

Tipo de artículo: Artículo original
Temática: Inteligencia artificial, Bioinformática
Recibido: 01/09/2020 | Aceptado: 20/11/2020

Integración de rasgos y aprendizaje semi-supervisado para la clasificación funcional de enzimas utilizando K-medias de Spark

Feature integration and semi-supervised learning for functional enzyme classification by using Spark K-means

Yadelis González Valle ^{1*} <https://orcid.org/0000-0002-8700-3823>

Deborah Galpert ^{1,2} <https://orcid.org/0000-0002-5222-3324>

Reinaldo Molina-Ruiz ³ <https://orcid.org/0000-0001-5098-5432>

Guillermin Aguero-Chapin ⁴ <https://orcid.org/0000-0002-9908-2418>

¹ Centro de Investigaciones Informáticas. Universidad Central “Marta Abreu” de Las Villas (UCLV), Santa Clara, 54830, Cuba. Correo electrónico. yadelisgv@gmail.com

² Departamento de Ciencia de la Computación. Universidad Central “Marta Abreu” de Las Villas (UCLV), Santa Clara, 54830, Cuba. deborah@uclv.edu.cu

³ Centro de Bioactivos Químicos (CBQ), Universidad Central “Marta Abreu” de Las Villas (UCLV), Santa Clara, 54830, Cuba. reymolina@uclv.edu.cu

⁴ CIIMAR | Interdisciplinary Centre of Marine and Environmental Research of the University of Porto, Porto, 4450-208, Portugal. gchapin@ciimar.up.pt

*Autor para la correspondencia. (yadelisgv@gmail.com)

RESUMEN

La clasificación funcional de las enzimas constituye un campo de gran interés para la bioinformática desde hace varios años. Dicha clasificación debe tener en cuenta la escasa información de algunas clases, el desbalance entre ellas y el número creciente de enzimas a clasificar. En este artículo investigamos el uso de algoritmos de agrupamiento semi-supervisados y no supervisados para agrupar secuencias similares de enzimas, a partir de la integración de descriptores de proteínas libres de alineamiento basados en el método de *k-mers* con diferentes valores de *k*. Se implementaron en Spark cuatro algoritmos que agrupan las enzimas de acuerdo a su función enzimática. Estos están basados en transformaciones a métodos existentes como el Combinatorio Lógico Global, el K-medias y el Ensamblado de Agrupamientos. La calidad del agrupamiento se midió usando como medida interna el índice de silueta y como medida externa la medida-F. En la experimentación, se tomaron como referencia 58 secuencias funcionalmente caracterizadas de 501 enzimas de la familia Glicosil Hidrolasa-70 (GH-70) (con un alto valor para la biotecnología y que a su vez pueden ocasionar pérdidas millonarias en la producción de azúcar) de la base de datos CAZy, con el objetivo de comparar los resultados de los métodos de agrupamiento implementados. Se obtuvieron valores moderados del índice de silueta como medida interna pero mejor que los obtenidos con el método K-medias. Se alcanzó el mejor valor de 0.9 de la medida-F del método del Ensamblado de Agrupamientