurt	Min	Max	Q1	Q3	N_Streaks
count	53.000	53.000	53.000	53.000	53.000	53.000	53.000	53.000	53.000	53.000
mean	14.314	9.838	12.731	0.624	-0.720	-15.663	48.531	4.747	24.449	94,648,358
std	1.995	4.350	3.881	2.527	0.153	0.319	4.249	9.016	3.546	6.457
min	1.475	5.762	2.096	6.404	0.228	-1.164	-28.273	27.146	-1.446	11.317
25%	16.000	10.708	7.198	11.469	0.532	-0.921	-17.664	43.313	1.943	18.781
50%	16.000	15.430	9.564	13.268	0.649	-0.793	-14.891	50.507	4.873	25.905
75%	16.000	17.302	13.019	14.752	0.738	-0.624	-12.637	53.064	7.273	27.890
max	16.000	22.909	16.944	17.010	1.072	0.549	-9.488	62.922	10.356	38.366

SUMMARY

DataSet	Dtype	Table	Chunk_Size	
85860	/V	float32	0.000	16.000

Chunk_Size	Mean	Median	Sd	Skew	Kurt	Min	Max	Q1	Q3	N_Streaks
count	40.000	40.000	40.000	40.000	40.000	40.000	40.000	40.000	40.000	40.000
mean	2.073	1.526	4.976	0.311	0.901	-16.644	23.037	-1.197	4.881	194,369,825
std	0.631	2.517	1.696	2.391	0.510	0.742	4.047	9.672	1.472	3.369
min	12.009	-1.626	-1.256	2.474	-0.600	-0.370	-29.640	13.443	-4.887	0.552
25%	16.000	-0.240	-0.088	3.414	-0.031	-0.162	-19.447	16.708	-2.397	2.357
50%	16.000	1.886	1.721	4.303	0.253	0.240	-16.237	20.683	-0.907	4.500
75%	16.000	3.743	2.851	5.930	0.644	0.484	-13.344	25.571	-0.204	6.422

max	16.000	9.091	4.968	14.419	1.748	4.040	-11.483	56.161	1.253	15.373	293,423.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
150660	/Grids/G1/precipAllObs	int32	0.000	0.738							
SUMMARY											
DataSet Dtype Table Chunk_Size											
150660	0.738	46,750.635	42,412.000	42,964.463	1.123	2.123	0.000	211,383.000	121.000	79,434.750	27,744.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
152280	/Grids/G1/surfPrecipLiqRateProb	float32	0.000	0.015							
152280	0.015	0.044	0.037	0.040	1.346	3.059	0.000	0.352	0.011	0.066	1,032.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
153900	/Grids/G1/surfPrecipLiqRateEth	float32	0.000	0.015							
153900	0.015	0.092	0.048	0.123	2.762	12.094	0.000	1.414	0.011	0.124	992.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
155520	/Grids/G1/surfPrecipTotRateDiurnalAllObs	int32	0.000	1.107							
155520	1.107	1,947.943	272.000	2,888.095	2.804	13.277	0.000	24,063.000	0.000	3,094.000	31,604.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
157140	/Grids/G1/surfPrecipTotRateProb	float32	0.000	0.015							
157140	0.015	0.050	0.043	0.040	1.218	2.721	0.000	0.352	0.018	0.072	1,137.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
158760	/Grids/G1/surfPrecipTctRateUn	float32	0.000	0.015							
158760	0.015	0.101	0.064	0.121	2.739	12.272	0.000	1.414	0.022	0.133	1,099.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
160380	/Grids/G2/precipAllObs	int32	0.000	16.000							
160380	6.000	6.000	6.000	6.000	6.000	6.000	6.000	6.000	6.000	6.000	6.000
count	6.000	6.000	6.000	6.000	6.000	6.000	6.000	6.000	6.000	6.000	6.000
mean	15.703	183.354	173.500	107.464	2.317	9.421	0.000	910.000	116.167	222.333	198,604.333
std	0.727	6.775	10.710	1.604	0.023	0.173	0.000	0.000	5.742	4.502	14,750.195
min	14.219	176.954	163.000	105.856	2.292	9.218	0.000	910.000	111.000	218.000	179,642.000
25%	16.000	177.709	164.250	106.084	2.296	9.273	0.000	910.000	111.500	218.500	188,721.000
50%	16.000	181.741	171.500	107.211	2.316	9.426	0.000	910.000	114.500	221.500	197,790.500
75%	16.000	187.916	181.750	108.644	2.338	9.577	0.000	910.000	119.750	225.250	210,105.250
max	16.000	193.347	188.000	109.676	2.342	9.605	0.000	910.000	125.000	229.000	216,495.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
170100	/Grids/G2/surfPrecipLiqRateProb	float32	0.000	5.889							
170100	5.889	0.045	0.009	0.074	2.804	12.031	0.000	1.000	0.000	0.063	291,171.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
171720	/Grids/G2/surfPrecipLiqRateEth	float32	0.000	5.889							
171720	5.889	0.094	0.004	0.337	12.404	321.944	0.000	26.186	0.000	0.051	288,953.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
173340	/Grids/G2/surfPrecipTotRateDiurnalAllObs	int32	0.000	16.000							
count	9.000	9.000	9.000	9.000	9.000	9.000	9.000	9.000	9.000	9.000	9.000
mean	15.703	7.629	0.000	12.705	1.798	4.317	0.000	102.222	0.000	13.778	154,746.778
std	0.891	1.237	0.000	0.843	0.792	4.134	0.000	17.683	0.000	8.059	56,353.353
min	13.328	5.467	0.000	11.541	0.728	-1.091	0.000	65.000	0.000	0.000	80,589.000
25%	16.000	7.239	0.000	11.730	1.005	-0.012	0.000	93.000	0.000	14.000	109,781.000
50%	16.000	8.051	0.000	12.935	1.725	4.011	0.000	113.000	0.000	18.000	161,634.000
75%	16.000	8.505	0.000	13.343	2.259	6.763	0.000	113.000	0.000	19.000	207,840.000
max	16.000	9.073	0.000	13.710	2.875	9.967	0.000	114.000	0.000	20.000	223,100.000
SUMMARY											
DataSet Dtype Table Chunk_Size											
187920	/Grids/G2/surfPrecipTotRateProb	float32	0.000	5.889							
187920	5.889	0.050	0.017	0.075	2.606	10.682	0.000	1.000	0.000	0.074	305,495.000

SUMMARY												
	DataSet	DType	Table	Chunk_Size								
1116180	/s506/events.n3	float32	1.000	7.224								
1116180	7.224	0.860	0.553	1.942	-134.250	74,975.796	-999.000	310.790	0.000	1.207	946,423.000	
SUMMARY												
	DataSet	DType	Table	Chunk_Size								
1117800	/s506/events.n4	float32	1.000	7.224								
1117800	7.224	0.890	0.603	1.544	13.214	1,255.583	-1.000	321.740	0.000	1.259	947,489.000	
SUMMARY												
	DataSet	DType	Table	Chunk_Size								
1119420	/s506/events.t1	float32	1.000	7.224								
1119420	7.224	-370.239	12.500	611.587	0.584	0.980	-999.000	5,022.500	-999.000	15.000	845,656.000	
SUMMARY												
	DataSet	DType	Table	Chunk_Size								
1121040	/s506/events.t2	float32	1.000	7.224								
1121040	7.224	-307.761	12.500	598.034	0.377	0.818	-999.000	5,017.500	-999.000	20.000	938,072.000	
SUMMARY												
	DataSet	DType	Table	Chunk_Size								
1122660	/s506/events.t3	float32	1.000	7.224								
1122660	7.224	-386.432	12.500	616.676	0.677	1.328	-999.000	5,385.000	-999.000	17.500	911,415.000	
SUMMARY												
	DataSet	DType	Table	Chunk_Size								
1124280	/s506/events.t4	float32	1.000	7.224								
1124280	7.224	-346.851	12.500	621.689	0.554	0.866	-999.000	5,122.500	-999.000	22.500	934,425.000	
SUMMARY												
	DataSet	DType	Table	Chunk_Size								
1125900	/s506/events.t_trigger	float32	1.000	7.224								
1125900	7.224	250.095	32.500	414.191	1.686	1.643	-999.000	4,997.500	22.500	267.500	940,519.000	

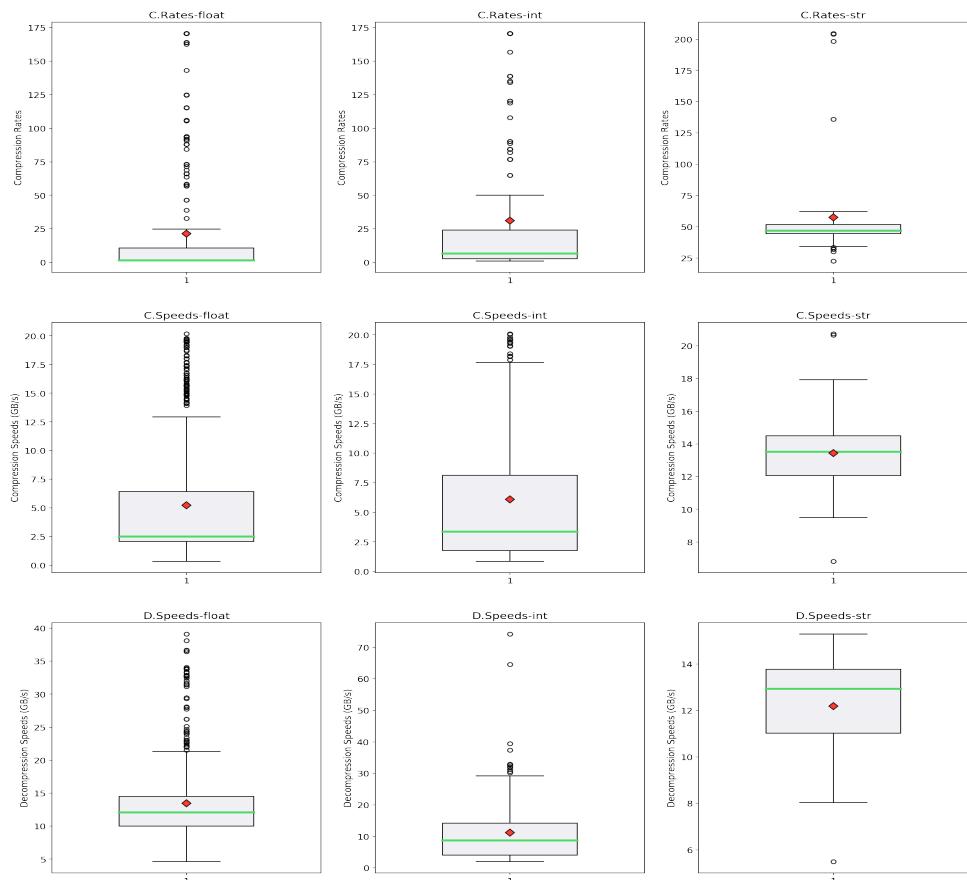
No entraremos en detalles sobre cada conjunto de datos, simplemente nos conviene tener estas tablas como referencia rápida en caso de detectar anomalías en algún conjunto en concreto.

Deteción de datos atípicos

Para evitar que los diagramas de caja estén plagados de datos atípicos, procedemos a filtrar con el codec blosclz, filtro shuffle, nivel de compresión 5 y tamaño de bloque automático para buscar con detenimiento datos atípicos.

```
in [7]: df_outliers = my_df[(my_df.Block_Size == 0) & (my_df.CL == 5) &
                           (my_df.Codec == 'blosclz') &
                           (my_df.Filter == 'noshuffle')]
cst.paint_dtype_boxplots(df_outliers)
```

Test features boxplots



Mostramos a continuación los datos atípicos

```
in [20]: for i in range(2):
    dfaux = df_outliers[df_outliers.DType.str.contains(cst.TYPES[i])]
    if dfaux.size > 0:
        cr_lim = cst.outlier_lim(dfaux['CRate'])
        cs_lim = cst.outlier_lim(dfaux['CSpeed'])
        ds_lim = cst.outlier_lim(dfaux['DSpeed'])
        result = dfaux[(dfaux.CRate < cr_lim[0]) |
                        (dfaux.CRate > cr_lim[1]) |
                        (dfaux.CSpeed < cs_lim[0]) |
                        (dfaux.CSpeed > cs_lim[1]) |
                        (dfaux.DSpeed < ds_lim[0]) |
                        (dfaux.DSpeed > ds_lim[1])][cst.ALL_FEATURES]
        if result.size > 0:
            print("%d %s OUTLIERS" % (result.shape[0],
                                         cst.TYPES[i].upper()))
            display(result.head())
81 FLOAT OUTLIERS
```

	Chunk_Size	Mean	Median	Sd	Skew	Kurt	Min	Max	Q1	Q3	N_Streaks	CRate	CSpeed	DSpeed
84244	1.475	7.835	6.866	6.404	0.414	0.209	-12.035	27.183	4.119	11.317	13,756.000	1.000	1.739	29.472
200884	2.215	0.456	0.000	1.532	8.146	210.120	0.000	122.311	0.000	0.000	28,860.000	2.935	3.793	38.118

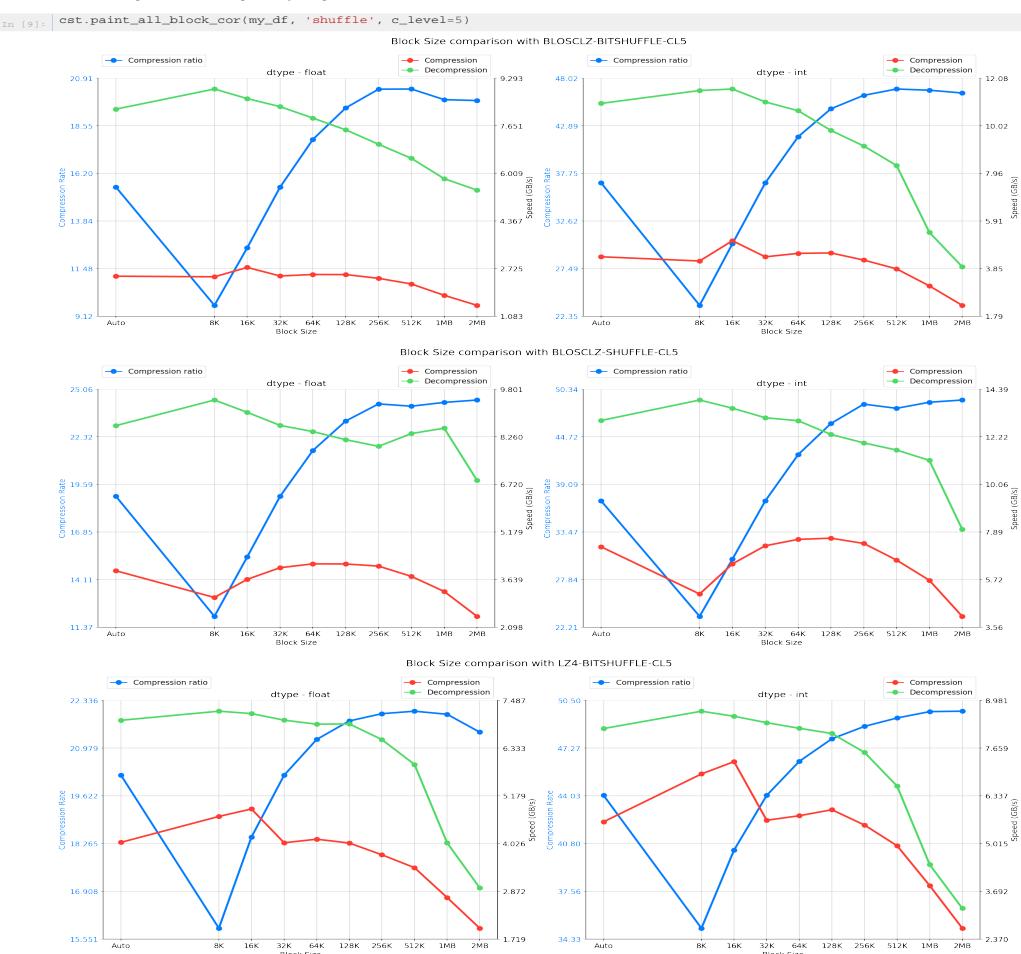
202504	2,215	0.650	0.000	2,098	4,997	32,385	0.000	43,932	0.000	0.000	29,002,000	3,036	4,552	33,353
213844	2,215	0.036	0.000	0.104	5,367	54,662	0.000	4,731	0.000	0.000	28,858,000	2,935	4,428	39,103
215464	2,215	0.044	0.000	0.127	4,180	23,454	0.000	3,249	0.000	0.000	29,004,000	3,036	4,566	36,434
38 INT OUTLIERS														
Chunk	Size	Mean	Median	Sd	Skew	Kurt	Min	Max	Q1	Q3	N_Streaks	CRate	CSpeed	DSpeed
199264	2,445	0.000	0.000	0.027	99,485	18,684,148	0.000	8,000	0.000	0.000	505,000	156,816	20,032	74,193
212224	2,445	0.002	0.000	0.055	50,616	3,993,813	0.000	8,000	0.000	0.000	1,523,000	134,316	19,042	22,407
231664	16,000	0.000	0.000	0.000	-0.000	-3,000	0.000	0.000	0.000	0.000	1,000	170,639	0.193	29,024
251104	2,445	0.001	0.000	0.045	47,237	3,683,632	0.000	7,000	0.000	0.000	1,533,000	135,187	19,078	64,619

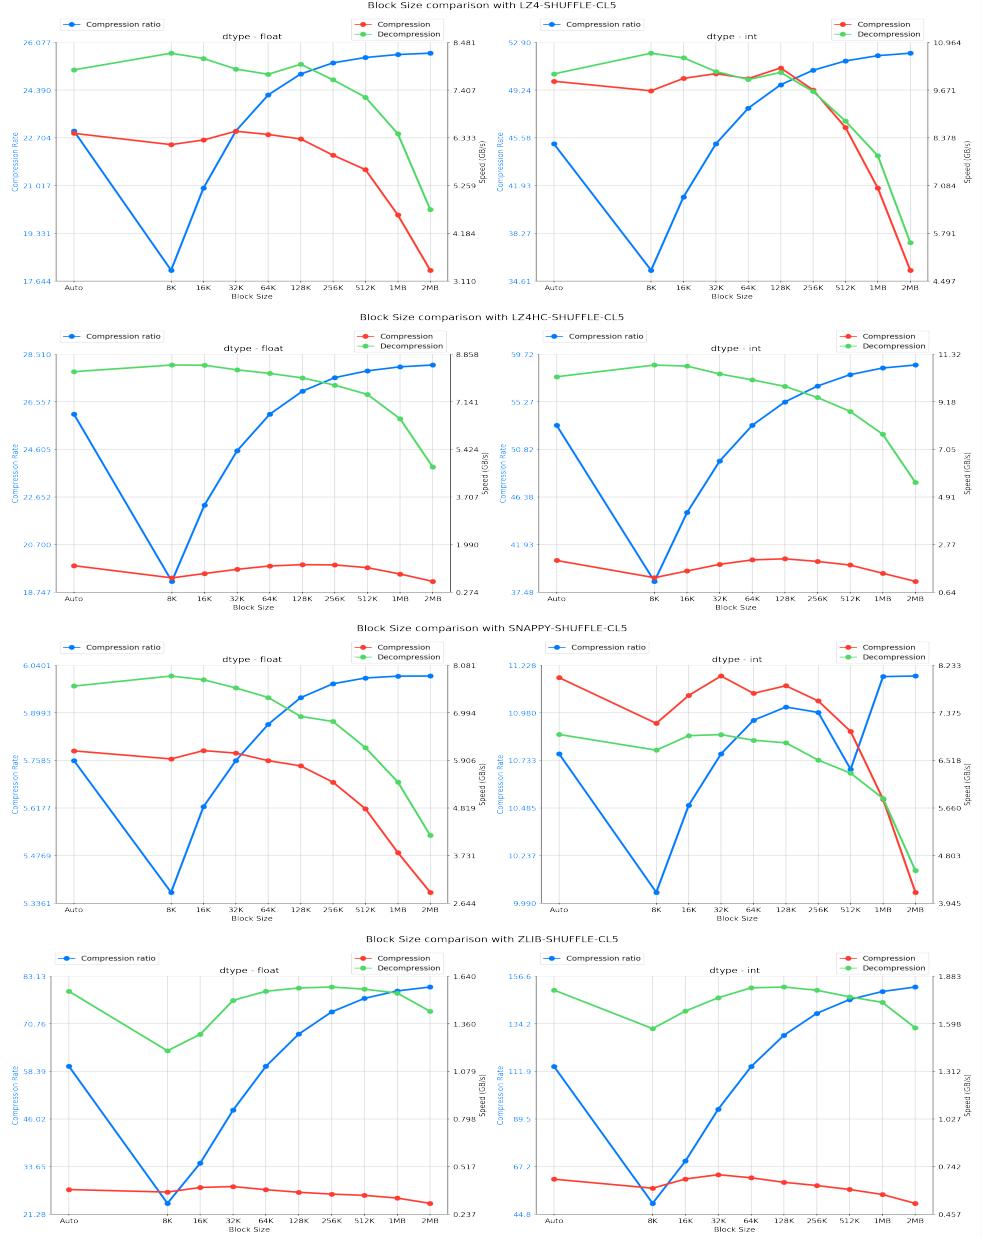
No mostramos los datos atípicos de tipo string dado que no extraemos ninguna característica de chunk que podamos comentar.

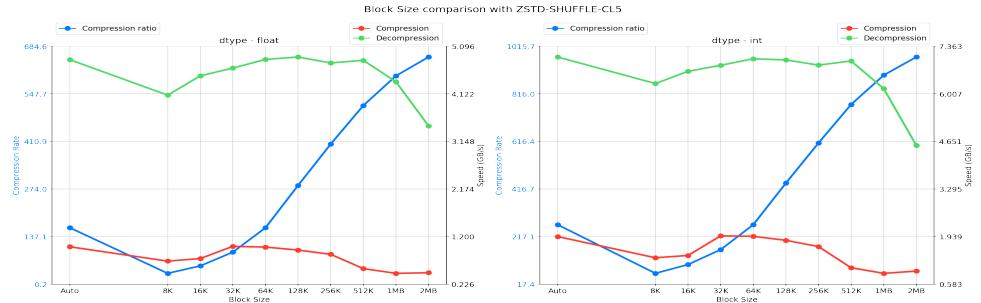
Correlaciones Block Size

Aquí pretendemos observar la correlación entre el tamaño de bloque y las medidas de compresión, para ello filtramos los datos por tipo, codec, filtro, nivel de compresión y tamaño de bloque; y calculamos la media de su ratio de compresión y velocidades de compresión/decompresión.

Las gráficas presentan los ratios de compresión (en azul) y las velocidades de compresión y de descompresión (en rojo y verde) medios para cada tamaño de bloque. Primero mostramos estos datos para los datos de tipo float y de tipo int.

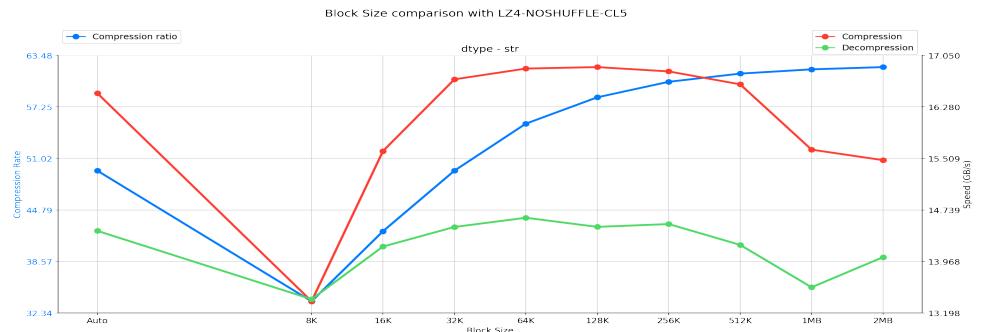
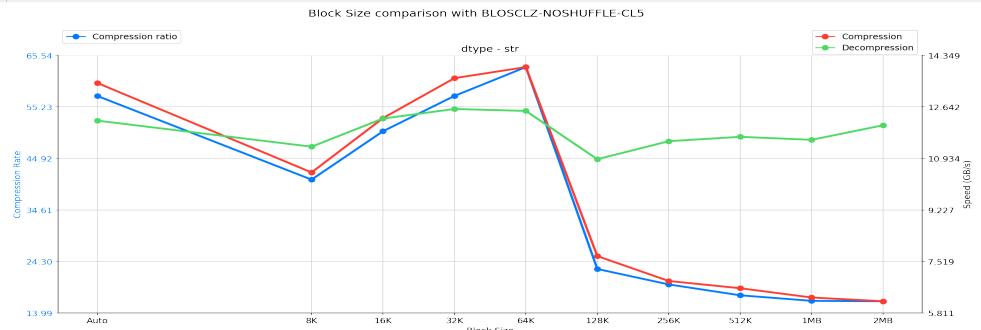


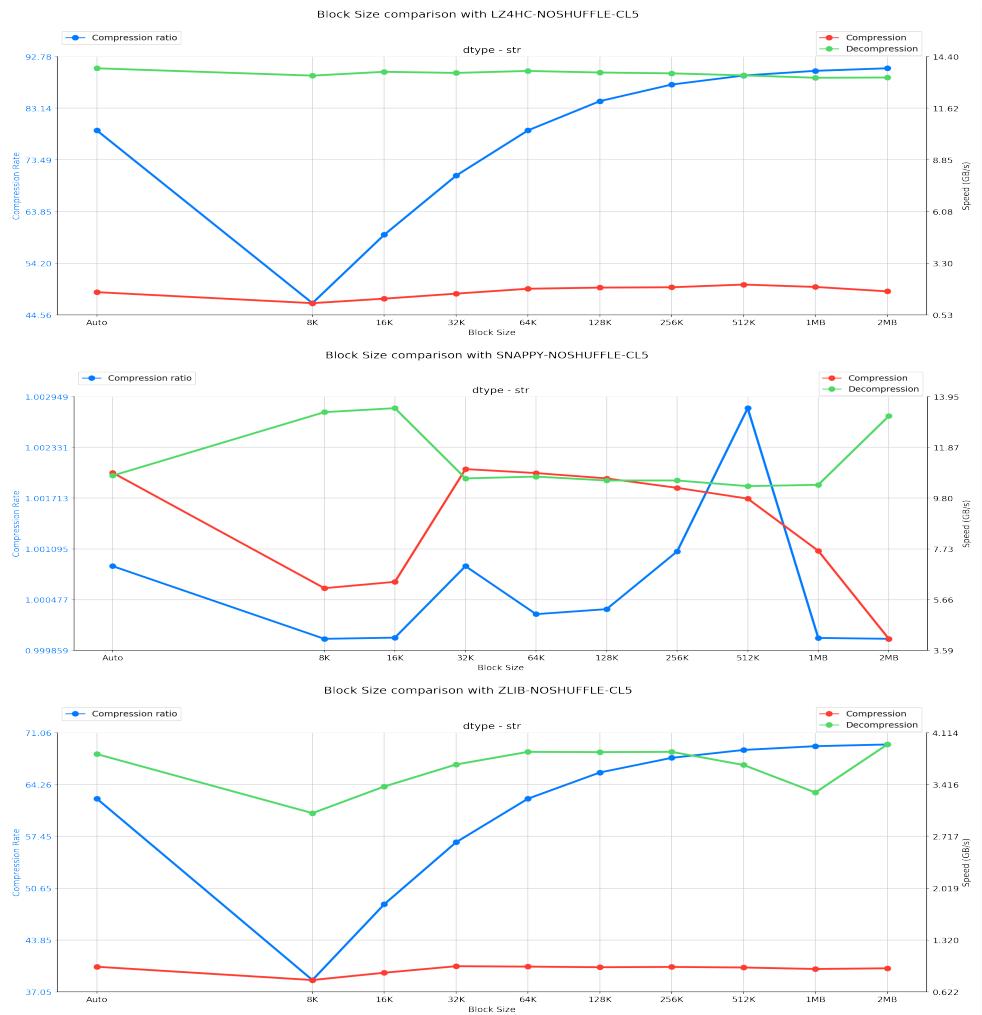


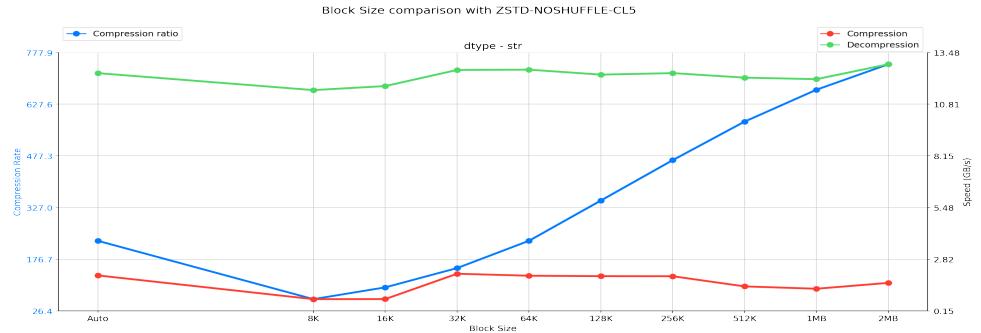


Aquí se muestran los mismos gráficos pero para los datos del tipo cadenas de texto

```
in [10]: cst.paint_all_block_csr(my_df, 'noshuffle')
```



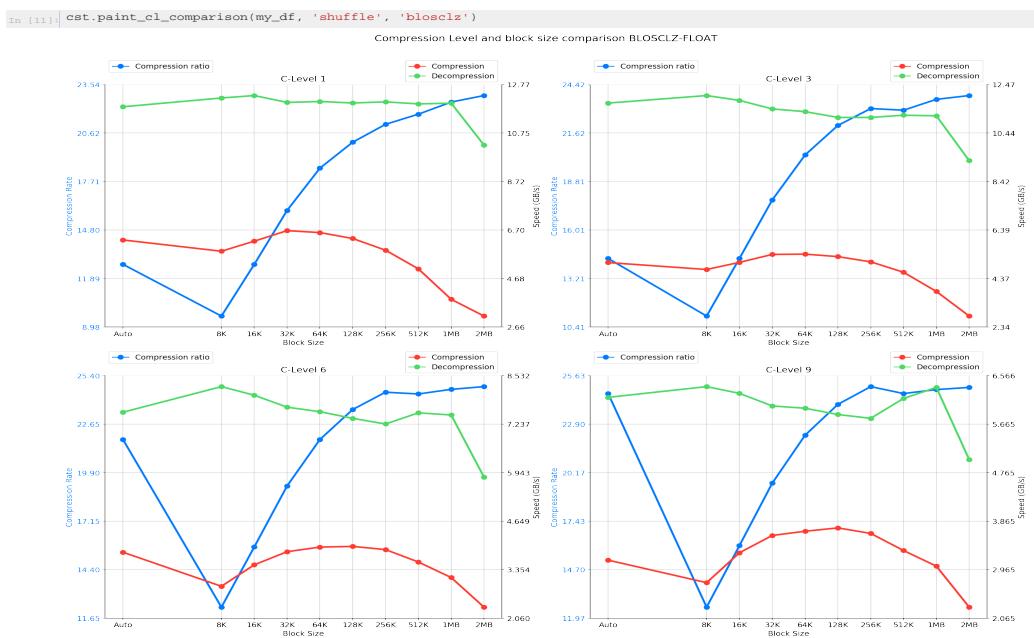


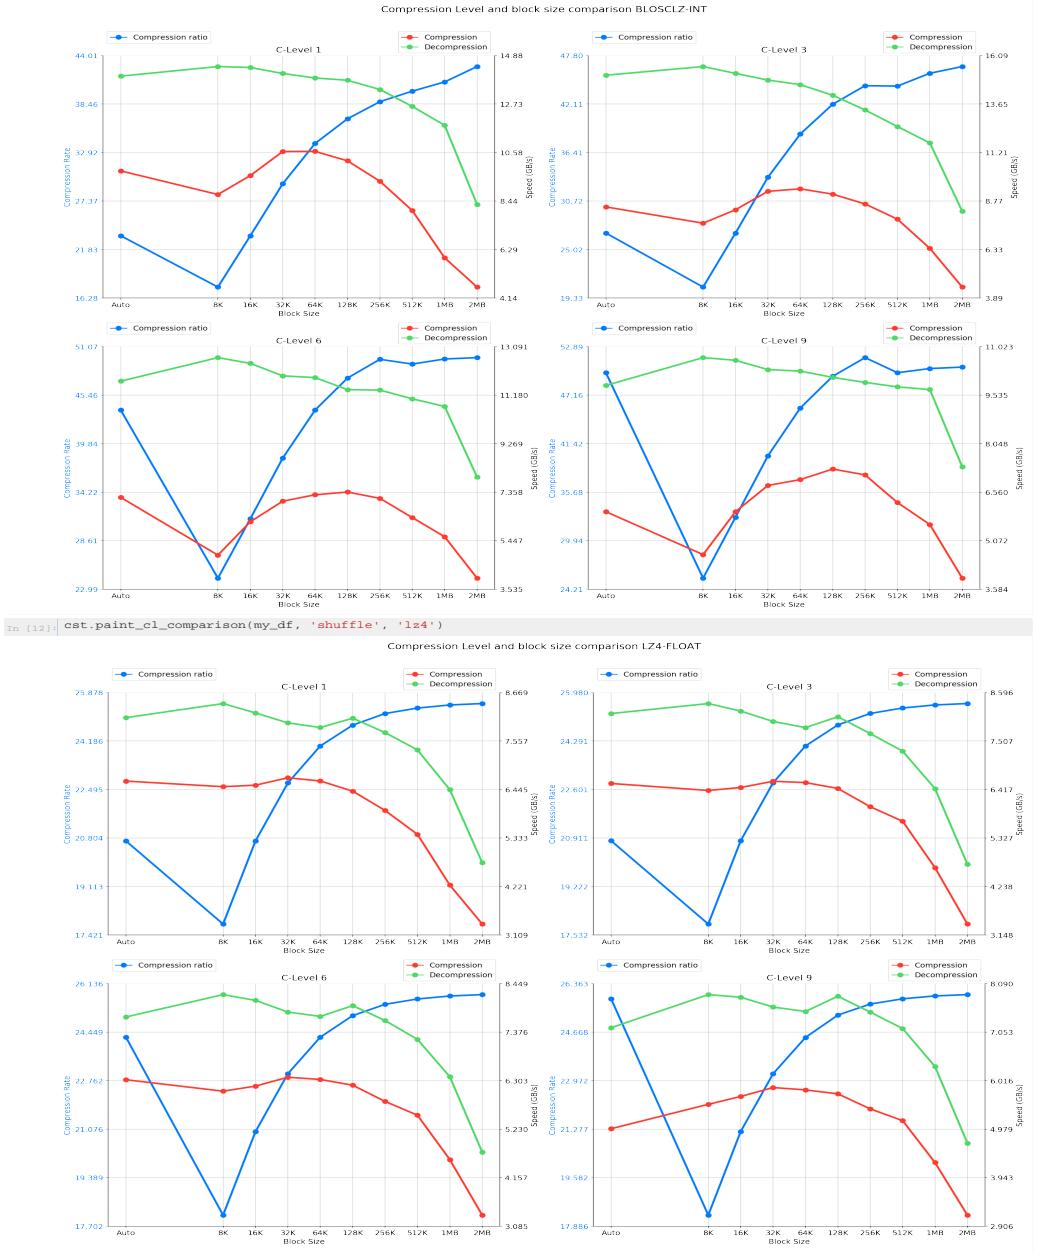


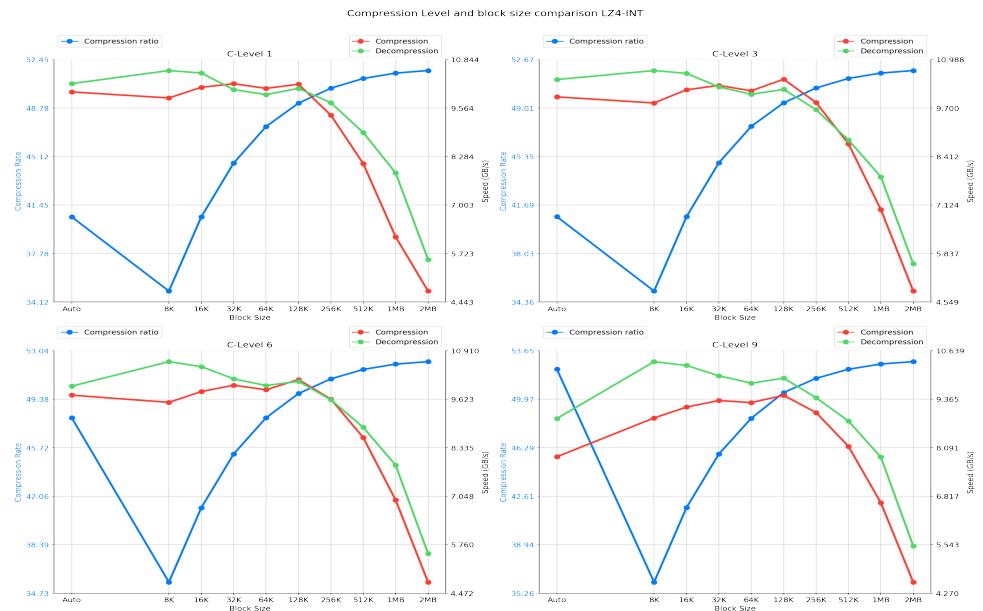
Como podemos observar, al aumentar el tamaño de bloque suele aumentar el ratio de compresión pero parece converger hasta un límite entre los tamaños de 512 KB y 2 MB. Además cuando el tamaño de bloque es menor en general las velocidades son más rápidas.

Por otro lado destaca el comportamiento de Snappy pues no parece comprimir muy bien con respecto al resto. Por otro lado Zlib parece ser inferior en todo a Zstd.

Aquí se presentan las mismas gráficas pero alterando el nivel de compresión para ver como afecta al tamaño de bloque.



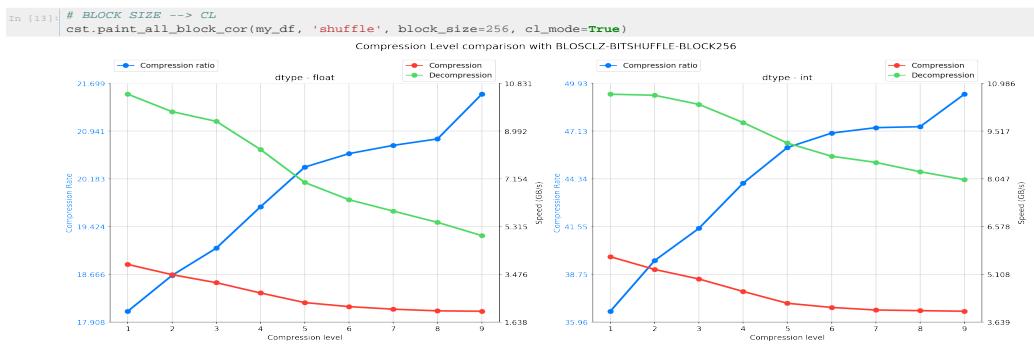


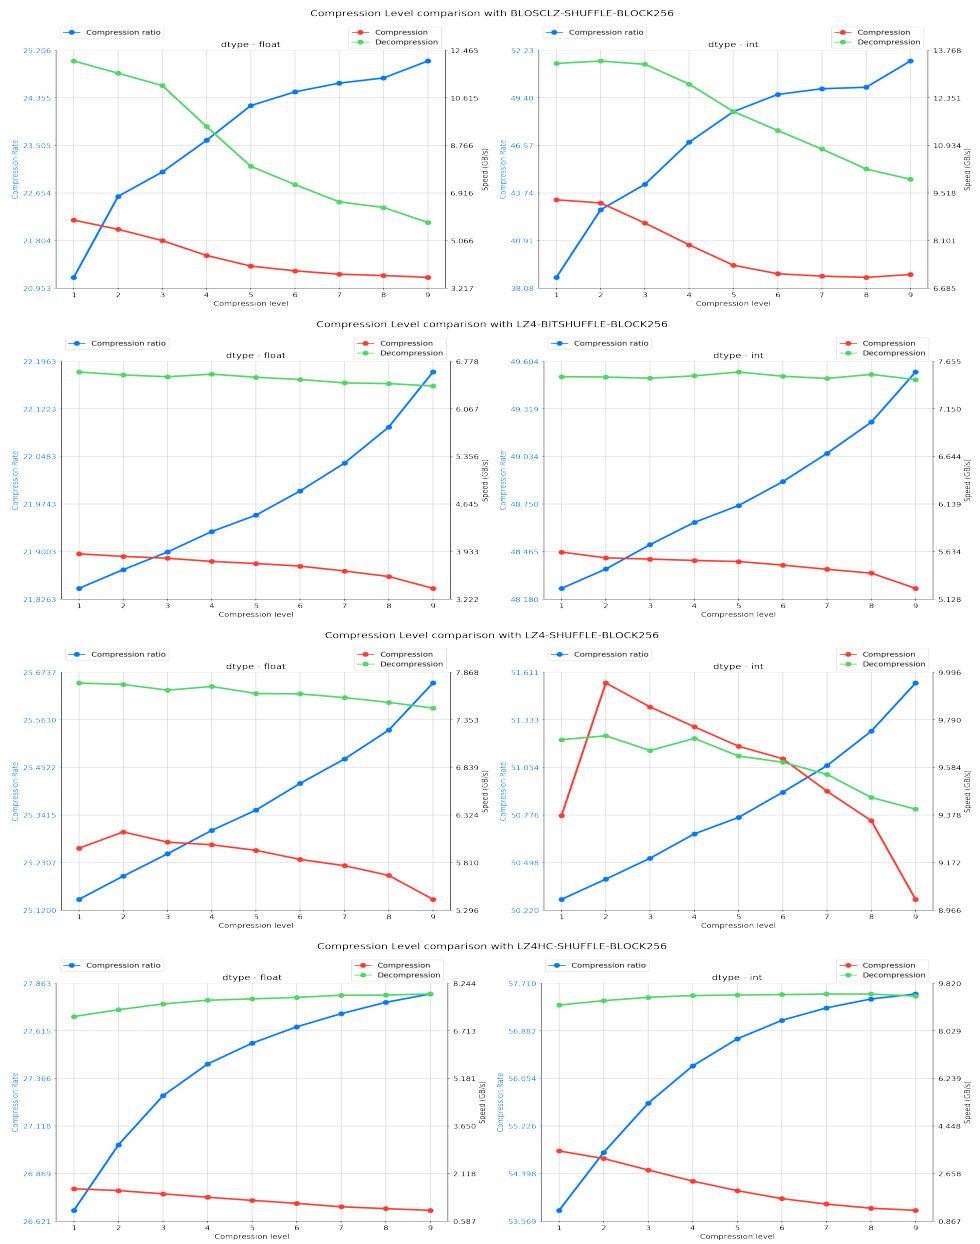


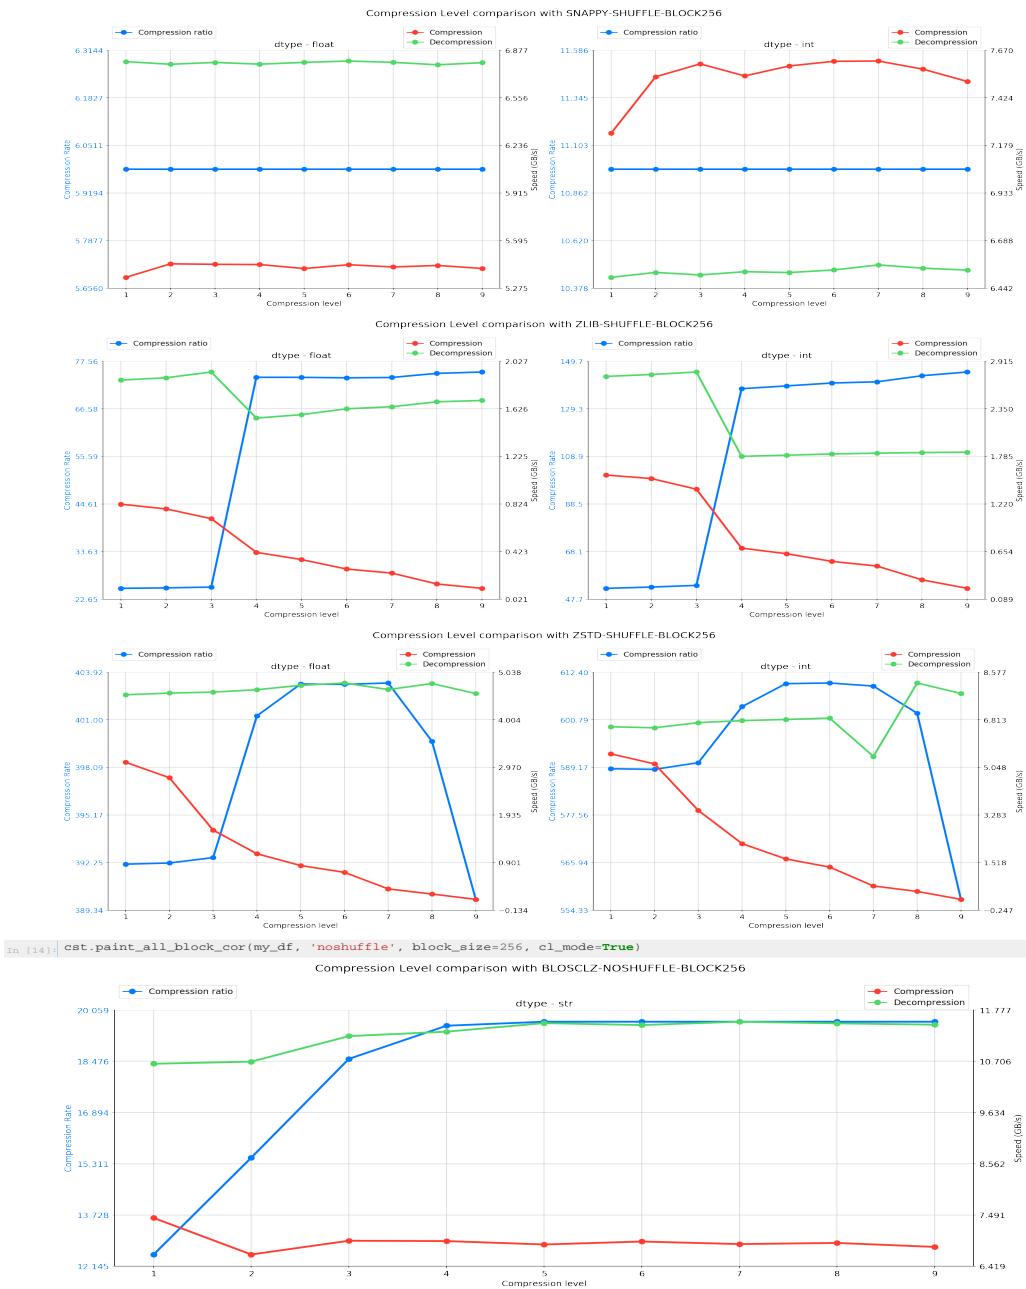
Los resultados son los esperados el comportamiento es en general el mismo, simplemente suben los ratio de compresión y bajan las velocidades a medida que aumenta el nivel de compresión. Por otra parte destaca el comportamiento del tamaño de bloque automático observamos que está programado para que aumente conjuntamente con el nivel de compresión.

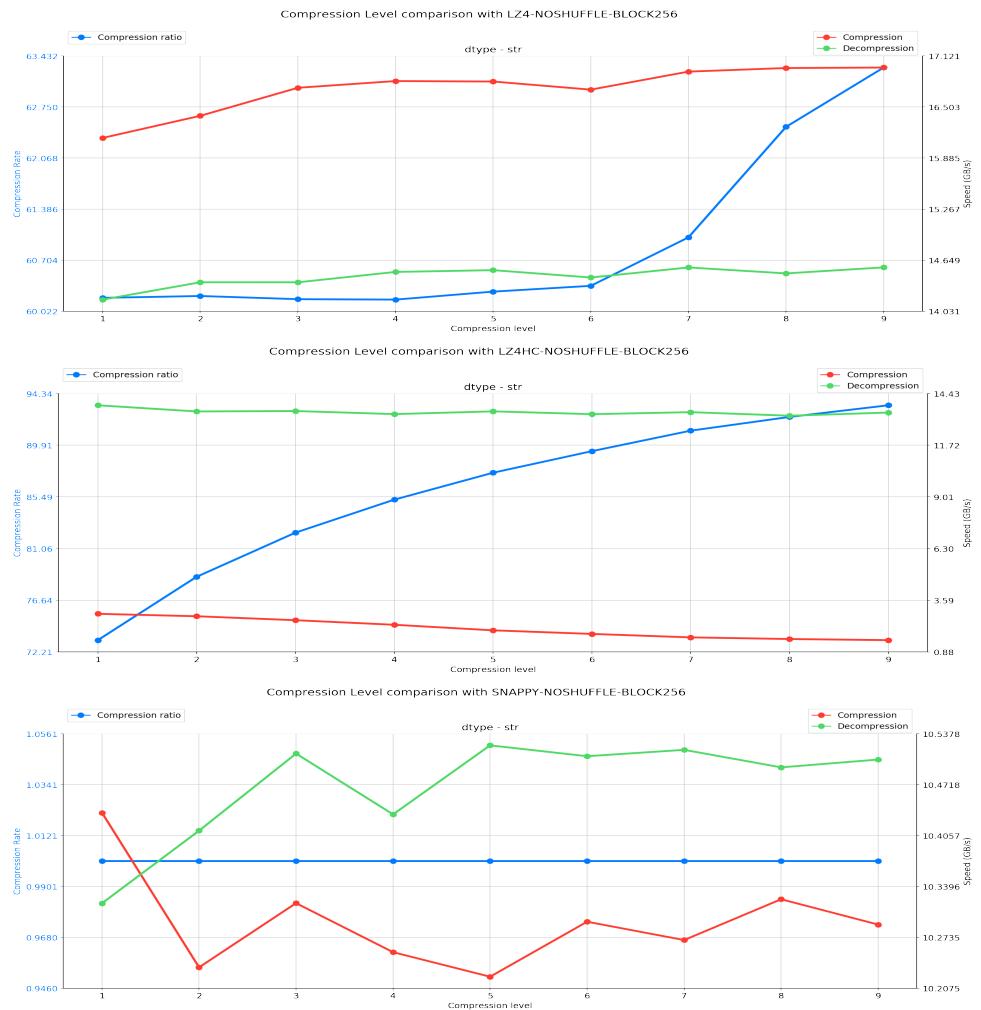
Comparación de niveles de compresión

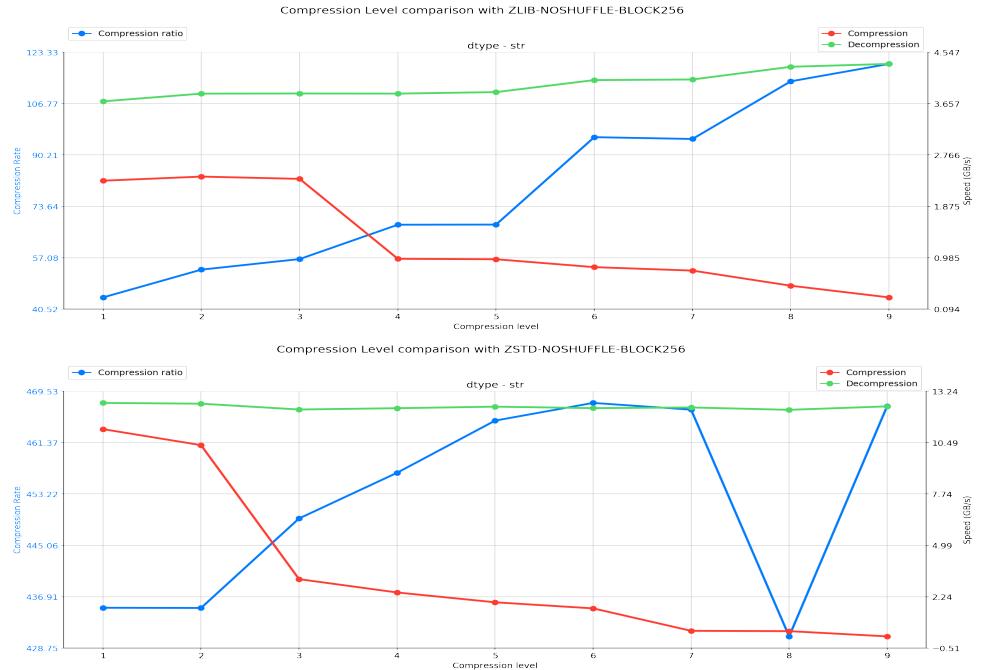
Al igual que en el anterior caso hacemos los mismos gráficos pero observando el nivel de compresión.











Destaca el comportamiento de Snappy de nuevo vuelve a ser el más raro de todos, el nivel de compresión no cambia nada. Por otro lado Zlib tiene un cambio brusco a partir del nivel de compresión 3, esto se debe a que a partir de ese nivel activa métodos más potentes a la hora de comprimir. Finalmente Zstd parece hacer lo mismo que Zlib, pero parece que en los últimos niveles de compresión no funciona bien, pues pierde ratio de compresión.

Tablas columnares VS Tablas normales

En el caso de que los datos estén en forma de tabla, si la tabla contiene más de una columna se realizan dos pruebas de compresión, una guardando los datos como tabla normal, fila por fila y otra guardándolos columnarmente.

```
in [15]: df_col = my_df[my_df.Table == 2]
if df_col.size > 0:
    sets = df_col.drop_duplicates(subset=['DataSet'])
    for dataset in sets['DataSet']:
        dfaux = my_df[my_df.Dataset == dataset]
        normal_table = dfaux[dfaux.Table == 1][cst.TEST_FEATURES]
        normal_table.columns = ['N_CRate', 'N_CSspeed', 'N_DSspeed']
        col_table = dfaux[dfaux.Table == 2][cst.TEST_FEATURES]
        col_table.columns = ['COL_CRate', 'COL_CSspeed', 'COL_DSspeed']
        result = pd.concat([normal_table, col_table])
        result = result[['N_CRate', 'COL_CRate', 'N_CSspeed',
                         'COL_CSspeed', 'N_DSspeed', 'COL_DSspeed']]
        print(sets[sets.DataSet == dataset][cst.DESC_SET])
        display(result.describe())
```

	DataSet	DType	Table	Chunk_Size		
1001160	/msft/table.values_block_0	float64	2.000	16.000		
	N_CRate	COL_CRate	N_CSspeed	COL_CSspeed	N_DSspeed	COL_DSspeed
count	9,720.000	9,720.000	9,720.000	9,720.000	9,720.000	9,720.000
mean	10.462	17.942	2.063	2.281	5.760	4.986
std	7.310	33.079	2.237	2.462	4.037	3.204
min	1.000	1.000	0.002	0.002	0.361	0.345
25%	4.342	5.133	0.413	0.401	2.599	2.595
50%	8.844	8.050	1.249	1.557	4.425	4.276
75%	14.532	15.924	3.038	3.397	8.164	6.744
max	39.004	297.005	10.584	15.156	28.628	28.773

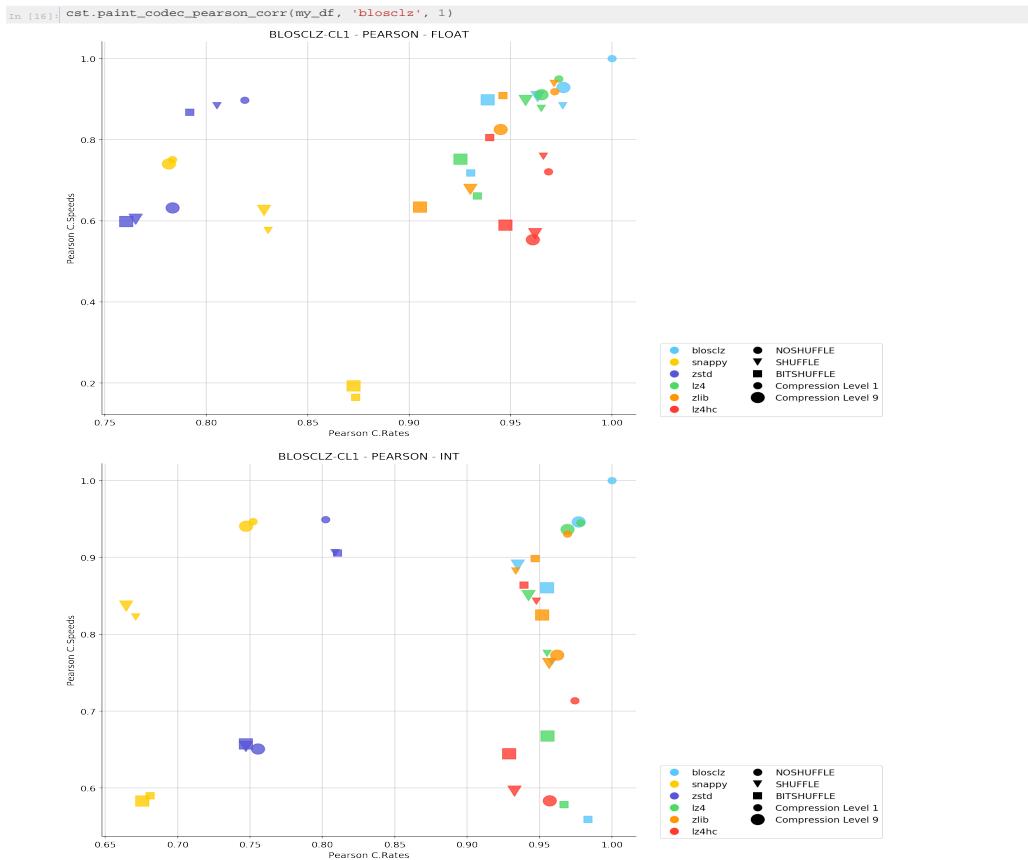
	DataSet	DType	Table	Chunk_Size		
1025460	/msft/table.values_block_2	s49	2.000	16.000		
	N_CRate	COL_CRate	N_CSspeed	COL_CSspeed	N_DSspeed	COL_DSspeed
count	12,960.000	12,960.000	12,960.000	12,960.000	12,960.000	12,960.000
mean	52.373	147.258	6.509	6.845	11.466	10.729

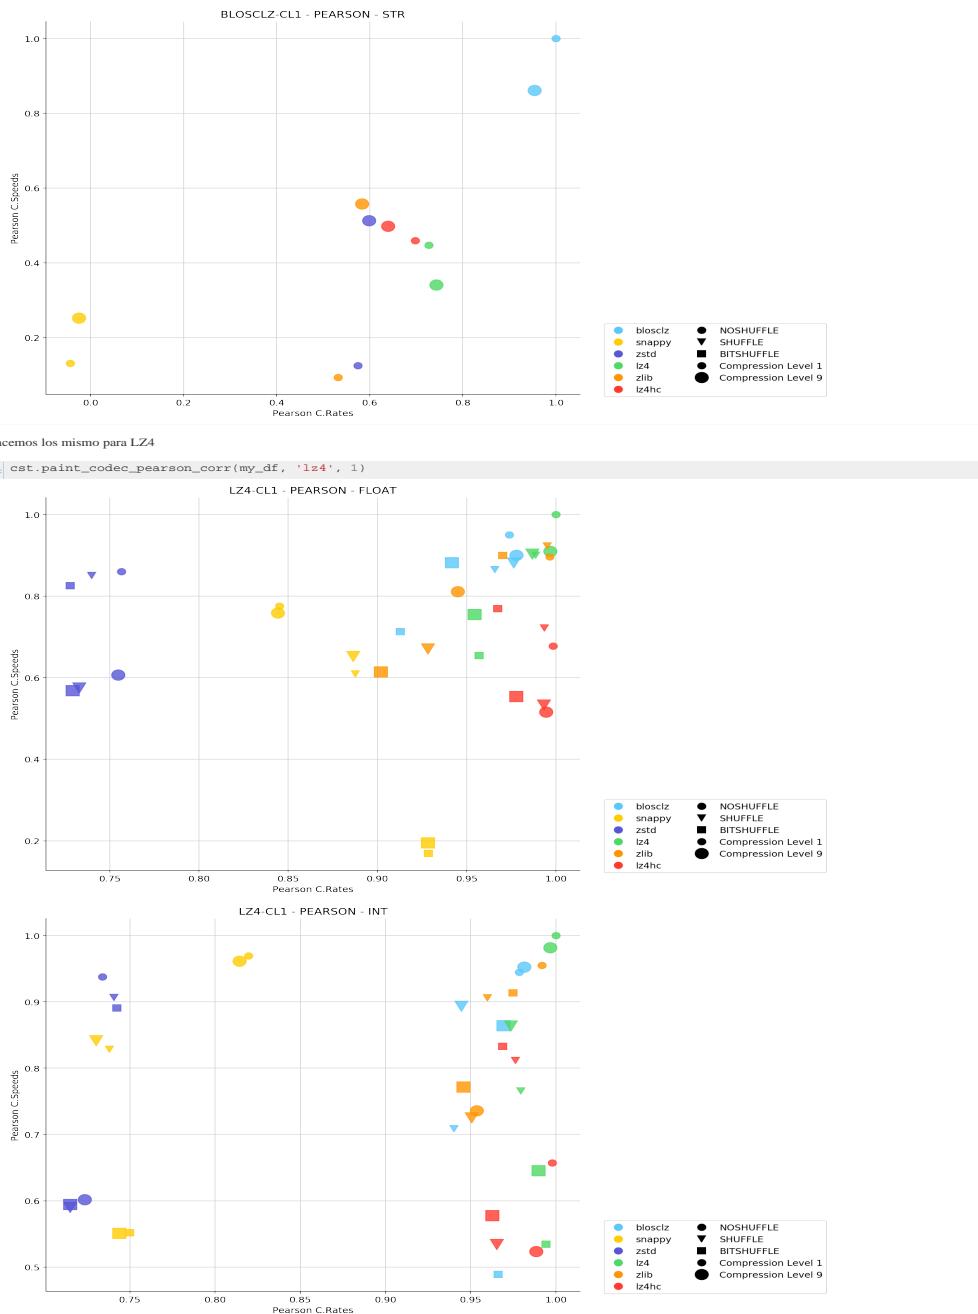
std	45.062	737.652	5.962	6.167	3.926	3.685
min	1.000	1.000	0.005	0.007	1.862	1.881
25%	7.624	21.154	1.176	1.012	10.437	9.548
50%	46.981	47.146	4.621	5.745	12.911	11.920
75%	72.699	86.410	11.163	11.211	13.708	13.126
max	234.129	10.131.164	20.215	22.567	34.169	30.888
Dataset Dtype Table Chunk_Size						
1046520	/s501/events.pulseheights	int16	2.000	12.999		
N_CRate	COL_CRate	N_CSspeed	COL_CSspeed	N_DSspeed	COL_DSspeed	
count	1,620,000	1,620,000	1,620,000	1,620,000	1,620,000	1,620,000
mean	1.412	1.408	1.788	1.545	5.182	4.917
std	0.314	0.307	2.634	2.243	4.310	4.134
min	1.000	1.000	0.002	0.002	0.398	0.366
25%	1.070	1.079	0.318	0.314	1.533	1.571
50%	1.479	1.473	0.650	0.624	4.019	3.790
75%	1.711	1.702	2.320	2.132	6.754	6.321
max	2.041	2.034	10.864	10.954	13.834	14.090
Dataset Dtype Table Chunk_Size						
1051380	/s501/events.integrals	int32	2.000	16.000		
N_CRate	COL_CRate	N_CSspeed	COL_CSspeed	N_DSspeed	COL_DSspeed	
count	3,240,000	3,240,000	3,240,000	3,240,000	3,240,000	3,240,000
mean	2.199	2.196	1.574	1.473	4.854	4.707
std	0.478	0.465	1.848	1.672	3.330	3.265
min	1.000	1.000	0.003	0.003	0.503	0.363
25%	1.979	1.983	0.194	0.184	2.044	1.979
50%	2.197	2.184	0.935	0.899	4.277	4.094
75%	2.555	2.538	2.265	2.120	6.912	6.646
max	3.337	3.353	10.366	7.975	14.669	14.785
Dataset Dtype Table Chunk_Size						
1077300	/s503/events.pulseheights	int16	2.000	7.706		
N_CRate	COL_CRate	N_CSspeed	COL_CSspeed	N_DSspeed	COL_DSspeed	
count	1,620,000	1,620,000	1,620,000	1,620,000	1,620,000	1,620,000
mean	1.476	1.609	1.685	1.849	5.506	5.006
std	0.364	0.407	2.447	2.514	4.916	4.439
min	1.000	1.000	0.003	0.003	0.463	0.445
25%	1.085	1.216	0.117	0.131	1.623	1.594
50%	1.517	1.733	0.697	0.763	3.803	3.878
75%	1.811	1.954	2.334	2.602	6.985	6.048
max	2.157	2.304	10.535	10.696	15.687	15.782
Dataset Dtype Table Chunk_Size						
1080540	/s503/events.integrals	int32	2.000	15.412		
N_CRate	COL_CRate	N_CSspeed	COL_CSspeed	N_DSspeed	COL_DSspeed	
count	1,620,000	1,620,000	1,620,000	1,620,000	1,620,000	1,620,000
mean	2.322	2.681	1.632	2.165	4.971	5.347
std	0.570	0.561	1.851	2.453	3.185	3.381
min	1.000	1.309	0.004	0.006	0.644	0.652
25%	1.984	2.540	0.204	0.266	2.411	2.482
50%	2.245	2.748	1.010	1.200	4.540	5.224
75%	2.684	3.026	2.361	3.383	7.110	7.711
max	3.470	3.780	9.585	12.086	13.480	12.727
Dataset Dtype Table Chunk_Size						
1104840	/s506/events.pulseheights	int16	2.000	14.449		
N_CRate	COL_CRate	N_CSspeed	COL_CSspeed	N_DSspeed	COL_DSspeed	
count	1,620,000	1,620,000	1,620,000	1,620,000	1,620,000	1,620,000
mean	1.414	1.410	1.946	1.703	5.586	5.287
std	0.315	0.308	2.804	2.389	4.372	4.332
min	1.000	1.000	0.002	0.003	0.481	0.409
25%	1.069	1.083	0.133	0.126	1.838	1.702
50%	1.487	1.479	0.722	0.683	4.954	4.501
75%	1.702	1.696	2.572	2.316	7.118	6.470
max	2.040	2.034	11.275	11.068	13.450	13.589
Dataset Dtype Table Chunk_Size						
1109700	/s506/events.integrals	int32	2.000	16.000		
N_CRate	COL_CRate	N_CSspeed	COL_CSspeed	N_DSspeed	COL_DSspeed	
count	3,240,000	3,240,000	3,240,000	3,240,000	3,240,000	3,240,000
mean	2.204	2.203	1.673	1.551	5.080	4.912
std	0.473	0.462	1.915	1.721	3.341	3.268
min	1.000	1.000	0.004	0.005	0.592	0.558
25%	1.985	1.987	0.213	0.205	2.255	2.286
50%	2.213	2.202	0.969	0.936	4.682	4.568
75%	2.545	2.544	2.388	2.253	7.217	6.879
max	3.330	3.390	10.567	8.706	13.782	13.920

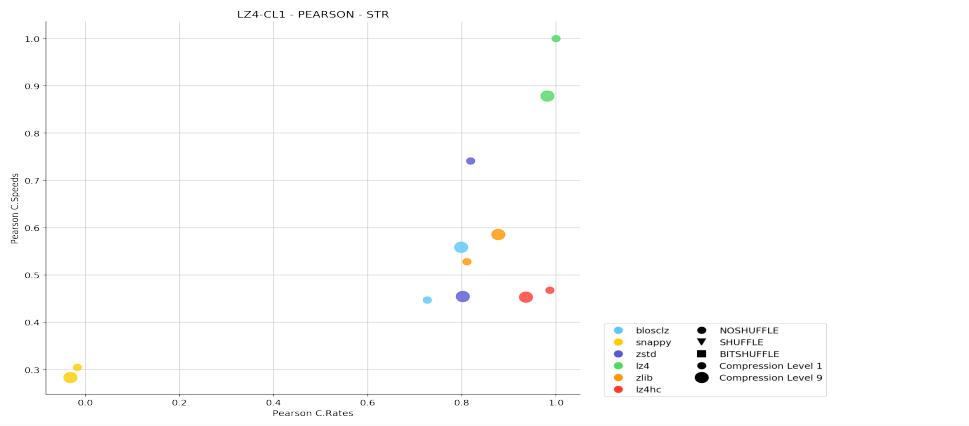
Como era de esperar, parece que las tablas columnares son más comprimibles. Aunque hay casos en los que se comprimen igual, nunca se comprimen menos.

Correlaciones Blosclz-CL1 VS Otros

Para poder visualizar todas estas correlaciones calculamos directamente el coeficiente de pearson asociado entre los datos de blosclz con nivel de compresión 1 y el resto.



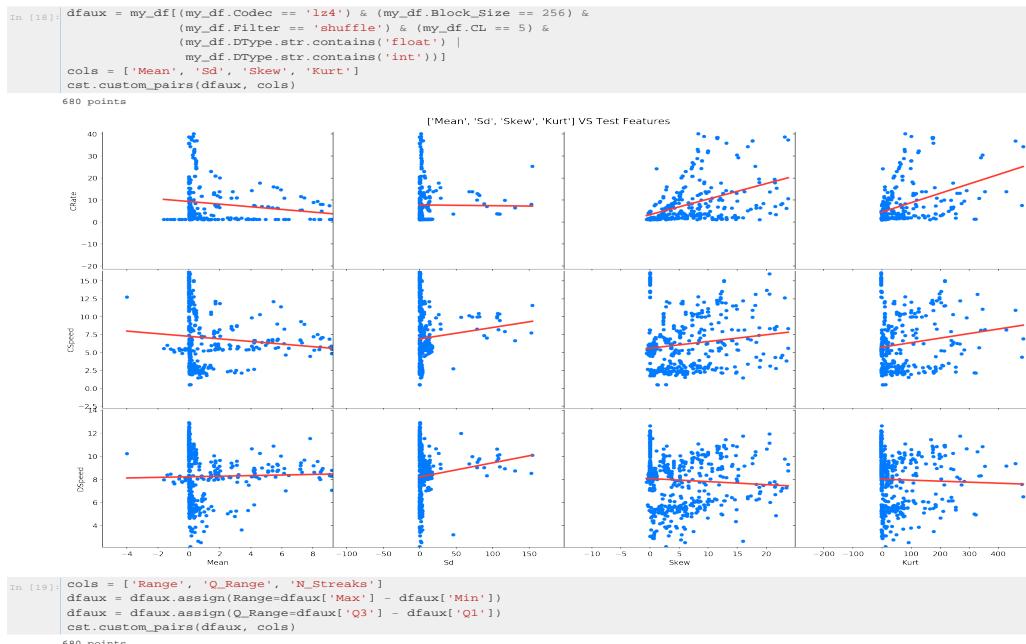


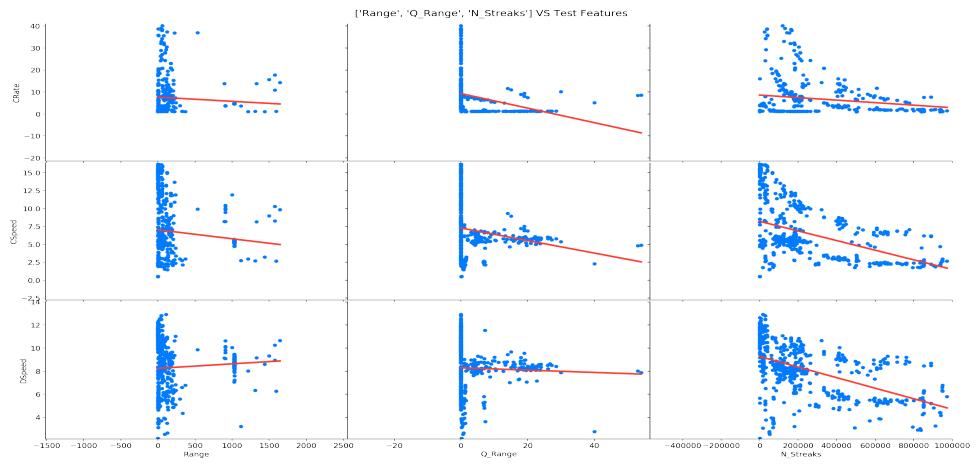


Los resultados son bastante buenos, además era de esperar. Aunque LZ4 tiene mejores resultados ambas opciones parecen lo suficientemente buenas.

Correlaciones entre características de chunk y pruebas de compresión

Aquí se trata de observar las correlaciones entre características de chunk seleccionadas y las pruebas de compresiones. Para ello se utiliza un gráfico de pares personalizado. Además los datos se filtran por codec, filtro, nivel de compresión y tamaño de bloque, sino no tendría sentido los gráficos debido a la enorme variabilidad que habría.





Aunque se podría plantear decir que a mayor rango y número de rachas disminuye el ratio de compresión, no sería muy adecuado sacar conclusiones de estos gráficos. Hay demasiada variabilidad en los datos en sí como para extraer conclusiones de un simple gráfico, será mejor que estas correlaciones las busquen los algoritmos de clasificación en si.

Anexo C

Generador de los datos de entrenamiento

Para la generación de los datos de entrenamiento se utilizó de nuevo un cuaderno *jupyter*, pues aunque se trata de un programa de mero procesamiento de datos resultaba interesante destacar algunas observaciones. Por tanto, en el cuaderno **training_data_generator.ipynb** mostrado a continuación se encuentra el código de generación de los datos de entrenamiento.

C.1. Cuaderno training_data_generator.ipynb

Generador de los datos de entrenamiento

Objetivos del análisis

- Extraer el data frame final con los datos preparados para entrenar algoritmos machine learning.

```
In [1]: %load_ext autoreload
%autoreload 2

%matplotlib inline

%load_ext version_information
%version_information numpy, pandas

Software Version
Python 3.5.3 |64bit| [GCC 4.4.7 20120313 (Red Hat 4.4.7-1)]
IPython 6.1.0
OS Linux 4.9.16 gentoo x86_64 with debian stretch sid
numpy 1.12.1
pandas 0.19.2
Sat Apr 29 13:34:01 2017 UTC

In [2]: import numpy as np
import pandas as pd
from IPython.display import display
import matplotlib.pyplot as plt

pd.options.display.float_format = '{:.3f}'.format

In [3]: CHUNK_ID = ["Filename", "DataSet", "Table", "Chunk_Number"]
CHUNK_FEATURES = ["Table", "Type", "Chunk_Size", "Mean", "Median",
                  "Sd", "Skew", "Kurt", "Min", "Max", "Q1", "Q3",
                  "N_Streaks"]
OUT_OPTIONS = ["Block_Size", "Codec", "Filter", "CL"]
TEST_FEATURES = ["CRate", "CSpeed", "DSpeed"]
COLS = ["filename", "DataSet", "Chunk_Number"] + CHUNK_FEATURES
    + OUT_OPTIONS + TEST_FEATURES
IN_TESTS = ['BLZ_CRate', 'BLZ_CSspeed', 'BLZ_DSpeed', 'LZ4_CRate',
            'LZ4_CSspeed', 'LZ4_DSpeed']
IN_USER = ['IN_CR', 'IN_CS', 'IN_DS']

In [4]: df = pd.read_csv('../data/bloco_test_data_final.csv.gz', sep='\t')
my_df = df[(df.CRate != 0) & (df.CRate > 1.1)]
```

Extracción de los datos por chunk

```
In [5]: %%time
# DATAFRAME WITH DISTINCT CHUNKS
chunks_df = my_df.drop_duplicates(subset=CHUNK_ID)
print("%d rows" % chunks_df.shape[0])
chunk_tests_list = []
# FOR EACH CHUNK
for index, row in chunks_df.iterrows():
    # DATAFRAME WITH CHUNK TESTS
    chunk_tests_list.append(my_df[(my_df.Filename == row["Filename"]) &
                                  (my_df.DataSet == row["dataset"]) &
                                  (my_df.Table == row["Table"]) &
                                  (my_df.Chunk_Number == row["Chunk_Number"])])

725 rows
CPU times: user 1min 36s, sys: 76 ms, total: 1min 36s
Wall time: 1min 36s
```

Selección de opciones para cada chunk

```
In [6]: %%time
training_df = pd.DataFrame()
for chunk_test in chunk_tests_list:
    # EXTRACT MAX MIN AND SOME AUX MAX INDICES
    i_max_crate, i_max_c_speed, i_max_d_speed = \
        chunk_test['CRate'].idxmax(), chunk_test['CSpeed'].idxmax(), \
        chunk_test['DSpeed'].idxmax()
    max_crate, max_c_speed, max_d_speed = \
        (chunk_test.ix[i_max_crate]['CRate'],
         chunk_test.ix[i_max_c_speed]['CSpeed'],
         chunk_test.ix[i_max_d_speed]['DSpeed'])

    min_crate, min_c_speed, min_d_speed = (chunk_test['CRate'].min(),
                                            chunk_test['CSpeed'].min(),
                                            chunk_test['DSpeed'].min())

    # NORMALIZED COLUMNS
    chunk_test = chunk_test.assign(N_CRate=(chunk_test['CRate'] -
                                           min_crate) /
                                 (max_crate - min_crate),
                                   N_CSspeed=(chunk_test['CSpeed'] -
                                              min_c_speed) /
                                              (max_c_speed - min_c_speed),
                                   N_DSpeed=(chunk_test['DSpeed'] -
                                              min_d_speed) /
                                              (max_d_speed - min_d_speed))

    # DISTANCE FUNC COLUMNS
```

```

chunk_test = chunk_test.assign(Distance_1=(chunk_test['N_CRate'] - 1)**2
                               + (chunk_test['N_CSspeed'] - 1)**2,
                               Distance_2=(chunk_test['N_CRate'] - 1)**2
                               + (chunk_test['N_DSspeed'] - 1) ** 2,
                               Distance_3=(chunk_test['N_CRate'] - 1)**2
                               + (chunk_test['N_DSspeed'] - 1)**2,
                               Distance_4=(chunk_test['N_CSspeed'] - 1)**2
                               + (chunk_test['N_DSspeed'] - 1) ** 2)
# BALANCED INDICES
i_balanced_c_speed, i_balanced_d_speed,
i_balanced, i_balanced_speeds = (chunk_test[['Distance_1']].idxmin(),
                                   chunk_test[['Distance_2']].idxmin(),
                                   chunk_test[['Distance_3']].idxmin(),
                                   chunk_test[['Distance_4']].idxmin())
indices = [i_max_d_speed, i_max_c_speed, i_balanced_speeds,
           i_max_crate, i_balanced_d_speed, i_balanced_c_speed,
           i_balanced]
# TYPE FILTER FOR LZ_DATA
d_type = chunk_test.iloc[0]['DType']
filter_name = 'noshuffle'
if 'float' in d_type or 'int' in d_type:
    filter_name = 'shuffle'
aux = df[(df.CR == 1) & (df.Block_Size == 0) &
          (df.Filter == filter_name) &
          (df.Filename == chunk_test.iloc[0]['Filename']) &
          (df.DataSet == chunk_test.iloc[0]['DataSet']) &
          (df.Table == chunk_test.iloc[0]['Table']) &
          (df.Chunk_Number == chunk_test.iloc[0]['Chunk_Number'])]
lz_data = np.append(aux[aux.Code == 'blosclz'][TEST_FEATURES].values[0],
                     aux[aux.Code == 'lz4'][TEST_FEATURES].values[0])
# APPEND ROWS TO TRAINING DATA FRAME
for i in range(len(indices)):
    in_1, r = divmod((i+1), 4)
    in_2, in_3 = divmod(r, 2)
    training_df = training_df.append(
        dict(zip(COLS + IN_TESTS + IN_USER,
                 np.append(np.append(chunk_test.ix[indices[i]][COLS].values,
                                    lz_data),
                           [in_1, in_2, in_3])),
             ignore_index=True))
CPU times: user 3min 6s, sys: 44 ms, total: 3min 6s
Wall time: 3min 6s

```

Algunas comprobaciones

```

In [7]: print('DISTINCT MAX RATE')
distinct_max_rate = training_df[(training_df.IN_CR == 1) &
                                 (training_df.IN_CS == 0) &
                                 (training_df.IN_DS == 0)]\
    .drop_duplicates(subset=OUT_OPTIONS)\n[OUT_OPTIONS + TEST_FEATURES]
print('%s rows' % distinct_max_rate.shape[0])
display(distinct_max_rate.head())
print('DISTINCT MAX C SPEED')
distinct_max_c_speed = training_df[(training_df.IN_CR == 0) &
                                     (training_df.IN_CS == 1) &
                                     (training_df.IN_DS == 0)]\
    .drop_duplicates(subset=OUT_OPTIONS)\n[OUT_OPTIONS + TEST_FEATURES]
print('%s rows' % distinct_max_c_speed.shape[0])
display(distinct_max_c_speed.head())
print('DISTINCT MAX D SPEED')
distinct_max_d_speed = training_df[(training_df.IN_CR == 0) &
                                     (training_df.IN_CS == 0) &
                                     (training_df.IN_DS == 1)]\
    .drop_duplicates(subset=OUT_OPTIONS)\n[OUT_OPTIONS + TEST_FEATURES]
print('%s rows' % distinct_max_d_speed.shape[0])
display(distinct_max_d_speed.head())
print('DISTINCT BALANCED CSPEED')
distinct_balanced_c_speed = training_df[(training_df.IN_CR == 1) &
                                         (training_df.IN_CS == 1) &
                                         (training_df.IN_DS == 0)]\
    .drop_duplicates(subset=OUT_OPTIONS)\n[OUT_OPTIONS + TEST_FEATURES]
print('%s rows' % distinct_balanced_c_speed.shape[0])
display(distinct_balanced_c_speed.head())
print('DISTINCT BALANCED DSPEED')
distinct_balanced_d_speed = training_df[(training_df.IN_CR == 1) &
                                         (training_df.IN_CS == 0) &
                                         (training_df.IN_DS == 1)]\
    .drop_duplicates(subset=OUT_OPTIONS)\n[OUT_OPTIONS + TEST_FEATURES]
print('%s rows' % distinct_balanced_d_speed.shape[0])
display(distinct_balanced_d_speed.head())
print('DISTINCT BALANCED SPEED')
distinct_balanced_speed = training_df[(training_df.IN_CR == 0) &
                                       (training_df.IN_CS == 1) &
                                       (training_df.IN_DS == 1)]\
    .drop_duplicates(subset=OUT_OPTIONS)\n[OUT_OPTIONS + TEST_FEATURES]

```

```

print('%s rows' % distinct_balanced_speed.shape[0])
display(distinct_balanced_speed.head())
print('DISTINCT BALANCED')
distinct_balanced = training_df[(training_df.IN_CR == 1) &
                                (training_df.IN_CS == 1) &
                                (training_df.IN_DS == 1)]\ 
                                .drop_duplicates(subset=OUT_OPTIONS)
[OUT_OPTIONS + TEST_FEATURES]
print('%s rows' % distinct_balanced.shape[0])
display(distinct_balanced.head())
DISTINCT MAX RATE
27 rows


|     | Block_Size | Codec | Filter     | CL    | CRate  | CSpeed | DSpeed |
|-----|------------|-------|------------|-------|--------|--------|--------|
| 3   | 2,048.000  | zstd  | shuffle    | 9.000 | 1.366  | 0.014  | 3.320  |
| 554 | 0.000      | zstd  | shuffle    | 9.000 | 49.115 | 0.066  | 4.596  |
| 661 | 0.000      | zstd  | shuffle    | 8.000 | 1.212  | 0.011  | 1.145  |
| 668 | 0.000      | zstd  | shuffle    | 7.000 | 1.179  | 0.013  | 1.050  |
| 696 | 2,048.000  | zstd  | bitshuffle | 9.000 | 4.588  | 0.057  | 2.761  |


DISTINCT MAX C.SPEED
131 rows


|    | Block_Size | Codec | Filter  | CL    | CRate | CSpeed | DSpeed |
|----|------------|-------|---------|-------|-------|--------|--------|
| 1  | 64.000     | 1z4   | shuffle | 3.000 | 1.244 | 6.440  | 8.259  |
| 8  | 16.000     | 1z4   | shuffle | 1.000 | 1.233 | 6.758  | 8.311  |
| 22 | 0.000      | 1z4   | shuffle | 1.000 | 1.217 | 6.533  | 8.251  |
| 29 | 64.000     | 1z4   | shuffle | 1.000 | 1.225 | 6.336  | 8.421  |
| 50 | 64.000     | 1z4   | shuffle | 4.000 | 1.226 | 6.166  | 8.820  |


DISTINCT MAX D.SPEED
189 rows


|    | Block_Size | Codec   | Filter     | CL    | CRate | CSpeed | DSpeed |
|----|------------|---------|------------|-------|-------|--------|--------|
| 0  | 32.000     | blosclz | shuffle    | 1.000 | 1.108 | 4.402  | 9.849  |
| 7  | 32.000     | blosclz | bitshuffle | 2.000 | 1.110 | 3.669  | 9.728  |
| 14 | 16.000     | blosclz | shuffle    | 4.000 | 1.170 | 2.678  | 9.861  |
| 21 | 8.000      | blosclz | shuffle    | 2.000 | 1.119 | 4.288  | 9.845  |
| 28 | 64.000     | blosclz | shuffle    | 3.000 | 1.129 | 3.476  | 9.781  |


DISTINCT BALANCED CSPEED
98 rows


|    | Block_Size | Codec | Filter  | CL    | CRate | CSpeed | DSpeed |
|----|------------|-------|---------|-------|-------|--------|--------|
| 5  | 256.000    | 1z4   | shuffle | 4.000 | 1.252 | 5.825  | 8.554  |
| 12 | 256.000    | 1z4   | shuffle | 8.000 | 1.255 | 6.033  | 8.148  |
| 19 | 128.000    | 1z4   | shuffle | 5.000 | 1.248 | 6.201  | 9.488  |
| 26 | 256.000    | 1z4   | shuffle | 6.000 | 1.242 | 5.558  | 8.574  |
| 33 | 0.000      | 1z4   | shuffle | 8.000 | 1.241 | 5.440  | 8.557  |


DISTINCT BALANCED DSPEED
167 rows


|    | Block_Size | Codec | Filter  | CL    | CRate | CSpeed | DSpeed |
|----|------------|-------|---------|-------|-------|--------|--------|
| 4  | 256.000    | 1z4hc | shuffle | 8.000 | 1.310 | 0.134  | 8.219  |
| 11 | 128.000    | 1z4hc | shuffle | 8.000 | 1.300 | 0.153  | 8.513  |
| 25 | 256.000    | 1z4hc | shuffle | 5.000 | 1.292 | 0.190  | 8.783  |
| 32 | 128.000    | 1z4hc | shuffle | 9.000 | 1.286 | 0.117  | 8.351  |
| 39 | 256.000    | 1z4hc | shuffle | 7.000 | 1.290 | 0.147  | 8.150  |


DISTINCT BALANCED SPEED
157 rows


|    | Block_Size | Codec | Filter  | CL    | CRate | CSpeed | DSpeed |
|----|------------|-------|---------|-------|-------|--------|--------|
| 2  | 32.000     | 1z4   | shuffle | 3.000 | 1.239 | 6.157  | 8.908  |
| 9  | 16.000     | 1z4   | shuffle | 5.000 | 1.238 | 6.366  | 9.139  |
| 16 | 0.000      | 1z4   | shuffle | 4.000 | 1.239 | 6.501  | 9.179  |
| 23 | 128.000    | 1z4   | shuffle | 2.000 | 1.233 | 6.000  | 9.044  |
| 30 | 64.000     | 1z4   | shuffle | 2.000 | 1.226 | 6.196  | 8.831  |


DISTINCT BALANCED
148 rows


|    | Block_Size | Codec | Filter  | CL    | CRate | CSpeed | DSpeed |
|----|------------|-------|---------|-------|-------|--------|--------|
| 6  | 256.000    | 1z4   | shuffle | 5.000 | 1.252 | 5.722  | 8.805  |
| 13 | 128.000    | 1z4   | shuffle | 6.000 | 1.250 | 6.042  | 9.115  |
| 20 | 128.000    | 1z4   | shuffle | 5.000 | 1.248 | 6.201  | 9.488  |
| 27 | 256.000    | 1z4   | shuffle | 6.000 | 1.242 | 5.558  | 8.574  |
| 34 | 0.000      | 1z4   | shuffle | 8.000 | 1.241 | 5.440  | 8.557  |


In [8]:
distinct_total = training_df.drop_duplicates(subset=OUT_OPTIONS)
[OUT_OPTIONS + TEST_FEATURES]
print('%d distinct options from a total of %d' %
      (distinct_total.shape[0], 1620))
distinct_total_noblock = distinct_total.drop_duplicates(subset=OUT_OPTIONS[1:4])
print('%d distinct options from a total of %d' %
      (distinct_total_noblock.shape[0], 162))
print('Distinct codecs %d' %
      distinct_total.drop_duplicates(subset=['Codec']).shape[0])
print('Distinct filters %d' %
      distinct_total.drop_duplicates(subset=['Filter']).shape[0])

```

```

print('Distinct CL %d' %
      distinct_total.drop_duplicates(subset=['CL']).shape[0])
print('Distinct block sizes %d' %
      distinct_total.drop_duplicates(subset=['Block_Size']).shape[0])
display(distinct_total.describe())
487 distinct options from a total of 1620
96 distinct options from a total of 162
Distinct codecs 5
Distinct filters 3
Distinct CL 9
Distinct block sizes 10

```

	Block_Size	CL	CRate	CSpeed	DSpeed
count	487.000	487.000	487.000	487.000	487.000
mean	311.737	5.335	327.070	6.583	13.948
std	553.841	2.583	1.585.596	6.718	11.312
min	0.000	1.000	1.101	0.004	0.474
25%	16.000	3.000	1.268	0.763	8.743
50%	64.000	6.000	4.112	4.860	10.421
75%	256.000	8.000	49.268	9.370	14.523
max	2.048.000	9.000	10.645.442	23.848	86.345

Zlib queda descartado dado que nunca es seleccionado como óptimo.

```

In [9]: display(training_df[training_df.Codec == 'snappy']
              [IN_USER + TEST_FEATURES + OUT_OPTIONS])

```

	IN_CR	IN_CS	IN_DS	CRate	CSpeed	DSpeed	Block_Size	Codec	Filter	CL
1681	0.000	1.000	0.000	21.195	20.349	9.824	0.000	snappy	noshuffle	7.000
4291	0.000	1.000	11.049	7.158	13.803	128.000	snappy	noshuffle	3.000	

Snappy ha sido seleccionado en dos ocasiones. Por tanto podríamos considerar que tenemos 488/1080 opciones totales y sin contar el tamaño de bloque 97/108.

```

In [10]: print('%d blosclz classes from 270' %
          distinct_total[distinct_total.Codec == 'blosclz'].shape[0])
print('%d lz4 classes from 270' %
      distinct_total[distinct_total.Codec == 'lz4'].shape[0])
print('%d lz4hc classes from 270' %
      distinct_total[distinct_total.Codec == 'lz4hc'].shape[0])
print('%d zstd classes from 270' %
      distinct_total[distinct_total.Codec == 'zstd'].shape[0])

```

144 blosclz classes from 270
168 lz4 classes from 270
102 lz4hc classes from 270
71 zstd classes from 270

Debido a que Snappy solo es seleccionado en dos ocasiones lo consideraremos como datos atípicos y por tanto los sustituimos por la segunda mejor opción.

```

In [11]: # ELIMINAMOS SNAPPY
for i, row in (training_df[training_df.Codec == 'snappy']).iterrows():
    aux = df[(df.Filename == row['Filename']) &
              (df.DataSet == row['DataSet']) &
              (df.Table == row['Table']) &
              (df.Chunk_Number == row['Chunk_Number']) &
              (df.Codec != 'snappy')]
    i_max_crate, i_max_c_speed, i_max_d_speed = aux['CRate'].idxmax(),
                                                aux['CSpeed'].idxmax(), \
                                                aux['DSpeed'].idxmax()
    max_crate, max_c_speed, max_d_speed = (aux.ix[i_max_crate]['CRate'],
                                             aux.ix[i_max_c_speed]['CSpeed'],
                                             aux.ix[i_max_d_speed]['DSpeed'])

    min_crate, min_c_speed, min_d_speed = (aux['CRate'].min(),
                                             aux['CSpeed'].min(),
                                             aux['DSpeed'].min())

# NORMALIZED COLUMNS
aux = aux.assign(N_CRate=(aux['CRate'] - min_crate) /
                  (max_crate - min_crate),
                 N_CSspeed=(aux['CSpeed'] - min_c_speed) /
                  (max_c_speed - min_c_speed),
                 N_DSpeed=(aux['DSpeed'] - min_d_speed) /
                  (max_d_speed - min_d_speed))
aux['Distance'] = row['IN_CR']*(aux['N_CRate'] - 1)**2
                + row['IN_DS']*(aux['N_CSspeed'] - 1)**2
                + row['IN_CS']*(aux['N_DSpeed'] - 1)**2
index = aux['Distance'].idxmin()
training_df.loc[i, TEST_FEATURES + OUT_OPTIONS] = \
    aux.ix[index][TEST_FEATURES + OUT_OPTIONS]

```

Tamaño de bloque automático

```

%%time
count = training_df[training_df.Block_Size == 0].shape[0]
for i, row in training_df.iterrows():
    block = row['Block_Size']
    aux = df[(df.Filename == row['Filename']) &
              (df.DataSet == row['DataSet']) &
              (df.Table == row['Table']) &
              (df.Chunk_Number == row['Chunk_Number']) &
              (df.Codec == row['Codec']) &
              (df.Filter == row['Filter']) &
              (df.CL == row['CL'])]

```

```

crate = aux[aux.Block_Size == 0]['CRate'].values[0]
auto_block = aux[(aux.CRate == crate) &
                 (aux.Block_Size != 0)]['Block_Size'].values[0]
if block != 0:
    if auto_block == block:
        count += 1
    else:
        training_df.loc[i, 'Block_Size'] = auto_block
CPU times: user 24min 29s, sys: 284 ms, total: 24min 29s
Wall time: 24min 29s
In [13]: print("%d from %d --> %d %%" %
           (count, training_df.shape[0], count / training_df.shape[0] * 100))
1372 from 5075 --> 27 %
In [14]: training_df.drop_duplicates(subset=['Block_Size'])

   BLZ_CRate  BLZ_CSspeed  BLZ_DSspeed  Block_Size  CL  CRate  CSspeed  Chunk_Number  Chunk_Size  Codec ...  Max  Mean  Median
0  1.110      3.959       7.963     32.000  1.000  1.108  4.402  1.000      16.000  blosclz ...  27.146  5.762  3.093
1  1.110      3.959       7.963     64.000  3.000  1.244  6.440  1.000      16.000  lz4 ...  27.146  5.762  3.093
3  1.110      3.959       7.963     2,048.000  9.000  1.366  0.014  1.000      16.000  zstd ...  27.146  5.762  3.093
4  1.110      3.959       7.963     256.000  8.000  1.310  0.134  1.000      16.000  lz4hc ...  27.146  5.762  3.093
8  1.110      5.626       9.007     16.000  1.000  1.233  6.758  2.000      16.000  lz4 ...  27.775  6.145  4.291
11 1.110      5.626       9.007    128.000  8.000  1.300  0.153  2.000      16.000  lz4hc ...  27.775  6.145  4.291
21 1.100      5.482       9.048     8.000  2.000  1.119  4.288  4.000      16.000  blosclz ...  33.807  6.450  2.096
82 1.072      5.368       9.172    512.000  8.000  1.243  5.329  12.000     16.000  lz4 ...  49.183  10.937  7.797
654 1.326      3.743      15.588   1,024.000  9.000  49.115  0.066  1.000      0.738  zstd ...  211,383.000  46,750.635  42,412.0

9 rows × 32 columns

```

Preparación de inputs para scikit-learn

```

In [15]: from sklearn.preprocessing import binarize
from sklearn.preprocessing import OneHotEncoder
training_df = training_df.assign(
    is_Table=binarize(training_df['Table'].values.reshape(-1,1), 0),
    is_Columnar=binarize(training_df['Table'].values.reshape(-1,1), 1),
    is_Int=training_df['DType'].str.contains('int').astype(int),
    is_Float=training_df['DType'].str.contains('float').astype(int),
    is_String=(training_df['DType'].str.contains('S') |
               training_df['DType'].str.contains('U')).astype(int))

import re
def aux_func(s):
    n = int(re.findall('\d+', s)[0])
    if len(isNum) > 0:
        return n // 8
    else:
        return n
training_df['Type_Size'] = [aux_func(s) for s in training_df['DType']]

```

Preparación de outputs para scikit-learn

```

In [16]: training_df = training_df.assign(
    Blosclz=(training_df['Codec'] == 'blosclz').astype(int),
    Lz4=(training_df['Codec'] == 'lz4').astype(int),
    Lz4hc=(training_df['Codec'] == 'lz4hc').astype(int),
    Snappy=(training_df['Codec'] == 'snappy').astype(int),
    Zstd=(training_df['Codec'] == 'zstd').astype(int),
    Noshuffle=(training_df['Filter'] == 'noshuffle').astype(int),
    Shuffle=(training_df['Filter'] == 'shuffle').astype(int),
    Bitsshuffle=(training_df['Filter'] == 'bitsshuffle').astype(int))
enc_cl = OneHotEncoder()
enc_cl.fit(training_df['CL'].values.reshape(-1, 1))
new_cls = enc_cl.transform(training_df['CL'].values.reshape(-1, 1)).toarray()
enc_block = OneHotEncoder()
enc_block.fit(training_df['Block_Size'].values.reshape(-1, 1))
new_blocks = enc_block.transform(training_df['Block_Size'].values.reshape(-1, 1)).toarray()
for i in range(9):
    cl_label = 'CL' + str(i+1)
    block_label = 'Block_' + str(2**((i+3)))
    training_df[cl_label] = new_cls[:, i]
    training_df[block_label] = new_blocks[:, i]
In [17]: training_df.to_csv('../data/training_data.csv', sep='\t', index=False)

```

Anexo D

Análisis de los algoritmos de clasificación

En este anexo se presentan los informes realizados para cada algoritmo de clasificación estudiado. Además también se incluyen los programas auxiliares que utilizan. Los programas son: **ml_plots.py** que incluye funciones auxiliares para las gráficas, **scoring_functions.py** donde se definen las métricas de puntuación personalizadas, **multioutput_chained.py** donde se define la clase **ChainedMultiOutputClassifier** y **nested_hypertuner.py** que realiza las validaciones cruzadas de los parámetros de cada algoritmo clasificador.

Los informes realizados con *jupyter notebook* son: **lda_logit_analysis.ipynb**, **SVM_analysis.ipynb**, **KNeig_analysis.ipynb**, **RFC_analysis.ipynb** y **classifiers_comparison.ipynb** este último es la comparativa entre los distintos algoritmos, mientras que el resto son los análisis individuales de cada uno.

D.1. Programas Python

```
1 from collections import Counter
2 from matplotlib import pyplot as plt
3 import numpy as np
4 from sklearn.model_selection import learning_curve
5 from sklearn.model_selection import validation_curve
6 from sklearn.model_selection import cross_val_score
7 import scoring_functions as sf
8
9
10
```

```

11 def plot_learning_curve(ax, estimator, title, X, y, scoring, ylim=None, cv=None,
12                         n_jobs=1, train_sizes=np.linspace(.1, 1.0, 5)):
13     """
14     Generate a simple plot of the test and training learning curve.
15
16     Parameters
17     -----
18     estimator : object type that implements the "fit" and "predict" methods
19         An object of that type which is cloned for each validation.
20
21     title : string
22         Title for the chart.
23
24     X : array-like, shape (n_samples, n_features)
25         Training vector, where n_samples is the number of samples and
26         n_features is the number of features.
27
28     y : array-like, shape (n_samples) or (n_samples, n_features), optional
29         Target relative to X for classification or regression;
30         None for unsupervised learning.
31
32     ylim : tuple, shape (ymin, ymax), optional
33         Defines minimum and maximum yvalues plotted.
34
35     cv : int, cross-validation generator or an iterable, optional
36         Determines the cross-validation splitting strategy.
37         Possible inputs for cv are:
38             - None, to use the default 3-fold cross-validation,
39             - integer, to specify the number of folds.
40             - An object to be used as a cross-validation generator.
41             - An iterable yielding train/test splits.
42
43         For integer/None inputs, if ``y`` is binary or multiclass,
44         :class:`StratifiedKFold` used. If the estimator is not a classifier
45         or if ``y`` is neither binary nor multiclass, :class:`KFold` is used.
46
47         Refer :ref:`User Guide <cross-validation>` for the various
48         cross Validators that can be used here.
49
50     n_jobs : integer, optional
51         Number of jobs to run in parallel (default 1).
52     """
53     ax.set_title(title)
54     if ylim is not None:
55         ax.set_ylim(*ylim)
56     ax.set_xlabel("Training examples")
57     ax.set_ylabel("Score %" % scoring.__name__)
58     train_sizes, train_scores, test_scores = learning_curve(
59         estimator, X, y, cv=cv, n_jobs=n_jobs, train_sizes=train_sizes,
60         scoring=scoring)
61     train_scores_mean = np.mean(train_scores, axis=1)
62     train_scores_std = np.std(train_scores, axis=1)

```

```

63     test_scores_mean = np.mean(test_scores, axis=1)
64     test_scores_std = np.std(test_scores, axis=1)
65     ax.yaxis.grid(color="#CECED2")
66     ax.xaxis.grid(color="#CECED2")
67
68     ax.fill_between(train_sizes, train_scores_mean - train_scores_std,
69                     train_scores_mean + train_scores_std, alpha=0.1,
70                     color="#FF3B30")
71     ax.fill_between(train_sizes, test_scores_mean - test_scores_std,
72                     test_scores_mean + test_scores_std, alpha=0.1,
73                     color="#4CD964")
74     ax.plot(train_sizes, train_scores_mean, 'o--', color="#FF3B30",
75             label="Training score")
76     ax.plot(train_sizes, test_scores_mean, 'o--', color="#4CD964",
77             label="Cross-validation score")
78
79     plt.legend(loc="best")
80
81     return ax
82
83
84 def plot_validation_curve(ax, estimator, X, Y, param_name, param_range,
85                         scoring, ylim, cv):
86     train_scores, test_scores = validation_curve(estimator, X, Y,
87                                                 param_name=param_name,
88                                                 param_range=param_range,
89                                                 cv=cv, scoring=scoring,
90                                                 n_jobs=-1)
91
92     train_scores_mean = np.mean(train_scores, axis=1)
93     train_scores_std = np.std(train_scores, axis=1)
94     test_scores_mean = np.mean(test_scores, axis=1)
95     test_scores_std = np.std(test_scores, axis=1)
96
97     ax.set_title("Validation Curve")
98     ax.set_xlabel(param_name)
99     ax.set_ylabel("Score %" % scoring.__name__)
100    ax.set_ylim(*ylim)
101    lw = 2
102    ax.yaxis.grid(color="#CECED2")
103    ax.xaxis.grid(color="#CECED2")
104
105    ax.plot(param_range, train_scores_mean, label="Training score",
106            color="#FF9500", lw=lw)
107    ax.fill_between(param_range, train_scores_mean - train_scores_std,
108                    train_scores_mean + train_scores_std, alpha=0.2,
109                    color="#FF9500", lw=lw)
110    ax.plot(param_range, test_scores_mean, label="Cross-validation score",
111            color="#007AFF", lw=lw)
112    ax.fill_between(param_range, test_scores_mean - test_scores_std,
113                    test_scores_mean + test_scores_std, alpha=0.2,
114                    color="#007AFF", lw=lw)

```

```

115     plt.legend(loc="best")
116
117     return ax
118
119
120 def plot_nested_cv(non_nested_score, nested_score):
121     score_difference = non_nested_score - nested_score
122
123     print('Average difference of %.6f with std. dev. of %.6f.' %
124           (score_difference.mean(), score_difference.std()))
125
126     # Plot scores on each trial for nested and non-nested CV
127     plt.figure(figsize=(20, 8))
128     plt.subplot(121)
129     non_nested_scores_line, = plt.plot(non_nested_score, color="#FF3B30")
130     nested_line, = plt.plot(nested_score, color="#007AFF")
131     plt.ylabel("score", fontsize=14)
132     plt.legend([non_nested_scores_line, nested_line],
133               ["Non-Nested CV", "Nested CV"],
134               bbox_to_anchor=(0, 1, 0, 0))
135
136     # Plot bar chart of the difference.
137     plt.subplot(122)
138     difference_plot = plt.bar(range(20), score_difference, color="#007AFF")
139     plt.xlabel("Individual Trial #")
140     plt.legend([difference_plot],
141               ["Non-Nested CV - Nested CV Score"],
142               bbox_to_anchor=(0, 1, .8, 0))
143     plt.ylabel("score difference", fontsize=14)
144     plt.tight_layout()
145     plt.suptitle("Non-Nested and Nested Cross Validation",
146                  x=.5, y=1.1, fontsize=15)
147
148     return plt
149
150
151 def print_nested_winners(nested_clf, non_nested_clf):
152     clf_name = non_nested_clf[0].__class__.__name__
153     if (clf_name == 'RandomForestClassifier' or clf_name == 'ExtraTreesClassifier'):
154         params = ('criterion', 'bootstrap', 'class_weight')
155     elif (clf_name == "MultiOutputClassifier"):
156         params = ('estimator__C', 'estimator__gamma')
157     else:
158         params = ('n_neighbors', 'weights')
159     values = [[] for i in range(len(params))]
160     for est in non_nested_clf:
161         aux_dict = est.get_params()
162         for i in range(len(params)):
163             values[i].append(aux_dict.get(params[i]))
164     print('Non Nested Winners')
165     for i in range(len(params)):

```

```

166     print('%-s --> %-s' % (params[i], Counter(values[i])))
167 values = [[] for i in range(len(params))]
168 for estimators in nested_clf:
169     for est in estimators:
170         aux_dict = est.get_params()
171         for i in range(len(params)):
172             values[i].append(aux_dict.get(params[i]))
173 print('Nested Winners')
174 for i in range(len(params)):
175     print('%-s --> %-s' % (params[i], Counter(values[i])))
176
177
178 class ReportList(list):
179     def __repr__html__(self):
180         html = ["<table><caption><b>Report</b></caption><thead><tr><th>Name</th><th>Score</th></tr>"]
181         for i, row in enumerate(self):
182             html.append("<tr>")
183             html.append("<td>%s</td>" % (row[0]))
184             if i < 6:
185                 html.append(
186                     "<td>%4f +/-(%4f)</td>" % (row[1][0],
187                                                 row[1][1]))
188             else:
189                 html.append(
190                     "<td>%4f +/-(%4f) &nbsp; ~ &nbsp; \
191                     %.4f +/-(%4f)</td>" % (row[1][0],
192                                                 row[1][1],
193                                                 row[1][2],
194                                                 row[1][3]))
195             html.append("</tr>")
196         html.append("</table>")
197         return ''.join(html)
198
199
200 SCORES = [sf.balanced, sf.brier, None, sf.codec, sf.filter_,
201           sf.codec_filter, sf.c_level, sf.block, sf.cl_block]
202 NICE_SCORES = [sf.c_level_nice, sf.block_nice, sf.cl_block_nice]
203
204
205 def cross_val_report(estimator, cv, X, y, no_brier=False):
206     report = ReportList()
207     for i, scoring in enumerate(SCORES):
208         if scoring is None:
209             name = 'normal'
210             scores = cross_val_score(estimator, cv=cv, X=X, y=y,
211                                     scoring=scoring)
212             values = [scores.mean(), scores.std()]
213         elif no_brier and scoring.__name__ == 'brier':
214             values = [0, 0]
215             name = scoring.__name__
216         else:
217

```

```

218     scores = cross_val_score(estimator, cv=cv, X=X, y=y,
219                             scoring=scoring)
220     values = [scores.mean(), scores.std()]
221     name = scoring.__name__
222     if (i > 5):
223         scores = cross_val_score(estimator, cv=cv, X=X, y=y,
224                                   scoring=NICE_SCORES[i - 6])
225         values.extend([scores.mean(), scores.std()])
226     report.append([name, values])
227 return report

```

```

1
2 import numpy as np
3 import random
4 import pandas as pd
5
6
7 def brier(predictor, X, y):
8     probs = predictor.predict_proba(X)
9     sorted_probs = []
10    score = 0
11    for i in range(len(probs[0])):
12        list_aux = []
13        for j in range(25):
14            if probs[j][i].shape[0] > 1:
15                list_aux.append(probs[j][i][1])
16            else:
17                list_aux.append(0)
18        sorted_probs.append(list_aux)
19    for i in range(y.shape[0]):
20        aux = np.square(sorted_probs[i] - y[i])
21        score += np.sum(aux[0:4]) + np.sum(aux[4:7]) + \
22            np.sum(aux[7:16]) + np.sum(aux[16:25])
23    return -score / y.shape[0]
24
25
26 def balanced(predictor, X, y):
27     ypred = predictor.predict(X)
28     score = 0
29     for i in range(y.shape[0]):
30         if (y[i, 0:7] == ypred[i, 0:7]).all():
31             score += 0.5
32         score += (8 - abs(np.argmax(y[i, 7:16] == 1) -
33                           np.argmax(ypred[i, 7:16] == 1)))**2 / 64 * 0.25
34         score += (8 - abs(np.argmax(y[i, 16:25] == 1) -
35                           np.argmax(ypred[i, 16:25] == 1)))**2 / 64 * 0.25
36     return score / y.shape[0]
37
38
39 def codec_filter(predictor, X, y):
40     ypred = predictor.predict(X)
41     score = 0

```

```

42     for i in range(y.shape[0]):
43         if (y[i, 0:7] == ypred[i, 0:7]).all():
44             score += 1
45     return score / y.shape[0]
46
47
48 def codec(predictor, X, y):
49     ypred = predictor.predict(X)
50     score = 0
51     for i in range(y.shape[0]):
52         if (y[i, 0:4] == ypred[i, 0:4]).all():
53             score += 1
54     return score / y.shape[0]
55
56
57 def filter_(predictor, X, y):
58     ypred = predictor.predict(X)
59     score = 0
60     for i in range(y.shape[0]):
61         if (y[i, 4:7] == ypred[i, 4:7]).all():
62             score += 1
63     return score / y.shape[0]
64
65
66 def c_level(predictor, X, y):
67     ypred = predictor.predict(X)
68     score = 0
69     for i in range(y.shape[0]):
70         if (y[i, 7:16] == ypred[i, 7:16]).all():
71             score += 1
72     return score / y.shape[0]
73
74
75 def c_level_nice(predictor, X, y):
76     ypred = predictor.predict(X)
77     score = 0
78     for i in range(y.shape[0]):
79         score += (8 - abs(np.argmax(y[i, 7:16] == 1) -
80                           np.argmax(ypred[i, 7:16] == 1)))**2 / 64
81     return score / y.shape[0]
82
83
84 def block(predictor, X, y):
85     ypred = predictor.predict(X)
86     score = 0
87     for i in range(y.shape[0]):
88         if (y[i, 16:25] == ypred[i, 16:25]).all():
89             score += 1
90     return score / y.shape[0]
91
92
93 def block_nice(predictor, X, y):

```

```

94     ypred = predictor.predict(X)
95     score = 0
96     for i in range(y.shape[0]):
97         score += (8 - abs(np.argmax(y[i, 16:25] == 1) -
98                           np.argmax(ypred[i, 16:25] == 1)))**2 / 64
99     return score / y.shape[0]
100
101
102 def cl_block(predictor, X, y):
103     ypred = predictor.predict(X)
104     score = 0
105     for i in range(y.shape[0]):
106         if (y[i, 7:25] == ypred[i, 7:25]).all():
107             score += 1
108     return score / y.shape[0]
109
110
111 def cl_block_nice(predictor, X, y):
112     ypred = predictor.predict(X)
113     score = 0
114     for i in range(y.shape[0]):
115         score += (8 - abs(np.argmax(y[i, 7:16] == 1) -
116                           np.argmax(ypred[i, 7:16] == 1)))**2 / 64 * 0.5
117         score += (8 - abs(np.argmax(y[i, 16:25] == 1) -
118                           np.argmax(ypred[i, 16:25] == 1)))**2 / 64 * 0.5
119     return score / y.shape[0]

```

```

1
2 import numpy as np
3
4 from abc import ABCMeta
5 from sklearn.base import BaseEstimator, clone
6 from sklearn.base import RegressorMixin, ClassifierMixin
7 from sklearn.utils.fixes import parallel_helper
8 from sklearn.utils import check_array, check_X_y
9 from sklearn.utils.validation import check_is_fitted, has_fit_parameter
10 from sklearn.externals.joblib import Parallel, delayed
11 from sklearn.externals import six
12
13 __all__ = ["ChainedMultiOutputRegressor", "ChainedMultiOutputClassifier"]
14
15
16 def _fit_estimator(estimator, X, y, sample_weight=None):
17     estimator = clone(estimator)
18     if sample_weight is not None:
19         estimator.fit(X, y, sample_weight=sample_weight)
20     else:
21         estimator.fit(X, y)
22     return estimator
23
24
25 class MultiOutputEstimator(six.with_metaclass(ABCMeta, BaseEstimator)):

```

```

26
27     def __init__(self, estimator, n_jobs=1):
28         self.estimator = estimator
29         self.n_jobs = n_jobs
30
31     def fit(self, X, y, sample_weight=None):
32         """ Fit the model to data.
33         Fit a separate model for each output variable.
34         Parameters
35
36         X : (sparse) array-like, shape (n_samples, n_features)
37             Data.
38         y : (sparse) array-like, shape (n_samples, n_outputs)
39             Multi-output targets. An indicator matrix turns on multilabel
40             estimation.
41         sample_weight : array-like, shape = (n_samples) or None
42             Sample weights. If None, then samples are equally weighted.
43             Only supported if the underlying regressor supports sample
44             weights.
45         Returns
46
47         self : object
48             Returns self.
49         """
50
51     if not hasattr(self.estimator, "fit"):
52         raise ValueError(
53             "The base estimator should implement a fit method")
54
55     X, y = check_X_y(X, y,
56                         multi_output=True,
57                         accept_sparse=True)
58
59     if y.ndim == 1:
60         raise ValueError("y must have at least two dimensions for "
61                         "multi target regression but has only one.")
62
63     if (sample_weight is not None and
64         not has_fit_parameter(self.estimator, 'sample_weight')):
65         raise ValueError("Underlying regressor does not support"
66                         " sample weights.")
67
68     self.estimators_ = Parallel(n_jobs=self.n_jobs)(delayed(_fit_estimator)(
69         self.estimator, np.hstack([X, y[:, :i]]), y[:, i], sample_weight) for
70         i in range(y.shape[1]))
71     return self
72
73     def predict(self, X):
74         """Predict multi-output variable using a model
75             trained for each target variable.
76         Parameters

```

```

77     X : (sparse) array-like, shape (n_samples, n_features)
78         Data.
79     Returns
80
81     y : (sparse) array-like, shape (n_samples, n_outputs)
82         Multi-output targets predicted across multiple predictors.
83         Note: Separate models are generated for each predictor.
84     """
85     check_is_fitted(self, 'estimators_')
86     if not hasattr(self.estimator, "predict"):
87         raise ValueError(
88             "The base estimator should implement a predict method")
89
90     X = check_array(X, accept_sparse=True)
91     y = np.empty(shape=(X.shape[0], len(self.estimators_)))
92     for i, e in enumerate(self.estimators_):
93         pre = np.asarray([e.predict(np.hstack([X, y[:, :i]]))]).T
94         y[:, i] = pre[:, 0]
95     return y
96
97
98 class ChainedMultiOutputRegressor(MultiOutputEstimator, RegressorMixin):
99     """Multi target regression
100    This strategy consists of fitting one regressor per target. This is a
101    simple strategy for extending regressors that do not natively support
102    multi-target regression.
103    Parameters
104
105    estimator : estimator object
106        An estimator object implementing `fit` and `predict`.
107    n_jobs : int, optional, default=1
108        The number of jobs to run in parallel for `fit`. If -1,
109        then the number of jobs is set to the number of cores.
110        When individual estimators are fast to train or predict
111        using `n_jobs>1` can result in slower performance due
112        to the overhead of spawning processes.
113    """
114
115    def __init__(self, estimator, n_jobs=1):
116        super(ChainedMultiOutputRegressor, self).__init__(estimator, n_jobs)
117
118    def score(self, X, y, sample_weight=None):
119        """Returns the coefficient of determination R^2 of the prediction.
120        The coefficient R^2 is defined as  $(1 - u/v)$ , where  $u$  is the regression
121        sum of squares  $((y_{true} - y_{pred}) ** 2).sum()$  and  $v$  is the residual
122        sum of squares  $((y_{true} - y_{true}.mean()) ** 2).sum()$ .
123        Best possible score is 1.0 and it can be negative (because the
124        model can be arbitrarily worse). A constant model that always
125        predicts the expected value of y, disregarding the input features,
126        would get a R^2 score of 0.0.
127        Notes
128

```

```

129     R^2 is calculated by weighting all the targets equally using
130     `multioutput='uniform_average'`.
131
132     Parameters
133
134         X : array-like, shape (n_samples, n_features)
135             Test samples.
136         y : array-like, shape (n_samples) or (n_samples, n_outputs)
137             True values for X.
138         sample_weight : array-like, shape [n_samples], optional
139             Sample weights.
140
141     Returns
142
143         score : float
144             R^2 of self.predict(X) wrt. y.
145
146             # XXX remove in 0.19 when r2_score default for multioutput changes
147             from sklearn.metrics import r2_score
148             return r2_score(y, self.predict(X), sample_weight=sample_weight,
149                             multioutput='uniform_average')
150
151
152 class ChainedMultiOutputClassifier(MultiOutputEstimator, ClassifierMixin):
153     """Multi target classification
154     This strategy consists of fitting one classifier per target. This is a
155     simple strategy for extending classifiers that do not natively support
156     multi-target classification
157
158     Parameters
159
160         estimator : estimator object
161             An estimator object implementing `fit`, `score` and `predict_proba`.
162         n_jobs : int, optional, default=1
163             The number of jobs to use for the computation. If -1 all CPUs are used.
164             If 1 is given, no parallel computing code is used at all, which is
165             useful for debugging. For n_jobs below -1, (n_cpus + 1 + n_jobs) are
166             used. Thus for n_jobs = -2, all CPUs but one are used.
167             The number of jobs to use for the computation.
168             It does each target variable in y in parallel.
169
170     Attributes
171
172         estimators_ : list of `n_output` estimators
173             Estimators used for predictions.
174
175     def __init__(self, estimator, n_jobs=1):
176         super(ChainedMultiOutputClassifier, self).__init__(estimator, n_jobs)
177
178     def predict_proba(self, X):
179         """Probability estimates.
180         Returns prediction probabilites for each class of each output.
181
182         Parameters
183
184             X : array-like, shape (n_samples, n_features)

```

```

181     Data
182     Returns
183
184     T : (sparse) array-like, shape = (n_samples, n_classes, n_outputs)
185         The class probabilities of the samples for each of the outputs
186     """
187     check_is_fitted(self, 'estimators_')
188     if not hasattr(self.estimator, "predict_proba"):
189         raise ValueError("The base estimator should implement"
190                          "predict_proba method")
191     y = []
192     for e in self.estimators_:
193         y.append(np.asarray(e.predict(np.hstack([X, y]))).T)
194     results = np.dstack([estimator.predict_proba(np.hstack([X, y[:, :i]))) for i, estimator in enumerate(self.estimators_)])
195
196     return results
197
198 def score(self, X, y):
199     """Returns the mean accuracy on the given test data and labels.
200     Parameters
201
202     X : array-like, shape [n_samples, n_features]
203         Test samples
204     y : array-like, shape [n_samples, n_outputs]
205         True values for X
206     Returns
207
208     scores : float
209         accuracy-score of self.predict(X) versus y
210     """
211     check_is_fitted(self, 'estimators_')
212     n_outputs_ = len(self.estimators_)
213     if y.ndim == 1:
214         raise ValueError("y must have at least two dimensions for "
215                           "multi target classification but has only one")
216     if y.shape[1] != n_outputs_:
217         raise ValueError("The number of outputs of Y for fit {0} and"
218                           " score {1} should be same".
219                           format(n_outputs_, y.shape[1]))
220     y_pred = self.predict(X)
221     return np.mean(np.all(y == y_pred, axis=1))

```

```

1
2 import sys
3 import time
4 import pandas as pd
5 import numpy as np
6 from sklearn.ensemble import RandomForestClassifier
7 from sklearn.ensemble import ExtraTreesClassifier
8 from sklearn.preprocessing import scale
9 from sklearn.multioutput import MultiOutputClassifier
10 from sklearn.neighbors import KNeighborsClassifier

```

```

11 from sklearn.svm import SVC
12 from sklearn.model_selection import GridSearchCV
13 from sklearn.model_selection import ShuffleSplit
14 from sklearn.externals import joblib
15 from scoring_functions import balanced
16 from scoring_functions import brier
17
18
19 NUM_TRIALS = 20
20 SCORES = [balanced, brier]
21 DF = pd.read_csv('../data/training_data.csv', sep='\t')
22 IN_OPTIONS = ['IN_CR', 'IN_CS', 'IN_DS', 'is_Table', 'is_Columnar', 'is_Int',
23                 'is_Float', 'is_String', 'Type_Size', 'Chunk_Size', 'Mean',
24                 'Median', 'Sd', 'Skew', 'Kurt', 'Min', 'Max', 'Q1', 'Q3',
25                 'N_Streaks', 'BLZ_CRate', 'BLZ_CSspeed', 'BLZ_DSpeed',
26                 'LZ4_CRate', 'LZ4_CSspeed', 'LZ4_DSpeed']
27 OUT_CODEC = ['Blosclz', 'Lz4', 'Lz4hc', 'Zstd']
28 OUT_FILTER = ['Noshuffle', 'Shuffle', 'Bitshuffle']
29 OUT_LEVELS = ['CL1', 'CL2', 'CL3', 'CL4', 'CL5', 'CL6', 'CL7', 'CL8', 'CL9']
30 OUT_BLOCKS = ['Block_8', 'Block_16', 'Block_32', 'Block_64',
31                 'Block_128', 'Block_256', 'Block_512', 'Block_1024',
32                 'Block_2048']
33 OUT_OPTIONS = OUT_CODEC + OUT_FILTER + OUT_LEVELS + OUT_BLOCKS
34 X, Y = scale(DF[IN_OPTIONS].values), DF[OUT_OPTIONS].values
35 ESTIMATORS = []
36 ESTIMATORS.append(( 'KNei' , KNeighborsClassifier(n_jobs=-1),
37                     {'n_neighbors': [5, 10, 15, 30, 50],
38                      'weights': ['uniform', 'distance'],
39                      }, 2))
34 ESTIMATORS.append(( 'SVC' , MultiOutputClassifier(SVC(
35             decision_function_shape='ovr'))),
36                     {'estimator__C': [1, 10, 100, 1000],
37                      'estimator__gamma': [0.1, 0.01, 0.001]}, 1))
34 ESTIMATORS.append(( 'RFC' , RandomForestClassifier(
35             n_estimators=40, max_depth=14, n_jobs=-1),
36                     {'criterion': ['gini', 'entropy'],
37                      'bootstrap': [True, False],
38                      'class_weight': [None, 'balanced']}), 2))
34 ESTIMATORS.append(( 'ETC' , ExtraTreesClassifier(
35             n_estimators=40, max_depth=14, n_jobs=-1),
36                     {'criterion': ['gini', 'entropy'],
37                      'bootstrap': [True, False],
38                      'class_weight': [None, 'balanced']}), 2))
34 TOTAL = len(ESTIMATORS) * len(SCORES) * NUM_TRIALS - NUM_TRIALS
35
36
37 def main():
38     count = 0
39     for estimator_opt, estimator, p_grid, idx in ESTIMATORS:
40         if estimator_opt == 'SVC':
41             splits = 4
42         else:
43

```

```

63     splits = 10
64     for score in SCORES[:idx]:
65         non_nested_scores = np.zeros(NUM_TRIALS)
66         non_nested_estimators = []
67         nested_scores = np.zeros(NUM_TRIALS)
68         nested_estimators = []
69         for i in range(NUM_TRIALS):
70             start_time = time.time()
71             print('Estimator %s, Scorer: %s iteration %d ---- %.2f %% %'
72                   (estimator_opt, score.__name__, i, count / TOTAL * 100))
73             inner_cv = ShuffleSplit(n_splits=splits, test_size=0.25)
74             outer_cv = ShuffleSplit(n_splits=splits, test_size=0.25)
75             clf = GridSearchCV(estimator=estimator, param_grid=p_grid,
76                                 cv=inner_cv, n_jobs=-1, scoring(score))
77             clf.fit(X, Y)
78             non_nested_scores[i] = clf.best_score_
79             non_nested_estimators.append(clf.best_estimator_)
80
81             winner_estimators = []
82             outer_scores = []
83             for train_index, test_index in outer_cv.split(X, Y):
84                 clf = GridSearchCV(estimator=estimator, param_grid=p_grid,
85                                     cv=inner_cv, n_jobs=-1, scoring(score))
86                 clf.fit(X[train_index], Y[train_index])
87                 winner_estimators.append(clf.best_estimator_)
88                 outer_scores.append(
89                     score(clf, X[test_index], Y[test_index]))
90             nested_scores[i] = np.mean(outer_scores)
91             nested_estimators.append(winner_estimators)
92             count += 1
93             print('Time: %f minutes' % ((time.time() - start_time) / 60))
94             joblib.dump(non_nested_scores, estimator_opt +
95                         'non_nested_scores_' +
96                         score.__name__ + '.pkl', compress=('zlib', 3))
97             joblib.dump(nested_scores, estimator_opt + 'nested_scores_' +
98                         score.__name__ + '.pkl', compress=('zlib', 3))
99             joblib.dump(non_nested_estimators, estimator_opt +
100                         'non_nested_estimators_' + score.__name__ + '.pkl',
101                         compress=('zlib', 3))
102             joblib.dump(nested_estimators, estimator_opt +
103                         'nested_estimators_' +
104                         score.__name__ + '.pkl', compress=('zlib', 3))
105
106 if __name__ == '__main__':
107     main()

```

D.2. Cuaderno lda_logit_analysis.ipynb

```

LDA and Logit Analysis

In [1]: %matplotlib inline
%config InlineBackend.figure_format='retina'

%load_ext autoreload
%autoreload 2

%load_ext version_information
%version_information numpy, scipy, matplotlib, pandas, scikit-learn


| Software     | Version                                            |
|--------------|----------------------------------------------------|
| Python       | 3.5.5 64bit [GCC 4.4.7 20120313 (Red Hat 4.4.7-1)] |
| IPython      | 5.1.0                                              |
| OS           | Linux 4.9.16 gentoo x86_64 with debian stretch sid |
| numpy        | 1.12.1                                             |
| scipy        | 0.19.0                                             |
| matplotlib   | 2.0.0                                              |
| pandas       | 0.19.2                                             |
| scikit-learn | 0.18.1                                             |


Fri May 05 16:05:39 2017 UTC

In [2]: import os
import sys
sys.path.append("../src/")

from IPython.display import display
import pandas as pd
import matplotlib
import numpy as np
from matplotlib import pyplot as plt
from sklearn.externals import joblib
from sklearn.discriminant_analysis import LinearDiscriminantAnalysis
from sklearn.discriminant_analysis import QuadraticDiscriminantAnalysis
from sklearn.naive_bayes import GaussianNB
from sklearn.model_selection import ShuffleSplit
from sklearn.model_selection import cross_val_score
from sklearn.multioutput import MultiOutputClassifier
from sklearn.model_selection import GridSearchCV
from sklearn.linear_model import LogisticRegression
from sklearn.linear_model import SGDClassifier
from multioutput_chained import ChainedMultiOutputClassifier
from sklearn.preprocessing import scale
import ml_plots as mp
import scoring_functions as sf
import warnings
warnings.filterwarnings('ignore')

pd.options.display.float_format = '{:.3f}'.format
matplotlib.rcParams.update({'font.size': 12})

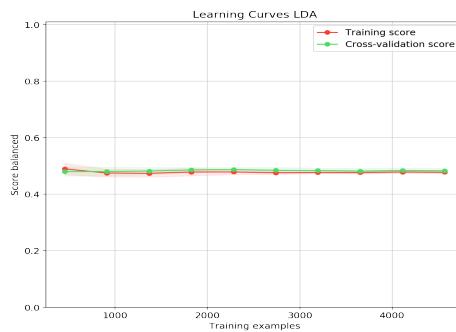
In [3]: SCORES = [(sf.Balanced, 0, 1.01)]
IN_OPTIONS = ['IN_CR', 'IN_CS', 'IN_DS', 'is_Table', 'is_Columnar',
              'is_Int', 'is_Float', 'is_String', 'Type_Size', 'Chunk_Size',
              'Mean', 'Median', 'Sd', 'Skew', 'Kurt', 'Min', 'Max', 'Q1',
              'Q3', 'N_Streaks', 'BLZ_CRate', 'BLZ_CSpeed',
              'BLZ_DSpeed', 'LZ4_CRate', 'LZ4_CSpeed', 'LZ4_DSpeed']
OUT_CODEC = ['Blosc1z', 'Lz4', 'Lz4hc', 'Zstd']
OUT_FILTER = ['Noshuffle', 'Shuffle', 'Bitshuffle']
OUT_LEVELS = ['CL1', 'CL2', 'CL3', 'CL4', 'CL5', 'CL6', 'CL7', 'CL8', 'CL9']
OUT_BLOCKS = ['Block_8', 'Block_16', 'Block_32', 'Block_64', 'Block_128',
              'Block_256', 'Block_512', 'Block_1024', 'Block_2048']
OUT_OPTIONS = OUT_CODEC + OUT_FILTER + OUT_LEVELS + OUT_BLOCKS
CUSTOM3_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSpeed',
              'Mean', 'Kurt', 'Skew', 'N_Streaks', 'Max', 'Min']
CUSTOM2_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSpeed',
              'Mean', 'Kurt', 'Skew', 'Max', 'Min']
CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'BLZ_CSpeed']

In [4]: df = pd.read_csv('../data/training_data.csv', sep='\t')
X, Y = scale(df[CUSTOM3_IN].values), df[OUT_OPTIONS].values

LDA - Curva de aprendizaje

In [5]: title = "Learning Curves LDA"
lda = MultiOutputClassifier(LinearDiscriminantAnalysis())
cv = ShuffleSplit(n_splits=10, test_size=0.1)
fig = plt.figure(figsize=(20,8))
n = 121
for score in SCORES:
    mp.plot_learning_curve(
        fig.add_subplot(n), lda, title, X, Y, scoring=score[0],
        ylim=(score[1], score[2]), cv=cv, n_jobs=-1,
        train_sizes=np.linspace(.1, 1.0, 10))
    n += 1

```



LDA - Resultados

```
In [6]: print('Normal')
cv = ShuffleSplit(n_splits=10, test_size=0.5, random_state=1)
lda = MultiOutputClassifier(LinearDiscriminantAnalysis())
display(mp.cross_val_report(lda, cv, X, Y, True))
print('Chained')
lda = ChainedMultiOutputClassifier(LinearDiscriminantAnalysis())
display(mp.cross_val_report(lda, cv, X, Y, True))

Normal
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.4796 +/- (0.0082)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0610 +/- (0.0059)                       |
| codec        | 0.7032 +/- (0.0172)                       |
| filter_      | 0.5821 +/- (0.0085)                       |
| codec_filter | 0.4138 +/- (0.0142)                       |
| c_level      | 0.1937 +/- (0.0105) ~ 0.5667 +/- (0.0051) |
| block        | 0.1455 +/- (0.0044) ~ 0.5241 +/- (0.0045) |
| cl_block     | 0.1029 +/- (0.0054) ~ 0.5454 +/- (0.0041) |


Chained
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6150 +/- (0.0110)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1247 +/- (0.0089)                       |
| codec        | 0.7908 +/- (0.0064)                       |
| filter_      | 0.6708 +/- (0.0083)                       |
| codec_filter | 0.5589 +/- (0.0130)                       |
| c_level      | 0.3127 +/- (0.0136) ~ 0.6129 +/- (0.0188) |
| block        | 0.3558 +/- (0.0116) ~ 0.7293 +/- (0.0105) |
| cl_block     | 0.1807 +/- (0.0105) ~ 0.6711 +/- (0.0139) |


In [7]: CUSTOM2_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSspeed',
                 'Mean', 'Kurt', 'Skew', 'Max', 'Min']
X = scale(df[CUSTOM2_IN].values)
print('Normal')
lda = MultiOutputClassifier(LinearDiscriminantAnalysis())
display(mp.cross_val_report(lda, cv, X, Y, True))
print('Chained')
lda = ChainedMultiOutputClassifier(LinearDiscriminantAnalysis())
display(mp.cross_val_report(lda, cv, X, Y, True))

Normal
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.4778 +/- (0.0075)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0597 +/- (0.0055)                       |
| codec        | 0.7048 +/- (0.0173)                       |
| filter_      | 0.5707 +/- (0.0083)                       |
| codec_filter | 0.4106 +/- (0.0125)                       |
| c_level      | 0.1951 +/- (0.0116) ~ 0.5667 +/- (0.0050) |
| block        | 0.1376 +/- (0.0054) ~ 0.5231 +/- (0.0046) |
| cl_block     | 0.1029 +/- (0.0053) ~ 0.5449 +/- (0.0041) |


Chained
```

```

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6144 +/- (0.0079)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1314 +/- (0.0087)                       |
| codec        | 0.7928 +/- (0.0069)                       |
| filter_      | 0.6611 +/- (0.0052)                       |
| codec_filter | 0.5554 +/- (0.0083)                       |
| c_level      | 0.318 +/- (0.0122) ~ 0.6156 +/- (0.0179)  |
| block        | 0.3553 +/- (0.0137) ~ 0.7309 +/- (0.0101) |
| cl_block     | 0.1863 +/- (0.0090) ~ 0.6733 +/- (0.0130) |


In [8]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'BLZ_CSspeed']
x = scale(df[CUSTOM_IN].values)
print('Normal')
lda = MultiOutputClassifier(LinearDiscriminantAnalysis())
display(mp.cross_val_report(lda, cv, x, Y, True))
print('Chained')
lda = ChainedMultiOutputClassifier(LinearDiscriminantAnalysis())
display(mp.cross_val_report(lda, cv, x, Y, True))
Normal
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.4549 +/- (0.0092)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0500 +/- (0.0059)                       |
| codec        | 0.7039 +/- (0.0150)                       |
| filter_      | 0.5250 +/- (0.0105)                       |
| codec_filter | 0.3653 +/- (0.0156)                       |
| c_level      | 0.1825 +/- (0.0094) ~ 0.5669 +/- (0.0052) |
| block        | 0.1361 +/- (0.0054) ~ 0.5222 +/- (0.0049) |
| cl_block     | 0.1022 +/- (0.0038) ~ 0.5446 +/- (0.0043) |


Chained
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6016 +/- (0.0120)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1209 +/- (0.0068)                       |
| codec        | 0.7943 +/- (0.0063)                       |
| filter_      | 0.6451 +/- (0.0092)                       |
| codec_filter | 0.5316 +/- (0.0141)                       |
| c_level      | 0.3156 +/- (0.0139) ~ 0.6120 +/- (0.0249) |
| block        | 0.3574 +/- (0.0140) ~ 0.7311 +/- (0.0112) |
| cl_block     | 0.1867 +/- (0.0096) ~ 0.6715 +/- (0.0163) |

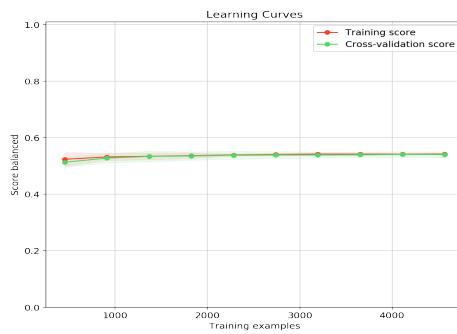

```

Logit - Curva de aprendizaje

```

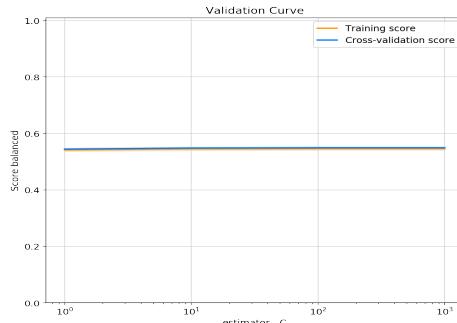
In [9]: df = pd.read_csv('../data/training_data.csv', sep='\t')
x, Y = scale(df[CUSTOM3_IN].values), df[OUT_OPTIONS].values
In [10]: title = "Learning Curves"
lda = MultiOutputClassifier(LogisticRegression())
cv = Shufflesplit(n_splits=10, test_size=0.1)
fig = plt.figure(figsize=(20,8))
n = 121
for score in SCORES:
    mp.plot_learning_curve(
        fig.add_subplot(n), lda, title, x, Y, scoring=score[0],
        ylim=(score[1], score[2]), cv=cv, n_jobs=-1,
        train_sizes=np.linspace(.1, 1.0, 10))
    n += 1

```



Logit - Curva de validación

```
In [11]: PARAM_NAMES = ['estimator_C']
PARAM_RANGES = [[1, 10, 100, 1000]]
cv = ShuffleSplit(n_splits=10, test_size=0.5)
clf = MultiOutputClassifier(LogisticRegression(solver='newton-cg'))
fig = plt.figure(figsize=(20, 8))
n = 121
for score in SCORES:
    ax = mp.plot_validation_curve(
        fig.add_subplot(n), clf, X, Y, param_name=PARAM_NAMES[0],
        param_range=PARAM_RANGES[0], cv=cv, scoring=score[0],
        ylim=(score[1], score[2]))
    ax.semilogx()
    n += 1
```



Logit - Resultados

```
In [12]: print('Normal')
clf = MultiOutputClassifier(LogisticRegression(solver='newton-cg'))
display(mp.cross_val_report(clf, cv, X, Y, True))
print('Chained')
clf = ChainedMultiOutputClassifier(LogisticRegression(solver='newton-cg'))
display(mp.cross_val_report(clf, cv, X, Y, True))
```

Name	Score
balanced	0.5397 +/- (0.0024)
brier	0.0000 +/- (0.0000)
normal	0.0810 +/- (0.0053)
codec	0.7857 +/- (0.0072)
filter_	0.6887 +/- (0.0069)
codec_filter	0.5394 +/- (0.0085)
c_level	0.1878 +/- (0.0150) ~ 0.5624 +/- (0.0042)
block	0.1438 +/- (0.0059) ~ 0.5229 +/- (0.0051)
cl_block	0.1015 +/- (0.0037) ~ 0.5416 +/- (0.0042)

Normal

Name	Score
balanced	0.6204 +/- (0.0079)

```

brier      0.0000 +/- (0.0000)
normal     0.1454 +/- (0.0076)
codec      0.8460 +/- (0.0085)
filter_    0.7440 +/- (0.0075)
codec_filter 0.6396 +/- (0.0115)
c_level    0.3435 +/- (0.0105) ~ 0.5519 +/- (0.0281)
block      0.3004 +/- (0.0113) ~ 0.6409 +/- (0.0148)
cl_block   0.1717 +/- (0.0078) ~ 0.5971 +/- (0.0126)

In [13]: CUSTOM2_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSspeed',
                  'Mean', 'Kurt', 'Skew', 'Max', 'Min']
X = scale(df[CUSTOM2_IN].values)
print('Normal')
clf = MultiOutputClassifier(LogisticRegression(solver='newton-cg'))
display(mp.cross_val_report(clf, cv, X, Y, True))
print('Chained')
clf = ChainedMultiOutputClassifier(LogisticRegression(solver='newton-cg'))
display(mp.cross_val_report(clf, cv, X, Y, True))

Normal
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.5388 +/- (0.0053)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0816 +/- (0.0036)                       |
| codec        | 0.7863 +/- (0.0068)                       |
| filter_      | 0.6798 +/- (0.0054)                       |
| codec_filter | 0.5343 +/- (0.0054)                       |
| c_level      | 0.1970 +/- (0.0090) ~ 0.5634 +/- (0.0055) |
| block        | 0.1433 +/- (0.0034) ~ 0.5204 +/- (0.0043) |
| cl_block     | 0.1034 +/- (0.0041) ~ 0.5417 +/- (0.0029) |


Chained
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6147 +/- (0.0073)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1416 +/- (0.0052)                       |
| codec        | 0.8478 +/- (0.0041)                       |
| filter_      | 0.7437 +/- (0.0143)                       |
| codec_filter | 0.6449 +/- (0.0140)                       |
| c_level      | 0.3489 +/- (0.0191) ~ 0.5747 +/- (0.0178) |
| block        | 0.2876 +/- (0.0137) ~ 0.6193 +/- (0.0149) |
| cl_block     | 0.1783 +/- (0.0088) ~ 0.6061 +/- (0.0163) |


In [14]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'BLZ_CSspeed']
X = scale(df[CUSTOM_IN].values)
print('Normal')
clf = MultiOutputClassifier(LogisticRegression(solver='newton-cg'))
display(mp.cross_val_report(clf, cv, X, Y, True))
print('Chained')
clf = ChainedMultiOutputClassifier(LogisticRegression(solver='newton-cg'))
display(mp.cross_val_report(clf, cv, X, Y, True))

Normal
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.5287 +/- (0.0028)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0723 +/- (0.0051)                       |
| codec        | 0.7839 +/- (0.0068)                       |
| filter_      | 0.6468 +/- (0.0075)                       |
| codec_filter | 0.5114 +/- (0.0071)                       |
| c_level      | 0.1752 +/- (0.0073) ~ 0.5651 +/- (0.0032) |
| block        | 0.1420 +/- (0.0050) ~ 0.5238 +/- (0.0038) |
| cl_block     | 0.1009 +/- (0.0033) ~ 0.5437 +/- (0.0038) |


Chained
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6066 +/- (0.0086)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1443 +/- (0.0092)                       |
| codec        | 0.8486 +/- (0.0072)                       |
| filter_      | 0.7129 +/- (0.0134)                       |
| codec_filter | 0.6217 +/- (0.0069)                       |
| c_level      | 0.3508 +/- (0.0140) ~ 0.5666 +/- (0.0145) |
| block        | 0.2701 +/- (0.0089) ~ 0.6315 +/- (0.0202) |
| cl_block     | 0.1783 +/- (0.0065) ~ 0.5895 +/- (0.0179) |


```

D.3. Cuaderno SVM_analysis.ipynb

Algoritmos SVM

```
In [1]: %matplotlib inline
%config InlineBackend.figure_format='retina'

%load_ext autoreload
%autoreload 2

%load_ext version_information
%version_information numpy, scipy, matplotlib, pandas, scikit-learn


| Software     | Version                                            |
|--------------|----------------------------------------------------|
| Python       | 3.5.3 64bit [GCC 4.4.7 20120313 (Red Hat 4.4.7-1)] |
| IPython      | 5.1.0                                              |
| OS           | Linux 4.9.16 gentoo x86_64 with debian stretch sid |
| numpy        | 1.12.1                                             |
| scipy        | 0.19.0                                             |
| matplotlib   | 2.0.0                                              |
| pandas       | 0.19.2                                             |
| scikit-learn | 0.18.1                                             |


Sat May 06 19:12:34 2017 UTC

In [2]: import os
import sys
sys.path.append("../src/")

from IPython.display import display
import pandas as pd
import matplotlib
import numpy as np
from matplotlib import pyplot as plt
from sklearn.externals import joblib
from sklearn.svm import SVC, LinearSVC
from sklearn.model_selection import ShuffleSplit
from sklearn.model_selection import cross_val_score
from sklearn.multioutput import MultiOutputClassifier
from multioutput_chained import ChainedMultiOutputClassifier
from sklearn.preprocessing import scale
import ml_plots as mp
import scoring_functions as sf

pd.options.display.float_format = '{:.3f}'.format
matplotlib.rcParams.update({'font.size': 12})

In [3]: SCORES = [(sf.balanced, 0.2, 1.01)]
IN_OPTIONS = ['IN_CR', 'IN_CS', 'IN_DS', 'is_Table', 'is_Columnnar',
              'is_Int', 'is_Float', 'is_String', 'Type_Size', 'Chunk_Size',
              'Mean', 'Median', 'Sd', 'Skew', 'Kurt', 'Min', 'Max', 'Q1',
              'Q3', 'BLZ_CRate', 'BLZ_CSspeed', 'BLZ_DSspeed', 'LZ4_CRate',
              'LZ4_CSspeed', 'LZ4_DSspeed']

OUT_CODEC = ['Blosclz', 'Lz4', 'Lz4hc', 'zstd']
OUT_FILTER = ['Noshuffle', 'Shuffle', 'Bitshuffle']
OUT_LEVELS = ['CL1', 'CL2', 'CL3', 'CL4', 'CL5', 'CL6', 'CL7', 'CL8', 'CL9']
OUT_BLOCKS = ['Block_8', 'Block_16', 'Block_32', 'Block_64', 'Block_128',
              'Block_256', 'Block_512', 'Block_1024', 'Block_2048']
OUT_OPTIONS = OUT_CODEC + OUT_FILTER + OUT_LEVELS + OUT_BLOCKS

In [4]: df = pd.read_csv('../data/training_data.csv', sep='\t')
df = df[IN_OPTIONS].values
/home/shurerto/miniconda3/lib/python3.5/site-packages/sklearn/preprocessing/data.py:160: UserWarning: Numerical issues were encountered when centering the data and might not be solved. Dataset may contain too large values. You may need to prescale your features.
warnings.warn('Numerical issues were encountered ')

In [5]: clf = LinearSVC()
clf = MultiOutputClassifier(clf)
```

SVM rbf - Curva de aprendizaje

```
svc = SVC(kernel='rbf')

clf = MultiOutputClassifier(svc)
title = "Learning Curves (rbf SVC)" cv = ShuffleSplit(n_splits=10, test_size=0.1) fig = plt.figure(figsize=(20,8)) n = 121 for score in SCORES:
mp.plot_learning_curve(fig.add_subplot(n), clf, title, X, Y, scoring=score[0], ylim=(score[1], score[2]), cv=cv, n_jobs=-1, train_sizes=np.linspace(.1, 1.0, 10)) n += 1
```

SVM rbf - Validación cruzada de hiperparámetros

```
nested_clf = joblib.load(
    '../src/SVCnested_estimators_my_accuracy_scorer.pkl')
non_nested_clf = joblib.load(
    '../src/SVCnon_nested_estimators_my_accuracy_scorer.pkl')
mp.print_nested_winners(nested_clf, non_nested_clf)

Non Nested Winners
estimator__C --> Counter({1000: 20})
estimator__gamma --> Counter({0.1: 20})
Nested Winners
estimator__C --> Counter({1000: 61, 100: 19})
estimator__gamma --> Counter({0.1: 80})
```

```
In [6]: del nested_clf
del non_nested_clf
```

SVM rbf - Resultados

```
In [8]: clf1 = MultiOutputClassifier(
    SVC(C=1000, gamma=0.1, decision_function_shape='ovr'))
cv = ShuffleSplit(n_splits=5, test_size=0.25, random_state=1)
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.7861 +/- (0.0067)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.2380 +/- (0.0119)                       |
| codec        | 0.9344 +/- (0.0054)                       |
| filter_      | 0.9087 +/- (0.0040)                       |
| codec_filter | 0.8564 +/- (0.0092)                       |
| c_level      | 0.4317 +/- (0.0185) ~ 0.7000 +/- (0.0112) |
| block        | 0.4017 +/- (0.0090) ~ 0.7313 +/- (0.0050) |
| cl_block     | 0.2492 +/- (0.0127) ~ 0.7157 +/- (0.0076) |



In [9]: CUSTOM3_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSpeed',
    'Mean', 'Kurt', 'Skew', 'N_Streaks', 'Max', 'Min']
X = scale(df[CUSTOM3_IN].values)
clf1 = MultiOutputClassifier(
    SVC(C=1000, gamma=0.1, decision_function_shape='ovr'))
mp.cross_val_report(clf1, cv, X, Y, True)
/home/shurberito/miniconda3/lib/python3.5/site-packages/sklearn/preprocessing/data.py:160: UserWarning: Numerical issues were encountered when centering the data and might not be solved. Dataset may contain too large values. You may need to prescale your features.
  warnings.warn("Numerical issues were encountered")

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.7061 +/- (0.0125)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1831 +/- (0.0096)                       |
| codec        | 0.8928 +/- (0.0066)                       |
| filter_      | 0.8591 +/- (0.0188)                       |
| codec_filter | 0.7850 +/- (0.0119)                       |
| c_level      | 0.3411 +/- (0.0188) ~ 0.6297 +/- (0.0113) |
| block        | 0.2994 +/- (0.0187) ~ 0.6245 +/- (0.0210) |
| cl_block     | 0.1970 +/- (0.0091) ~ 0.6271 +/- (0.0132) |



In [10]: CUSTOM2_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSpeed',
    'Mean', 'Kurt', 'Skew', 'Max', 'Min']
X = scale(df[CUSTOM2_IN].values)
clf1 = MultiOutputClassifier(
    SVC(C=1000, gamma=0.1, decision_function_shape='ovr'))
mp.cross_val_report(clf1, cv, X, Y, True)
/home/shurberito/miniconda3/lib/python3.5/site-packages/sklearn/preprocessing/data.py:160: UserWarning: Numerical issues were encountered when centering the data and might not be solved. Dataset may contain too large values. You may need to prescale your features.
  warnings.warn("Numerical issues were encountered")

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6272 +/- (0.0084)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1359 +/- (0.0113)                       |
| codec        | 0.8870 +/- (0.0039)                       |
| filter_      | 0.7325 +/- (0.0088)                       |
| codec_filter | 0.6602 +/- (0.0114)                       |
| c_level      | 0.3024 +/- (0.0198) ~ 0.6121 +/- (0.0125) |
| block        | 0.2293 +/- (0.0065) ~ 0.5762 +/- (0.0088) |
| cl_block     | 0.1658 +/- (0.0124) ~ 0.5941 +/- (0.0088) |



In [11]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'BLZ_CSpeed']
X = scale(df[CUSTOM_IN].values)
clf1 = MultiOutputClassifier(
    SVC(C=1000, gamma=0.1, decision_function_shape='ovr'))
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.5954 +/- (0.0060)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1196 +/- (0.0058)                       |
| codec        | 0.8821 +/- (0.0048)                       |
| filter_      | 0.6824 +/- (0.0075)                       |
| codec_filter | 0.6156 +/- (0.0074)                       |
| c_level      | 0.2772 +/- (0.0133) ~ 0.5927 +/- (0.0174) |
| block        | 0.1931 +/- (0.0077) ~ 0.5577 +/- (0.0093) |
| cl_block     | 0.1417 +/- (0.0103) ~ 0.5752 +/- (0.0101) |



In [12]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR']
X = scale(df[CUSTOM_IN].values)
clf1 = MultiOutputClassifier(
```

```

SVC(C=1000, gamma=0.1, decision_function_shape='ovr'))
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.3990 +/- (0.0279)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0402 +/- (0.0205)                       |
| codec        | 0.7554 +/- (0.0048)                       |
| filter_      | 0.3545 +/- (0.0560)                       |
| codec_filter | 0.2657 +/- (0.0493)                       |
| c_level      | 0.1064 +/- (0.0310) ~ 0.5645 +/- (0.0156) |
| block        | 0.1176 +/- (0.0093) ~ 0.5002 +/- (0.0115) |
| cl_block     | 0.0924 +/- (0.0076) ~ 0.5323 +/- (0.0120) |



In [13]: CUSTOM3_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSspeed',
      'Mean', 'Kurt', 'Skew', 'N_Streaks', 'Max', 'Min']
X = scale(df[CUSTOM3_IN].values)
clf1 = ChainedMultiOutputClassifier(
    SVC(C=1000, gamma=0.1, decision_function_shape='ovr'))
mp.cross_val_report(clf1, cv, X, Y, True)
/home/shurberito/miniconda3/lib/python3.5/site-packages/aklearn/preprocessing/data.py:160: UserWarning: Numerical issues were encountered when centering the data and might not be solved. Dataset may contain too large values. You may need to prescale your features.
warnings.warn('Numerical issues were encountered')

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8011 +/- (0.0037)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.3045 +/- (0.0119)                       |
| codec        | 0.9054 +/- (0.0058)                       |
| filter_      | 0.8801 +/- (0.0059)                       |
| codec_filter | 0.8201 +/- (0.0070)                       |
| c_level      | 0.4994 +/- (0.0122) ~ 0.7628 +/- (0.0061) |
| block        | 0.4739 +/- (0.0149) ~ 0.8005 +/- (0.0060) |
| cl_block     | 0.3165 +/- (0.0152) ~ 0.7816 +/- (0.0052) |

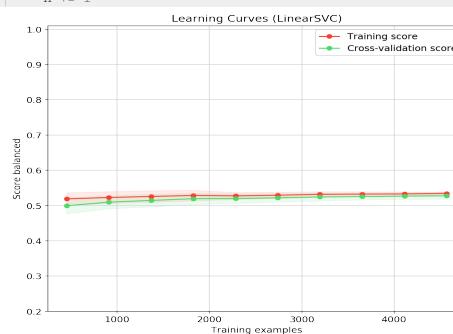

```

LinearSVC - Curva de aprendizaje

```

In [14]: title = "Learning Curves (LinearSVC)"
cv = Shufflesplit(n_splits=10, test_size=0.1)
fig = plt.figure(figsize=(20,8))
n = 121
for score in SCORES:
    mp.plot_learning_curve(
        fig.add_subplot(n), clf, title, X, Y, scoring=score[0],
        ylim=(score[1], score[2]), cv=cv, n_jobs=-1,
        train_sizes=np.linspace(.1, 1.0, 10))
    n += 1

```

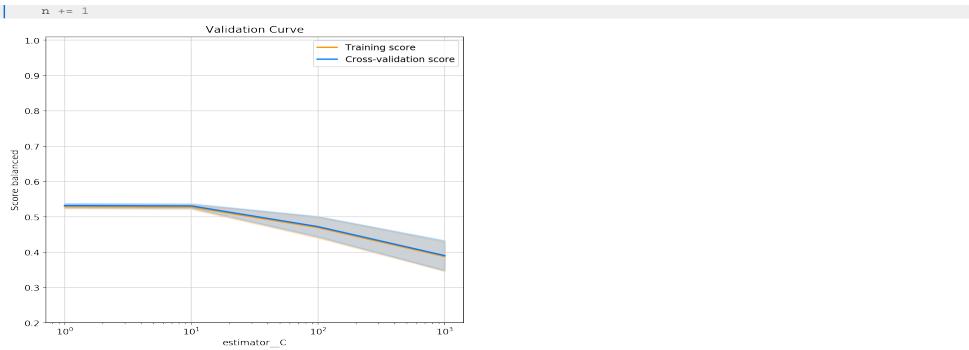


LinearSVC - Curva de validación

```

In [15]: PARAM_NAMES = ['estimator__C']
PARAM_RANGES = [[1, 10, 100, 1000]]
cv = Shufflesplit(n_splits=10, test_size=0.5)
clf = MultiOutputClassifier(LinearSVC())
fig = plt.figure(figsize=(20, 8))
n = 121
for score in SCORES:
    ax = mp.plot_validation_curve(
        fig.add_subplot(n), clf, X, Y, param_name=PARAM_NAMES[0],
        param_range=PARAM_RANGES[0], cv=cv, scoring=score[0],
        ylim=(score[1], score[2]))
    ax.semilogx()

```



LinearSVC - Resultados

```
In [16]: print('Normal')
clf = MultiOutputClassifier(LinearSVC())
display(mp.cross_val_report(clf, cv, X, Y, True))
print('Chained')
clf = ChainedMultiOutputClassifier(LinearSVC())
display(mp.cross_val_report(clf, cv, X, Y, True))

Normal
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.5294 +/- (0.0061)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0768 +/- (0.0043)                       |
| codec        | 0.7748 +/- (0.0121)                       |
| filter_      | 0.6686 +/- (0.0139)                       |
| codec_filter | 0.5160 +/- (0.0155)                       |
| c_level      | 0.1733 +/- (0.0084) ~ 0.5621 +/- (0.0045) |
| block        | 0.1390 +/- (0.0051) ~ 0.5212 +/- (0.0035) |
| cl_block     | 0.1000 +/- (0.0051) ~ 0.5405 +/- (0.0038) |


Chained
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6194 +/- (0.0067)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1429 +/- (0.0077)                       |
| codec        | 0.8407 +/- (0.0130)                       |
| filter_      | 0.7246 +/- (0.0135)                       |
| codec_filter | 0.6183 +/- (0.0136)                       |
| c_level      | 0.3244 +/- (0.0159) ~ 0.5429 +/- (0.0221) |
| block        | 0.3168 +/- (0.0090) ~ 0.6557 +/- (0.0162) |
| cl_block     | 0.1679 +/- (0.0059) ~ 0.6108 +/- (0.0111) |


In [17]: CUSTOM2_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRATE', 'Sd', 'BLZ_CSPEED',
   ...: 'Mean', 'Kurt', 'Skew', 'Max', 'Min']
X = scale(df[CUSTOM2_IN].values)
print('Normal')
clf = MultiOutputClassifier(LinearSVC())
display(mp.cross_val_report(clf, cv, X, Y, True))
print('Chained')
clf = ChainedMultiOutputClassifier(LinearSVC())
display(mp.cross_val_report(clf, cv, X, Y, True))

/home/shurberito/miniconda3/lib/python3.5/site-packages/sklearn/preprocessing/data.py:160: UserWarning: Numerical issues were encountered when centering the data and might not be solved. Dataset may contain too large values. You may need to prescale your features.
  warnings.warn("Numerical issues were encountered")

Normal
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.5305 +/- (0.0070)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0710 +/- (0.0070)                       |
| codec        | 0.7675 +/- (0.0076)                       |
| filter_      | 0.6630 +/- (0.0161)                       |
| codec_filter | 0.5220 +/- (0.0124)                       |
| c_level      | 0.1724 +/- (0.0049) ~ 0.5647 +/- (0.0062) |
| block        | 0.1384 +/- (0.0046) ~ 0.5223 +/- (0.0043) |


```

```

cl_block      0.1036 +/- (0.0035) ~ 0.5368 +/- (0.0034)
Chained
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6208 +/- (0.0106)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1435 +/- (0.0076)                       |
| codec        | 0.8437 +/- (0.0088)                       |
| filter_      | 0.7249 +/- (0.0169)                       |
| codec_filter | 0.6210 +/- (0.0135)                       |
| c_level      | 0.3272 +/- (0.0101) ~ 0.5428 +/- (0.0246) |
| block        | 0.3063 +/- (0.0088) ~ 0.6535 +/- (0.0206) |
| cl_block     | 0.1712 +/- (0.0090) ~ 0.6138 +/- (0.0077) |


In [18]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'BLZ_CSspeed']
X = scale(df[CUSTOM_IN].values)
print('Normal')
clf = MultiOutputClassifier(LinearSVC())
display(mp.cross_val_report(clf, cv, X, Y, True))
print('Chained')
clf = ChainedMultiOutputClassifier(LinearSVC())
display(mp.cross_val_report(clf, cv, X, Y, True))
Normal
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.5197 +/- (0.0046)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0688 +/- (0.0052)                       |
| codec        | 0.7777 +/- (0.0063)                       |
| filter_      | 0.6350 +/- (0.0094)                       |
| codec_filter | 0.4986 +/- (0.0121)                       |
| c_level      | 0.1657 +/- (0.0045) ~ 0.5626 +/- (0.0066) |
| block        | 0.1363 +/- (0.0042) ~ 0.5204 +/- (0.0041) |
| cl_block     | 0.1002 +/- (0.0034) ~ 0.5416 +/- (0.0043) |


Chained
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6050 +/- (0.0074)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1520 +/- (0.0117)                       |
| codec        | 0.8480 +/- (0.0091)                       |
| filter_      | 0.6983 +/- (0.0136)                       |
| codec_filter | 0.6115 +/- (0.0093)                       |
| c_level      | 0.3255 +/- (0.0123) ~ 0.5523 +/- (0.0307) |
| block        | 0.3167 +/- (0.0151) ~ 0.6641 +/- (0.0235) |
| cl_block     | 0.1704 +/- (0.0077) ~ 0.6031 +/- (0.0189) |


```

D.4. Cuaderno KNeig_analysis.ipynb

Vecinos más próximos

```
In [1]: %matplotlib inline
%config InlineBackend.figure_format='retina'

%load_ext autoreload
%autoreload 2

%load_ext version_information
%version_information numpy, scipy, matplotlib, pandas, scikit-learn


| Software     | Version                                            |
|--------------|----------------------------------------------------|
| Python       | 3.5.3 64bit [GCC 4.4.7 20120313 (Red Hat 4.4.7-1)] |
| IPython      | 5.1.0                                              |
| OS           | Linux 4.9.16 gentoo x86_64 with debian stretch sid |
| numpy        | 1.12.1                                             |
| scipy        | 0.19.0                                             |
| matplotlib   | 2.0.0                                              |
| pandas       | 0.19.2                                             |
| scikit-learn | 0.18.1                                             |


Sat May 06 10:20:07 2017 UTC

In [2]: import os
import sys
sys.path.append("../src/*")

from IPython.display import display
import pandas as pd
import matplotlib
import numpy as np
from matplotlib import pyplot as plt
from sklearn.externals import joblib
from sklearn.neighbors import KNeighborsClassifier
from sklearn.model_selection import ShuffleSplit
from sklearn.model_selection import cross_val_score
from sklearn.multioutput import MultiOutputClassifier
from multioutput_chained import ChainedMultiOutputClassifier
from sklearn.preprocessing import scale
import ml_plots as mp
import scoring_functions as sf
import warnings
warnings.filterwarnings('ignore')

pd.options.display.float_format = '{:.3f}'.format
matplotlib.rcParams.update({'font.size': 12})

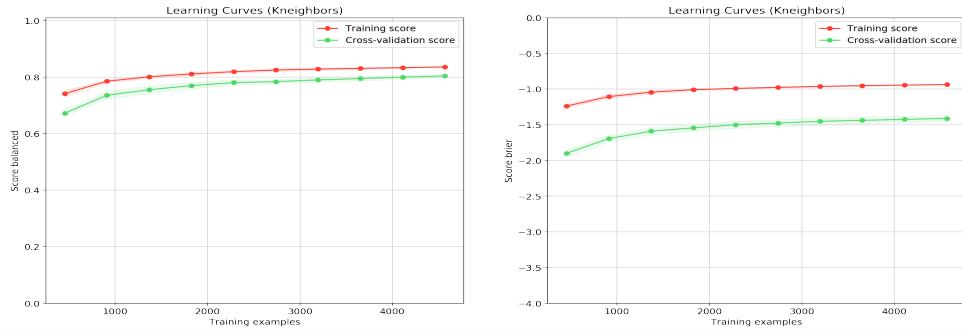
In [3]: SCORES = [(sf.balanced, 0, 1.01), (sf.brier, -4, 0)]
IN_OPTIONS = ['IN_CR', 'IN_CS', 'IN_DS', 'is_Table', 'is_Columnar',
              'is_Int', 'is_Float', 'is_String', 'Type_Size', 'Chunk_Size',
              'Mean', 'Median', 'Sd', 'Skew', 'Kurt', 'Min', 'Max', 'Q1',
              'Q3', 'N_Streaks', 'BLZ_CRate', 'BLZ_CSpeed',
              'BLZ_DSpeed', 'LZ4_CRate', 'LZ4_CSpeed', 'LZ4_DSpeed']
OUT_CODEC = ['Blosclz', 'Lz4', 'Lz4hc', 'Zstd']
OUT_FILTER = ['Noshuffle', 'Shuffle', 'Bitshuffle']
OUT_LEVELS = ['CL1', 'CL2', 'CL3', 'CL4', 'CL5', 'CL6', 'CL7', 'CL8', 'CL9']
OUT_BLOCKS = ['Block_8', 'Block_16', 'Block_32', 'Block_64', 'Block_128',
              'Block_256', 'Block_512', 'Block_1024', 'Block_2048']
OUT_OPTIONS = OUT_CODEC + OUT_FILTER + OUT_LEVELS + OUT_BLOCKS

df = pd.read_csv('../data/training_data.csv', sep='\t')
X, Y = scale(df[IN_OPTIONS].values), df[OUT_OPTIONS].values

In [5]: clf = KNeighborsClassifier(weights='uniform')
```

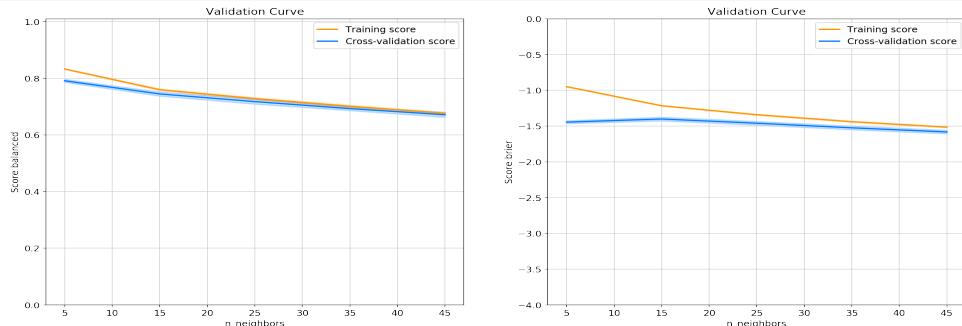
KNeigh - Curvas de aprendizaje

```
In [6]: title = "Learning Curves (Kneighbors)"
cv = ShuffleSplit(n_splits=10, test_size=0.1)
fig = plt.figure(figsize=(20,8))
n = 121
for score in SCORES:
    mp.plot_learning_curve(
        fig.add_subplot(n), clf, title, X, Y, scoring=score[0],
        ylim=(score[1], score[2]), cv=cv, n_jobs=-1,
        train_sizes=np.linspace(.1, 1.0, 10))
    n += 1
```



KNeigh - Curvas de validación

```
In [7]: PARAM_NAMES = ['n_neighbors']
PARAM_RANGES = [[5, 15, 25, 35, 45]]
cv = ShuffleSplit(n_splits=10, test_size=0.25)
fig = plt.figure(figsize=(20, 8))
n = 121
for score in SCORES:
    mp.plot_validation_curve(
        fig.add_subplot(n), clf, X, Y, param_name=PARAM_NAMES[0],
        param_range=PARAM_RANGES[0], cv=cv, scoring=score[0],
        ylim=(score[1], score[2]))
    n += 1
```



KNeigh - Validación cruzada de hiperparámetros

```
In [8]: nested_clf = joblib.load(
    '../src/KNeinested_estimators_my_accuracy_scorer.pkl')
non_nested_clf = joblib.load(
    '../src/KNeinon_nested_estimators_my_accuracy_scorer.pkl')
mp.print_nested_winners(nested_clf, non_nested_clf)
Non Nested Winners
n_neighbors --> Counter({5: 20})
weights --> Counter({'distance': 20})
Nested Winners
n_neighbors --> Counter({5: 200})
weights --> Counter({'distance': 200})

nested_clf = joblib.load(
    '../src/KNeinested_estimators_my_brier_scorer.pkl')
non_nested_clf = joblib.load(
    '../src/KNeinon_nested_estimators_my_brier_scorer.pkl')
mp.print_nested_winners(nested_clf, non_nested_clf)
Non Nested Winners
n_neighbors --> Counter({15: 20})
weights --> Counter({'distance': 20})
Nested Winners
n_neighbors --> Counter({15: 200})
weights --> Counter({'distance': 200})
In [10]: del nested_clf
del non_nested_clf
```

KNeigh - Resultados

```
In [11]: clf1 = KNeighborsClassifier(n_neighbors=5, weights='uniform')
mp.cross_val_report(clf1, cv, X, Y)
```

```

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.7930 +/-(-0.0053)                       |
| brier        | -1.4488 +/-(-0.0268)                      |
| normal       | 0.2631 +/-(-0.0123)                       |
| codec        | 0.9278 +/-(-0.0072)                       |
| filter_      | 0.9264 +/-(-0.0063)                       |
| codec_filter | 0.8754 +/-(-0.0081)                       |
| c_level      | 0.4482 +/-(-0.0112) ~ 0.6937 +/-(-0.0065) |
| block        | 0.4264 +/-(-0.0109) ~ 0.7160 +/-(-0.0044) |
| cl_block     | 0.2621 +/-(-0.0074) ~ 0.7072 +/-(-0.0047) |


in [12]: clf1 = KNeighborsClassifier(n_neighbors=5, weights='distance')
mp.cross_val_report(clf1, cv, X, Y)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8051 +/-(-0.0047)                       |
| brier        | -1.4469 +/-(-0.0220)                      |
| normal       | 0.2766 +/-(-0.0091)                       |
| codec        | 0.9361 +/-(-0.0067)                       |
| filter_      | 0.9318 +/-(-0.0048)                       |
| codec_filter | 0.8843 +/-(-0.0087)                       |
| c_level      | 0.4658 +/-(-0.0104) ~ 0.7157 +/-(-0.0087) |
| block        | 0.4355 +/-(-0.0076) ~ 0.7286 +/-(-0.0047) |
| cl_block     | 0.2813 +/-(-0.0130) ~ 0.7221 +/-(-0.0070) |


in [13]: CUSTOM3_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSspeed',
               'Mean', 'Kurt', 'Skew', 'N_Streaks', 'Max', 'Min']
X = scale(df[CUSTOM3_IN].values)
clf1 = KNeighborsClassifier(n_neighbors=5, weights='distance')
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.7883 +/-(-0.0062)                       |
| brier        | 0.0000 +/-(-0.0000)                       |
| normal       | 0.2746 +/-(-0.0072)                       |
| codec        | 0.9299 +/-(-0.0061)                       |
| filter_      | 0.9016 +/-(-0.0083)                       |
| codec_filter | 0.8481 +/-(-0.0099)                       |
| c_level      | 0.4650 +/-(-0.0070) ~ 0.7147 +/-(-0.0079) |
| block        | 0.4355 +/-(-0.0088) ~ 0.7366 +/-(-0.0069) |
| cl_block     | 0.2944 +/-(-0.0082) ~ 0.7265 +/-(-0.0058) |


in [14]: CUSTOM2_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSspeed',
                  'Mean', 'Kurt', 'Skew', 'Max', 'Min']
X = scale(df[CUSTOM2_IN].values)
clf1 = KNeighborsClassifier(n_neighbors=5, weights='distance')
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.7559 +/-(-0.0095)                       |
| brier        | 0.0000 +/-(-0.0000)                       |
| normal       | 0.2416 +/-(-0.0057)                       |
| codec        | 0.9124 +/-(-0.0071)                       |
| filter_      | 0.8548 +/-(-0.0113)                       |
| codec_filter | 0.7964 +/-(-0.0083)                       |
| c_level      | 0.4396 +/-(-0.0084) ~ 0.6984 +/-(-0.0099) |
| block        | 0.4021 +/-(-0.0115) ~ 0.7172 +/-(-0.0061) |
| cl_block     | 0.2504 +/-(-0.0120) ~ 0.7114 +/-(-0.0057) |


in [15]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'BLZ_CSspeed']
X = scale(df[CUSTOM_IN].values)
clf1 = KNeighborsClassifier(n_neighbors=5, weights='distance')
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.7130 +/-(-0.0084)                       |
| brier        | 0.0000 +/-(-0.0000)                       |
| normal       | 0.2284 +/-(-0.0105)                       |
| codec        | 0.9041 +/-(-0.0095)                       |
| filter_      | 0.7874 +/-(-0.0139)                       |
| codec_filter | 0.7338 +/-(-0.0105)                       |
| c_level      | 0.4225 +/-(-0.0102) ~ 0.6900 +/-(-0.0064) |
| block        | 0.3741 +/-(-0.0073) ~ 0.7093 +/-(-0.0074) |
| cl_block     | 0.2491 +/-(-0.0111) ~ 0.6961 +/-(-0.0077) |


in [16]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'Mean', 'Max', 'Min']

```

```

In [17]: X = scale(df[CUSTOM_IN].values)
clf1 = KNeighborsClassifier(n_neighbors=5, weights='distance')
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.6961 +/- (0.0080)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.1877 +/- (0.0120)                       |
| codec        | 0.8461 +/- (0.0089)                       |
| filter_      | 0.8556 +/- (0.0090)                       |
| codec_filter | 0.7460 +/- (0.0077)                       |
| c_level      | 0.3667 +/- (0.0151) ~ 0.6509 +/- (0.0097) |
| block        | 0.3392 +/- (0.0097) ~ 0.6644 +/- (0.0164) |
| cl_block     | 0.1909 +/- (0.0129) ~ 0.6573 +/- (0.0134) |



In [17]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR']
X = scale(df[CUSTOM_IN].values)
clf1 = KNeighborsClassifier(n_neighbors=5, weights='distance')
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.4339 +/- (0.0245)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.0434 +/- (0.0207)                       |
| codec        | 0.6855 +/- (0.0699)                       |
| filter_      | 0.4243 +/- (0.0474)                       |
| codec_filter | 0.3110 +/- (0.0430)                       |
| c_level      | 0.1856 +/- (0.0513) ~ 0.5962 +/- (0.0413) |
| block        | 0.1601 +/- (0.0277) ~ 0.5657 +/- (0.0439) |
| cl_block     | 0.0789 +/- (0.0426) ~ 0.5704 +/- (0.0375) |



In [18]: CUSTOM3_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSspeed',
'Mean', 'Kurt', 'Skew', 'N_Streaks', 'Max', 'Min']
X = scale(df[CUSTOM3_IN].values)
clf1 = ChainedMultioutputClassifier(
    KNeighborsClassifier(n_neighbors=5, weights='distance'))
mp.cross_val_report(clf1, cv, X, Y, True)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8205 +/- (0.0058)                       |
| brier        | 0.0000 +/- (0.0000)                       |
| normal       | 0.3146 +/- (0.0088)                       |
| codec        | 0.9298 +/- (0.0082)                       |
| filter_      | 0.9036 +/- (0.0095)                       |
| codec_filter | 0.8549 +/- (0.0117)                       |
| c_level      | 0.5189 +/- (0.0079) ~ 0.7723 +/- (0.0103) |
| block        | 0.4898 +/- (0.0136) ~ 0.8039 +/- (0.0050) |
| cl_block     | 0.3318 +/- (0.0121) ~ 0.7887 +/- (0.0070) |


```

D.5. Cuaderno RFC_analysis.ipynb

Algoritmos Random Forest

```
In [1]: %matplotlib inline
%config InlineBackend.figure_format='retina'

%load_ext autoreload
%autoreload 2

%load_ext version_information
%version_information numpy, scipy, matplotlib, pandas, scikit-learn


| Software     | Version                                            |
|--------------|----------------------------------------------------|
| Python       | 3.5.3 64bit [GCC 4.4.7 20120313 (Red Hat 4.4.7-1)] |
| IPython      | 5.1.0                                              |
| OS           | Linux 4.9.16 gentoo x86_64 with debian stretch sid |
| numpy        | 1.12.1                                             |
| scipy        | 0.19.0                                             |
| matplotlib   | 2.0.0                                              |
| pandas       | 0.19.2                                             |
| scikit-learn | 0.18.1                                             |


Sat May 06 16:57:06 2017 UTC

In [2]: import os
import sys
sys.path.append("../src/")

from IPython.display import display
import pandas as pd
import matplotlib
import numpy as np
from matplotlib import pyplot as plt
from sklearn.externals import joblib
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import ShuffleSplit
from sklearn.model_selection import cross_val_score
from sklearn.multioutput import MultiOutputClassifier
from multioutput_chained import ChainedMultiOutputClassifier
import ml_plots as mp
import scoring_functions as sf
import warnings
warnings.filterwarnings('ignore')

pd.options.display.float_format = '{:.3f}'.format
matplotlib.rcParams.update({'font.size': 12})

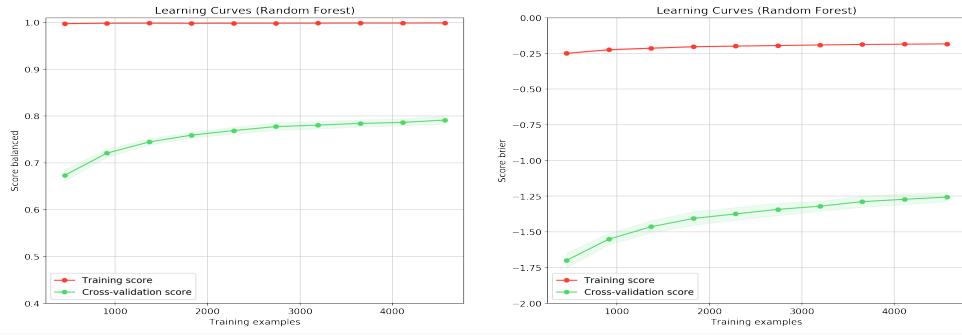
In [3]: SCORES = [(sf.balanced, 0.4, 1.01), (sf.brier, -2, 0)]
IN_OPTIONS = ['IN_CR', 'IN_CS', 'IN_DS', 'is_Table', 'is_Columnnar',
              'is_Int', 'is_Float', 'is_String', 'Type_Size', 'Chunk_Size',
              'Mean', 'Median', 'Sd', 'Skew', 'Kurt', 'Min', 'Max', 'Q1',
              'Q3', 'N_Streaks', 'BLZ_CRate', 'BLZ_CSspeed',
              'BLZ_DSpeed', 'LZ4_CRate', 'LZ4_CSspeed', 'LZ4_DSpeed']
OUT_CODEC = ['Blosclz', 'Lz4', 'Lz4hc', 'Zstd']
OUT_FILTER = ['Noshuffle', 'Shuffle', 'Bitshuffle']
OUT_LEVELS = ['CL1', 'CL2', 'CL3', 'CL4', 'CL5', 'CL6', 'CL7', 'CL8', 'CL9']
OUT_BLOCKS = ['Block_8', 'Block_16', 'Block_32', 'Block_64', 'Block_128',
              'Block_256', 'Block_512', 'Block_1024', 'Block_2048']
OUT_OPTIONS = OUT_CODEC + OUT_FILTER + OUT_LEVELS + OUT_BLOCKS

In [4]: df = pd.read_csv('../data/training_data.csv', sep='\t')
X, Y = df[IN_OPTIONS].values, df[OUT_OPTIONS].values

In [5]: rfc = RandomForestClassifier(n_estimators=50, n_jobs=-1)

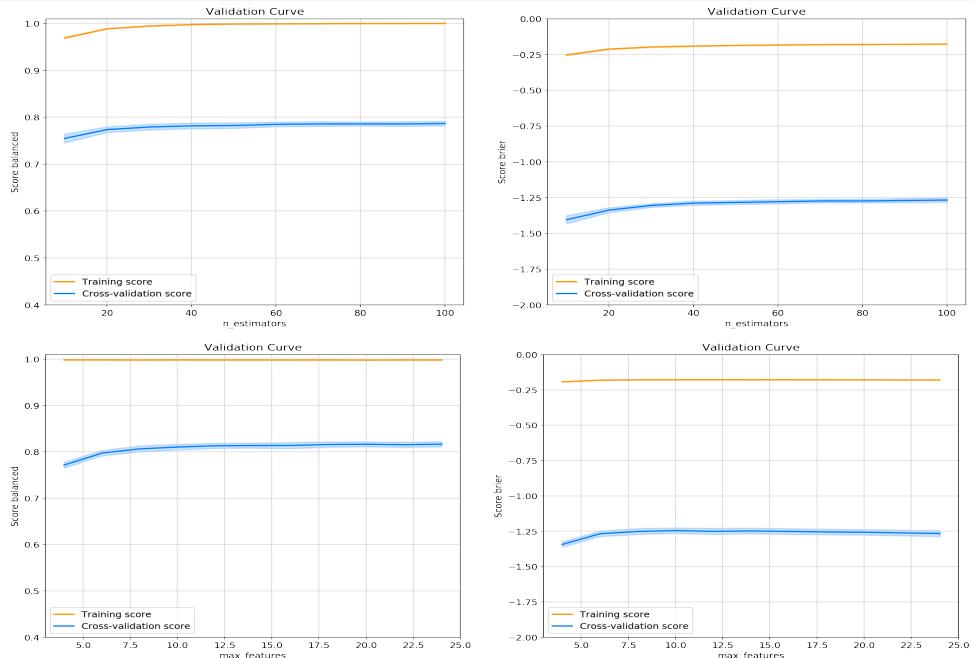
RFC - Curvas de aprendizaje

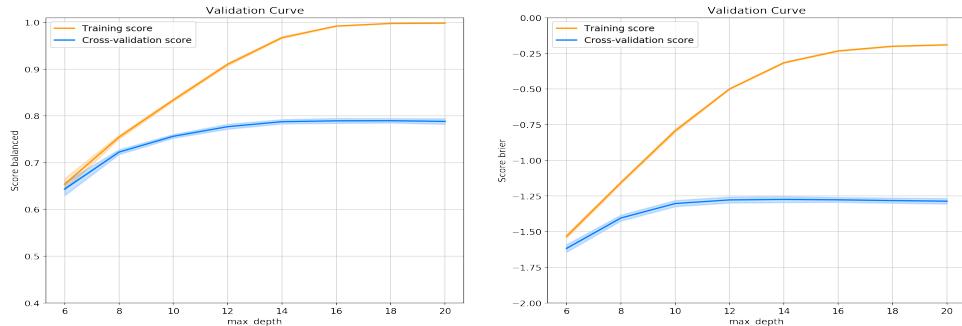
In [6]: title = "Learning Curves (Random Forest)"
cv = ShuffleSplit(n_splits=10, test_size=0.1)
fig = plt.figure(figsize=(20,8))
n = 121
for score in SCORES:
    mp.plot_learning_curve(
        fig.add_subplot(n), rfc, title, X, Y, scoring=score[0],
        ylim=(score[1], score[2]), cv=cv, n_jobs=-1,
        train_sizes=np.linspace(.1, 1.0, 10))
    n += 1
```



RFC - Curvas de validación

```
In [7]: PARAM_NAMES = ['n_estimators', 'max_features', 'max_depth']
PARAM_RANGES = [[10, 20, 30, 40, 50, 60, 70, 80, 90, 100],
                [4, 6, 8, 10, 12, 14, 16, 18, 20, 22, 24],
                [6, 8, 10, 12, 14, 16, 18, 20], 21]
cv = ShuffleSplit(n_splits=10, test_size=0.25)
for i in range(3):
    fig = plt.figure(figsize=(20, 8))
    n = 121
    for score in SCORES:
        mp.plot_validation_curve(
            fig.add_subplot(n), rfc, X, Y, param_name=PARAM_NAMES[i],
            param_range=PARAM_RANGES[i], cv=cv, scoring=score[0],
            ylim=(score[1], score[2]))
    n += 1
```





RFC - Validación cruzada de hiperparámetros

```
In [8]: nested_clf = joblib.load(
    './src/RFnested_estimators_my_accuracy_scorer.pkl')
non_nested_clf = joblib.load(
    './src/RFnon_nested_estimators_my_accuracy_scorer.pkl')
mp.print_nested_winners(nested_clf, non_nested_clf)

In [9]: Non Nested Winners
criterion --> Counter({'entropy': 20})
bootstrap --> Counter({False: 20})
class_weight --> Counter({None: 20})
Nested Winners
criterion --> Counter({'entropy': 191, 'gini': 9})
bootstrap --> Counter({False: 200})
class_weight --> Counter({None: 200})

In [10]: nested_clf = joblib.load(
    './src/RFnested_estimators_my_brier_scorer.pkl')
non_nested_clf = joblib.load(
    './src/RFnon_nested_estimators_my_brier_scorer.pkl')
mp.print_nested_winners(nested_clf, non_nested_clf)

Non Nested Winners
criterion --> Counter({'gini': 16, 'entropy': 4})
bootstrap --> Counter({True: 20})
class_weight --> Counter({None: 20})
Nested Winners
criterion --> Counter({'gini': 157, 'entropy': 43})
bootstrap --> Counter({True: 200})
class_weight --> Counter({None: 200})

In [11]: del nested_clf
del non_nested_clf
```

RFC - Resultados

```
In [12]: clf1 = RandomForestClassifier(
    n_estimators=20, max_features=10, max_depth=12, bootstrap=False,
    criterion='entropy')
clf2 = RandomForestClassifier(
    n_estimators=20, max_features=10, max_depth=12, bootstrap=True,
    criterion='gini')
clf3 = RandomForestClassifier(
    n_estimators=20, max_features=10, max_depth=12, bootstrap=True,
    criterion='entropy')
cv = ShuffleSplit(n_splits=10, test_size=0.25, random_state=1)

In [13]: print('Entropy')
mp.cross_val_report(clf1, cv, X, Y)
Entropy
Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8196 +/- (0.0072)                       |
| brier        | -1.2470 +/- (0.0435)                      |
| normal       | 0.2987 +/- (0.0140)                       |
| codec        | 0.9508 +/- (0.0041)                       |
| filter_      | 0.9503 +/- (0.0064)                       |
| codec_filter | 0.9131 +/- (0.0075)                       |
| c_level      | 0.4917 +/- (0.0176) ~ 0.7143 +/- (0.0151) |
| block        | 0.4611 +/- (0.0155) ~ 0.7395 +/- (0.0054) |
| cl_block     | 0.3029 +/- (0.0135) ~ 0.7277 +/- (0.0096) |



In [14]: print('Entropy bootstrap')
mp.cross_val_report(clf2, cv, X, Y)
Entropy bootstrap
Report


| Name     | Score               |
|----------|---------------------|
| balanced | 0.7997 +/- (0.0081) |


```

```

brier      -1.2344 +/-(-0.0333)
normal     0.2673 +/-(-0.0108)
codec      0.9485 +/-(-0.0041)
filter_    0.9458 +/-(-0.0066)
codec_filter 0.9076 +/-(-0.0077)
c_level    0.4593 +/-(-0.0211) ~ 0.6858 +/-(-0.0160)
block      0.4251 +/-(-0.0100) ~ 0.7022 +/-(-0.0085)
cl_block   0.2734 +/-(-0.0154) ~ 0.6956 +/-(-0.0105)

In [15]: print('Gini bootstrap')
mp.cross_val_report(clf3, cv, X, Y)
Gini bootstrap
Report



| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8062 +/-(-0.0067)                       |
| brier        | -1.2402 +/-(-0.032)                       |
| normal       | 0.2775 +/-(-0.0136)                       |
| codec        | 0.9490 +/-(-0.0056)                       |
| filter       | 0.9482 +/-(-0.0054)                       |
| codec_filter | 0.9104 +/-(-0.0077)                       |
| c_level      | 0.4638 +/-(-0.0182) ~ 0.6922 +/-(-0.0131) |
| block        | 0.4350 +/-(-0.0142) ~ 0.7132 +/-(-0.0096) |
| cl_block     | 0.2795 +/-(-0.0158) ~ 0.7012 +/-(-0.0096) |



In [16]: clf1.fit(X, Y)
RandomForestClassifier(bootstrap=False, class_weight=None,
                      criterion='entropy', max_depth=12, max_features=10,
                      max_leaf_nodes=None, min_impurity_split=1e-07,
                      min_samples_leaf=1, min_samples_split=2,
                      min_weight_fraction_leaf=0.0, n_estimators=20, n_jobs=1,
                      oob_score=False, random_state=None, verbose=0,
                      warm_start=False)

In [17]: my_dict = dict(zip(clf1.feature_importances_, IN_OPTIONS))
NEW_IN = []
for elem in np.sort(clf1.feature_importances_)[-1:]:
    print('%-12s --> %s' % (my_dict.get(elem), elem))
    if elem > 0.01:
        NEW_IN.append(my_dict.get(elem))

IN_CR      --> 0.148466477344
IN_CS      --> 0.130213557787
IN_DS      --> 0.10534829654
Sd         --> 0.0677787712108
BLZ_CRate  --> 0.0674005819952
LZ4_CRate  --> 0.0660674689345
LZ4_CSspeed --> 0.0400586743433
N_Streaks  --> 0.037901864108
BLZ_DSspeed --> 0.037901864124
BLZ_CSspeed --> 0.03680329565262
Mean       --> 0.0361343272803
Max        --> 0.0354673229451
Q3         --> 0.0345403385022
Kurt       --> 0.0315574961573
BLZ_DSspeed --> 0.0278866373071
Skew       --> 0.0234427007331
is_Int     --> 0.0120591547205
median     --> 0.0120591547204
Chkpt_Size --> 0.0106062301475
is_Float   --> 0.00897978537354
Q1         --> 0.0078805433221
Min        --> 0.00732846416934
is_String  --> 0.00450878531519
is_Table   --> 0.00285664487791
Type_Size  --> 0.00227379804071
is_Columnar--> 0.00122150874843

In [18]: X = df[NEW_IN].values

In [19]: clf1 = RandomForestClassifier(
            n_estimators=20, max_features=10, max_depth=12, bootstrap=False,
            criterion='entropy')
mp.cross_val_report(clf1, cv, X, Y)
Report



| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8237 +/-(-0.0080)                       |
| brier        | -1.2717 +/-(-0.0413)                      |
| normal       | 0.3052 +/-(-0.0136)                       |
| codec        | 0.9528 +/-(-0.0053)                       |
| filter       | 0.9491 +/-(-0.0067)                       |
| codec_filter | 0.9153 +/-(-0.0079)                       |
| c_level      | 0.4964 +/-(-0.0174) ~ 0.7207 +/-(-0.0147) |
| block        | 0.4631 +/-(-0.0161) ~ 0.7454 +/-(-0.0083) |
| cl_block     | 0.3075 +/-(-0.0160) ~ 0.7327 +/-(-0.0112) |



In [20]: clf1.fit(X, Y)
RandomForestClassifier(bootstrap=False, class_weight=None,
                      criterion='entropy', max_depth=12, max_features=10,
                      max_leaf_nodes=None, min_impurity_split=1e-07,
                      min_samples_leaf=1, min_samples_split=2,
                      min_weight_fraction_leaf=0.0, n_estimators=20, n_jobs=1,

```

```

        oob_score=False, random_state=None, verbose=0,
        warm_start=False)
In [21]: my_dict = dict(zip(clf1.feature_importances_, NEW_IN))
NEW_IN2 = []
for elem in np.sort(clf1.feature_importances_)[-1:]:
    print('%-12s --> %s' % (my_dict.get(elem), elem))
    if elem > 0.25:
        NEW_IN2.append(my_dict.get(elem))

IN_CR      --> 0.130644891879
IN_CS      --> 0.121037174859
IN_DS      --> 0.108231104076
Sd         --> 0.0975013899201
BLZ_CRATE --> 0.0934730929038
LZ4_CRATE  --> 0.0819683164911
N_Streaks  --> 0.0520481216005
LZ4_CSpeed --> 0.0494029069734
LZ4_DSspeed --> 0.0394371475015
BLZ_CSpeed --> 0.0373661339009
Max        --> 0.0359438571296
Mean       --> 0.0349147979797
Kurt       --> 0.03363731519158
BLZ_DSspeed --> 0.03013382732435
Q3         --> 0.0260208413754
Skew       --> 0.0241941140644
Median     --> 0.013533189131
is_Int     --> 0.0133624624045
Chunk_Size --> 0.00943554289396

In [22]: X = df[NEW_IN2].values
clf1 = RandomForestClassifier(
    n_estimators=20, max_features=10, max_depth=12, bootstrap=False,
    criterion='entropy')
mp.cross_val_report(clf1, cv, X, Y)

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8237 +/-(-0.0060)                       |
| brier        | -1.3075 +/-(-0.0511)                      |
| normal       | 0.3004 +/-(-0.0164)                       |
| codec        | 0.9526 +/-(-0.0059)                       |
| filter_      | 0.9440 +/-(-0.0058)                       |
| codec_filter | 0.9091 +/-(-0.0103)                       |
| c_level      | 0.5009 +/-(-0.0188) ~ 0.7256 +/-(-0.0115) |
| block        | 0.4634 +/-(-0.0139) ~ 0.7494 +/-(-0.0077) |
| cl_block     | 0.3083 +/-(-0.0152) ~ 0.7361 +/-(-0.0077) |



In [23]: clf1.fit(X, Y)
my_dict = dict(zip(clf1.feature_importances_, NEW_IN))
for elem in np.sort(clf1.feature_importances_)[-1:]:
    print('%-12s --> %s' % (my_dict.get(elem), elem))

IN_CR      --> 0.121871073429
IN_CS      --> 0.112380120629
Sd         --> 0.108231104076
LZ4_CRATE --> 0.0975013899201
IN_DS      --> 0.0970332074238
BLZ_CRATE --> 0.0949236989933
N_Streaks  --> 0.0597568902948
LZ4_CSpeed --> 0.0545806485144
Kurt       --> 0.051618042048
LZ4_DSspeed --> 0.0491060988069
BLZ_CSpeed --> 0.0438321764081
Mean       --> 0.03859970465782
BLZ_DSspeed --> 0.034441598845
Q3         --> 0.0318499061565

In [24]: CUSTOM3_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRATE', 'Sd', 'BLZ_CSpeed',
                  'Mean', 'Kurt', 'Skew', 'N_Streaks', 'Max', 'Min']
X = df[CUSTOM3_IN].values
clf1 = RandomForestClassifier(
    n_estimators=20, max_features=8, max_depth=12, bootstrap=False,
    criterion='entropy')
display(mp.cross_val_report(clf1, cv, X, Y))
clf1.fit(X, Y)
my_dict = dict(zip(clf1.feature_importances_, CUSTOM3_IN))
for elem in np.sort(clf1.feature_importances_)[-1:]:
    print('%-12s --> %s' % (my_dict.get(elem), elem))

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8240 +/-(-0.0055)                       |
| brier        | -1.3573 +/-(-0.0464)                      |
| normal       | 0.3038 +/-(-0.0118)                       |
| codec        | 0.9496 +/-(-0.0067)                       |
| filter_      | 0.9415 +/-(-0.0064)                       |
| codec_filter | 0.9061 +/-(-0.0075)                       |
| c_level      | 0.4999 +/-(-0.0172) ~ 0.7293 +/-(-0.0160) |
| block        | 0.4658 +/-(-0.0137) ~ 0.7531 +/-(-0.0073) |
| cl_block     | 0.3096 +/-(-0.0152) ~ 0.7418 +/-(-0.0091) |
| BLZ_CRATE    | --> 0.149275347548                        |
| IN_CR        | --> 0.137693395289                        |
| Sd           | --> 0.112265139683                        |
| IN_CS        | --> 0.112113780803                        |


```

```

IN_DS      --> 0.0964968848491
N_Streaks  --> 0.0891541754574
BLZ_CSspeed --> 0.0863057496674
Kurt       --> 0.0550968792025
Mean       --> 0.0542762784394
Max        --> 0.0494618342218
Skew        --> 0.0395579956027
Min        --> 0.0183028398374

In [28]: CUSTOM2_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSspeed',
               'Mean', 'Kurt', 'Skew', 'Max', 'Min']

x = df[CUSTOM2_IN].values
clf1 = RandomForestClassifier(
    n_estimators=20, max_features=8, max_depth=12, bootstrap=False,
    criterion='entropy')
display(mp.cross_val_report(clf1, cv, X, Y))
clf1.fit(X, Y)
my_dict = dict(zip(clf1.feature_importances_, CUSTOM2_IN))
for elem in np.sort(clf1.feature_importances_)[-1:]:
    print('%-12s --> %s' % (my_dict.get(elem), elem))

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.8165 +/- (0.0062)                       |
| brier        | -1.4211 +/- (0.0498)                      |
| normal       | 0.2998 +/- (0.0096)                       |
| codec        | 0.9417 +/- (0.0072)                       |
| filter_-     | 0.9380 +/- (0.0059)                       |
| codec_filter | 0.8966 +/- (0.0065)                       |
| c_level      | 0.4965 +/- (0.0193) ~ 0.7273 +/- (0.0118) |
| block        | 0.4638 +/- (0.0102) ~ 0.7527 +/- (0.0089) |
| cl_block     | 0.3045 +/- (0.0123) ~ 0.7402 +/- (0.0080) |
| BLZ_CRate    | --> 0.181184730064                        |
| Sd           | --> 0.135795449367                        |
| IN_CR        | --> 0.127324647265                        |
| IN_CS        | --> 0.108883495718                        |
| BLZ_CSspeed  | --> 0.102740443093                        |
| IN_DS        | --> 0.0853819248846                       |
| Kurt         | --> 0.055017891879                        |
| Mean         | --> 0.058504023312                        |
| Max          | --> 0.047419680212                        |
| Skew         | --> 0.021785207456                        |



In [28]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'BLZ_CSspeed']
x = df[CUSTOM_IN].values
clf1 = RandomForestClassifier(
    n_estimators=20, max_features=4, max_depth=12, bootstrap=False,
    criterion='entropy')
display(mp.cross_val_report(clf1, cv, X, Y))
clf1.fit(X, Y)
my_dict = dict(zip(clf1.feature_importances_, CUSTOM_IN))
for elem in np.sort(clf1.feature_importances_)[-1:]:
    print('%-12s --> %s' % (my_dict.get(elem), elem))

Report


| Name         | Score                                     |
|--------------|-------------------------------------------|
| balanced     | 0.7767 +/- (0.0087)                       |
| brier        | -1.6566 +/- (0.0500)                      |
| normal       | 0.2655 +/- (0.0073)                       |
| codec        | 0.9187 +/- (0.0112)                       |
| filter_-     | 0.8832 +/- (0.0091)                       |
| codec_filter | 0.8292 +/- (0.0116)                       |
| c_level      | 0.4586 +/- (0.0116) ~ 0.7117 +/- (0.0076) |
| block        | 0.4307 +/- (0.0116) ~ 0.7317 +/- (0.0094) |
| cl_block     | 0.2801 +/- (0.0118) ~ 0.7233 +/- (0.0078) |
| BLZ_CRate    | --> 0.414547820254                        |
| BLZ_CSspeed  | --> 0.29735766264                         |
| IN_CR        | --> 0.112420496888                        |
| IN_CS        | --> 0.111697815272                        |
| IN_DS        | --> 0.0815981013218                       |



In [27]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'LZ4_CRate', 'LZ4_CSspeed']
x = df[CUSTOM_IN].values
clf1 = RandomForestClassifier(
    n_estimators=20, max_features=4, max_depth=12, bootstrap=False,
    criterion='entropy')
display(mp.cross_val_report(clf1, cv, X, Y))
clf1.fit(X, Y)
my_dict = dict(zip(clf1.feature_importances_, CUSTOM_IN))
for elem in np.sort(clf1.feature_importances_)[-1:]:
    print('%-12s --> %s' % (my_dict.get(elem), elem))

Report


| Name     | Score                |
|----------|----------------------|
| balanced | 0.7802 +/- (0.0074)  |
| brier    | -1.6447 +/- (0.0473) |
| normal   | 0.2677 +/- (0.0114)  |
| codec    | 0.9304 +/- (0.0068)  |
| filter_- | 0.8758 +/- (0.0056)  |


```

```

codec_filter 0.8312 +/- (0.0094)
c_level 0.4711 +/- (0.0117) ~ 0.7221 +/- (0.0096)
block 0.4326 +/- (0.0130) ~ 0.7396 +/- (0.0079)
cl_block 0.2828 +/- (0.0144) ~ 0.7322 +/- (0.0061)

LZ4_CRate --> 0.3959243448978
LZ4_CSspeed --> 0.289277542278
IN_CR --> 0.120163085278
IN_CS --> 0.107634450453
IN_DS --> 0.087000573013

In [28]: CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'Mean', 'Max', 'Min']
X = df[CUSTOM_IN].values
clf1 = RandomForestClassifier(
    n_estimators=20, max_features=4, max_depth=12, bootstrap=False,
    criterion='entropy')
display(mp.cross_val_report(clf1, cv, X, Y))
clf1.fit(X, Y)
my_dict = dict(zip(clf1.feature_importances_, CUSTOM_IN))
for elem in np.sort(clf1.feature_importances_)[-1:]:
    print('%-12s --> %s' % (my_dict.get(elem), elem))

```

Report

Name	Score
balanced	0.7501 +/- (0.0061)
brier	-1.6290 +/- (0.0315)
normal	0.2177 +/- (0.0086)
codec	0.8852 +/- (0.0087)
filter_	0.9081 +/- (0.0080)
codec_filter	0.8119 +/- (0.0077)
c_level	0.4113 +/- (0.0144) ~ 0.6787 +/- (0.0137)
block	0.3848 +/- (0.0124) ~ 0.6891 +/- (0.0079)
cl_block	0.2257 +/- (0.0105) ~ 0.6836 +/- (0.0060)

Report

Name	Score
balanced	0.3846 +/- (0.0298)
brier	-2.3943 +/- (0.0201)
normal	0.0248 +/- (0.0250)
codec	0.7570 +/- (0.0097)
filter_	0.3281 +/- (0.0638)
codec_filter	0.2377 +/- (0.0570)
c_level	0.1178 +/- (0.0307) ~ 0.5633 +/- (0.0153)
block	0.1215 +/- (0.0100) ~ 0.4994 +/- (0.0098)
cl_block	0.0968 +/- (0.0103) ~ 0.5314 +/- (0.0108)

Report

Name	Score
balanced	0.409653469971
IN_CS	--> 0.398350906174
IN_DS	--> 0.191995623855

MultiOutputs

```

In [30]: CUSTOM3_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSspeed',
                  'Mean', 'Kurt', 'Skew', 'N_Streaks', 'Max', 'Min']
X = df[CUSTOM3_IN].values
clf1 = ChainedMultioutputClassifier(
    RandomForestClassifier(
        n_estimators=20, max_features=8, max_depth=12, bootstrap=False,
        criterion='entropy'))
display(mp.cross_val_report(clf1, cv, X, Y, True))

```

Report

Name	Score
balanced	0.8518 +/- (0.0047)
brier	0.0000 +/- (0.0000)
normal	0.3385 +/- (0.0091)
codec	0.9532 +/- (0.0047)
filter_	0.9504 +/- (0.0060)
codec_filter	0.9123 +/- (0.0076)
c_level	0.5563 +/- (0.0147) ~ 0.7867 +/- (0.0095)
block	0.5107 +/- (0.0059) ~ 0.8002 +/- (0.0072)
cl_block	0.3432 +/- (0.0111) ~ 0.7920 +/- (0.0053)

D.6. Cuaderno classifiers_comparison.ipynb

Comparativa de algoritmos clasificadores

```

In [1]: %matplotlib inline
%config InlineBackend.figure_format='retina'

%load_ext autoreload
%autoreload 2

%load_ext version_information
%version_information numpy, scipy, matplotlib, pandas, scikit-learn

Software          Version
Python            3.5.3 64bit [GCC 4.4.7 20120313 (Red Hat 4.4.7-1)]
IPython           5.1.0
OS                Linux 4.9.16 gentoo x86_64 with debian stretch sid
numpy             1.12.1
scipy              0.19.0
matplotlib        2.0.0
pandas             0.19.2
scikit-learn      0.18.1
Fri May 05 17:37:38 2017 UTC

In [2]: import os
import sys
sys.path.append("../src/")

import random
from IPython.display import display
import pandas as pd
import matplotlib
import numpy as np
from matplotlib import pyplot as plt
from sklearn.externals import joblib
from sklearn.ensemble import RandomForestClassifier
from sklearn.ensemble import ExtraTreesClassifier
from sklearn.svm import LinearSVC
from sklearn.svm import SVC
from sklearn.neighbors import KNeighborsClassifier
from sklearn.discriminant_analysis import LinearDiscriminantAnalysis
from sklearn.linear_model import LogisticRegression
from sklearn.model_selection import ShuffleSplit
from sklearn.model_selection import cross_val_score
from sklearn.multioutput import MultiOutputClassifier
from multioutput_chained import ChainedMultiOutputClassifier
from sklearn.preprocessing import StandardScaler
import ml_plots as mp
import scoring_functions as sf
import warnings
import time
warnings.filterwarnings('ignore')

pd.options.display.float_format = '{:.3f}'.format
matplotlib.rcParams.update({'font.size': 12})

In [3]: IN_OPTIONS = ['IN_CR', 'IN_CS', 'IN_DS', 'is_Table', 'is_Columnar',
                 'is_Int', 'is_Float', 'is_String', 'Type_Size', 'Chunk_Size',
                 'Mean', 'Median', 'Sd', 'Skew', 'Kurt', 'Min', 'Max', 'Q1',
                 'Q3', 'N_Streaks', 'BLZ_CRate', 'BLZ_CSpeed',
                 'BLZ_DSpeed', 'LZ4_CRate', 'LZ4_CSpeed', 'LZ4_DSpeed']
OUT_CODEC = ['Blosc1z', 'Lz4', 'Lz4hc', 'Zstd']
OUT_FILTER = ['Noshuffle', 'Shuffle', 'Bitshuffle']
OUT_LEVELS = ['CL1', 'CL2', 'CL3', 'CL4', 'CL5', 'CL6', 'CL7', 'CL8', 'CL9']
OUT_BLOCKS = ['Block_8', 'Block_16', 'Block_32', 'Block_64', 'Block_128',
              'Block_256', 'Block_512', 'Block_1024', 'Block_2048']
OUT_OPTIONS = OUT_CODEC + OUT_FILTER + OUT_LEVELS + OUT_BLOCKS
CUSTOM_IN = ['IN_CS', 'IN_DS', 'IN_CR', 'BLZ_CRate', 'Sd', 'BLZ_CSpeed',
             'Mean', 'Kurt', 'Skew', 'Max', 'Min', 'N_Streaks']
CHUNK_ID = ['Filename', 'DataSet', 'Table', 'Chunk_Number']

In [4]: df = pd.read_csv('../data/training_data.csv', sep='\t')
rfc = RandomForestClassifier(
    n_estimators=20, max_features=8, max_depth=12, bootstrap=False,
    criterion='entropy')
svc = MultiOutputClassifier(
    SVC(C=100, gamma=0.1, decision_function_shape='ovr'))
lsvc = MultiOutputClassifier(LinearSVC())
knc = KNeighborsClassifier(n_neighbors=5, weights='distance')
lda = MultiOutputClassifier(LogisticRegression(solver='newton-cg'))
lrc = MultiOutputClassifier(LogisticRegression(solver='newton-cg'))
names = ['RandomForest', 'SVM-rbf', 'SVM-linear', 'KNeighbors', 'LDA',
         'Logit']
classifiers = [rfc, svc, lsvc, knc, lda, lrc]

In [5]: rfc_ch = ChainedMultiOutputClassifier(
    RandomForestClassifier(
        n_estimators=20, max_features=8, max_depth=12, bootstrap=False,
        criterion='entropy'))
svc_ch = ChainedMultiOutputClassifier(
    SVC(C=100, gamma=0.1, decision_function_shape='ovr'))
lsvc_ch = ChainedMultiOutputClassifier(LinearSVC())

```

```

knc_ch = ChainedMultiOutputClassifier(
    KNeighborsClassifier(n_neighbors=5, weights='distance'))
lda_ch = ChainedMultiOutputClassifier(LinearDiscriminantAnalysis())
lrc_ch = ChainedMultiOutputClassifier(
    LogisticRegression(solver='newton-cg'))
classifiers_ch = [rfc_ch, svc_ch, lsvc_ch, knc_ch, lda_ch, lrc_ch]

In [6]:
def train_and_test(train_df, test_df, detailed=False):
    scaler = StandardScaler().fit(train_df[CUSTOM_IN].values)
    X_train, Y_train = (scaler.transform(train_df[CUSTOM_IN].values),
                        train_df[OUT_OPTIONS].values)
    X_test, Y_test = (scaler.transform(test_df[CUSTOM_IN].values),
                      test_df[OUT_OPTIONS].values)
    scores = []
    for i, clf in enumerate(classifiers):
        clf.fit(X_train, Y_train)
        if detailed:
            classifiers_ch[i].fit(X_train, Y_train)
            scores.append(sf.balanced(classifiers_ch[i], X_test, Y_test))
            scores.append(sf.balanced(clf, X_test, Y_test))
            scores.append(sf.codec(clf, X_test, Y_test))
            scores.append(sf.filter_(clf, X_test, Y_test))
            scores.append(sf.c_level_nice(clf, X_test, Y_test))
            scores.append(sf.block_nice(clf, X_test, Y_test))
        else:
            scores.append(sf.balanced(clf, X_test, Y_test))
    return scores

def autolabel(ax, rects):
    """
    Attach a text label above each bar displaying its height
    """
    for rect in rects:
        height = rect.get_height()
        ax.text(rect.get_x() + rect.get_width()/2., 1.01*height,
                '%.2f' % (height),
                ha='center', va='bottom')

def plot_clf_scores(title, x_labels, detailed=False):
    fig = plt.figure(figsize=(20, 8))
    width = 0.14
    if detailed:
        ind = np.arange(6)
    else:
        ind = np.arange(len(filenames))
    ax = fig.add_subplot(111)
    colors = ['#5AC8FA', '#FFCC00', '#FF9500', '#007AFF', '#4CD964',
              '#FF3B3D']
    if detailed:
        colors = ['#FF3B3D', '#4CD964', '#FFCC00', '#FF9500', '#5AC8FA',
                  '#007AFF']
    rects = []
    if detailed:
        for i in range(6):
            for j in range(6):
                rects.append(
                    ax.bar(ind + width * i,
                           [scores[i + j * 6] for j in range(len(names))],
                           width, color=colors[i]))
    else:
        for i, name in enumerate(names):
            rects.append(
                ax.bar(ind + width * i,
                       [e[i] for e in all_scores],
                       width, color=colors[i]))
    if detailed:
        ax.legend([rec[0] for rec in rects],
                  ['Chained_Balanced', 'Balanced', 'Codec', 'Filter', 'CL',
                   'Block'], loc='lower left', bbox_to_anchor=(1, 0.05))
    else:
        ax.legend([rec[0] for rec in rects], names, loc='lower left',
                  bbox_to_anchor=(1, 0.05))
    ax.set_ylabel('Scores')
    ax.set_title(title)
    ax.set_xticks(ind + width * 2.5)
    ax.set_xticklabels(x_labels)
    for rec in rects:
        autolabel(ax, rec)

```

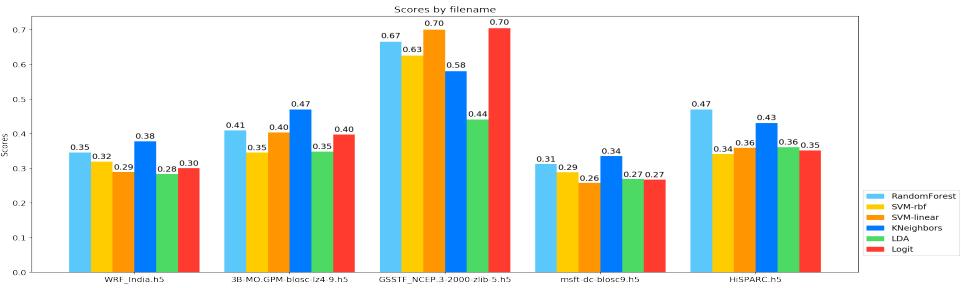
Puntuaciones CV-Fichero

```

In [7]: all_scores = []
filenames = []
for filename in df.drop_duplicates(subset=['Filename'])['Filename']:
    filenames.append(filename)
    test_df = df[df.Filename == filename]
    train_df = df[df.Filename != filename]
    all_scores.append(train_and_test(train_df, test_df))

In [8]: plot_clf_scores('Scores by filename', filenames)

```

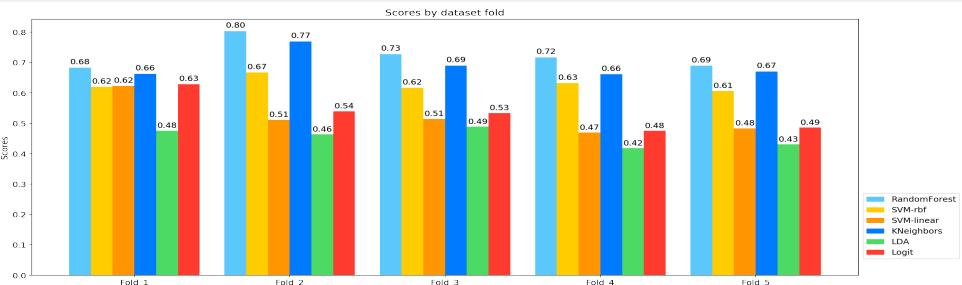


Puntuaciones CV-DataSets

```
In [9]: dataset_rows = []
set_id = ['filename', 'DataSet', 'Table']
for index, row in df.drop_duplicates().iterrows():
    subset=[('filename', 'DataSet', 'Table')][set_id].iterrows():
        dataset_rows.append(row)
N = len(dataset_rows)
split_size = N // 5
total = list(range(N))
current = total
test_indices = []
for i in range(5):
    test = random.sample(current, N // 5)
    test_indices.append(test)
    current = [x for x in current if x not in test]

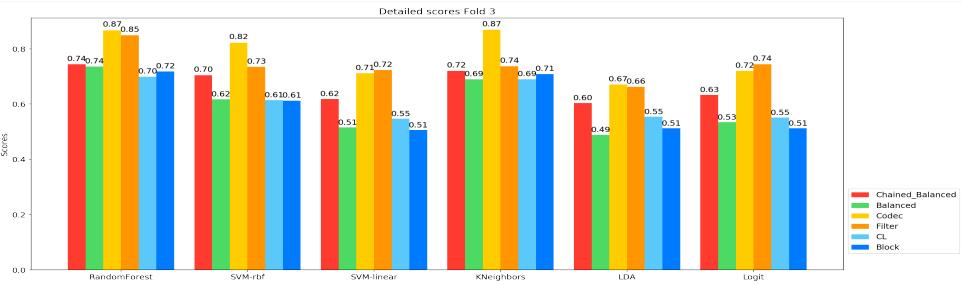
all_scores = []
for i in range(5):
    train_i = [x for x in total if x not in test_indices[i]]
    train_df = pd.DataFrame()
    test_df = pd.DataFrame()
    for j in train_i:
        train_df = train_df.append(
            df[(df.Filename == dataset_rows[j]['filename']) &
                (df.DataSet == dataset_rows[j]['DataSet']) &
                (df.Table == dataset_rows[j]['Table'])])
    for k in test_indices[i]:
        test_df = test_df.append(
            df[(df.Filename == dataset_rows[k]['filename']) &
                (df.DataSet == dataset_rows[k]['DataSet']) &
                (df.Table == dataset_rows[k]['Table'])])
    all_scores.append(train_and_test(train_df, test_df))

In [10]: plot_clf_scores('Scores by dataset fold', ('Fold_1', 'Fold_2', 'Fold_3',
                                             'Fold_4', 'Fold_5'))
```



```
In [11]: train_i = [x for x in total if x not in test_indices[2]]
train_df = pd.DataFrame()
test_df = pd.DataFrame()
for j in train_i:
    train_df = train_df.append(
        df[(df.Filename == dataset_rows[j]['filename']) &
            (df.DataSet == dataset_rows[j]['DataSet']) &
            (df.Table == dataset_rows[j]['Table'])])
for k in test_indices[2]:
    test_df = test_df.append(
        df[(df.Filename == dataset_rows[k]['filename']) &
            (df.DataSet == dataset_rows[k]['DataSet']) &
            (df.Table == dataset_rows[k]['Table'])])
scores = train_and_test(train_df, test_df, True)

In [12]: plot_clf_scores('Detailed scores Fold 3', names, detailed=True)
```

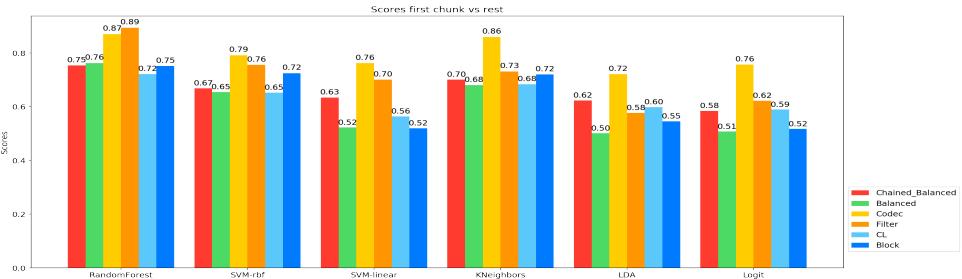


Puntuaciones CV-Chunk

Primer chunk vs el resto

```
In [13]: dataset_rows = []
for index, row in df[df.Chunk_Number == 2].drop_duplicates(
    subset=['Filename', 'DataSet', 'Table']).set_id().iterrows():
    dataset_rows.append(row)

all_scores = []
train_df = pd.DataFrame()
test_df = pd.DataFrame()
for j in range(len(dataset_rows)):
    train_df = train_df.append(
        df[(df.Filename == dataset_rows[j]['Filename']) &
           (df.DataSet == dataset_rows[j]['DataSet']) &
           (df.Table == dataset_rows[j]['Table']) &
           (df.Chunk_Number == 1)])
    test_df = test_df.append(
        df[(df.Filename == dataset_rows[j]['Filename']) &
           (df.DataSet == dataset_rows[j]['DataSet']) &
           (df.Table == dataset_rows[j]['Table']) &
           (df.Chunk_Number != 1)])
scores = train_and_test(train_df, test_df, True)
In [14]: plot_clf_scores('Scores first chunk vs rest', names, detailed=True)
print('%s train --- %s test' % (train_df.shape[0], test_df.shape[0]))
280 train --- 4256 test
```



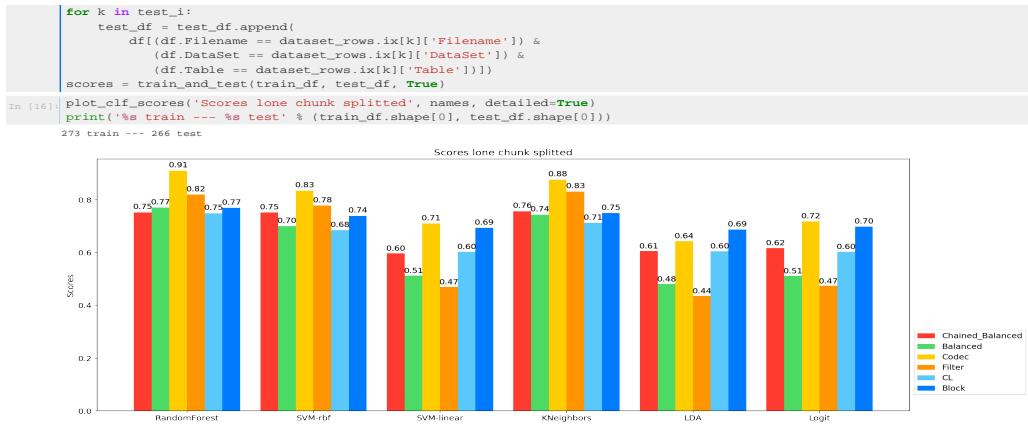
Chunks únicos mitad vs mitad

```
In [15]: sets = []
for index, row in df[df.Chunk_Number == 2].drop_duplicates(
    subset=['Filename', 'DataSet', 'Table']).set_id().iterrows():
    sets.append(row['DataSet'])

dataset_rows = df.drop_duplicates(
    subset=['Filename', 'DataSet', 'Table'])[-df.DataSet.isin(sets)]
dataset_rows = dataset_rows.reset_index(drop=True)

N = dataset_rows.shape[0]
total = list(range(N))
test_i = random.sample(total, N // 2)
train_i = [x for x in total if x not in test_i]

train_df = pd.DataFrame()
test_df = pd.DataFrame()
for j in train_i:
    train_df = train_df.append(
        df[(df.Filename == dataset_rows.ix[j]['Filename']) &
           (df.DataSet == dataset_rows.ix[j]['DataSet']) &
           (df.Table == dataset_rows.ix[j]['Table'])])
```



Velocidades



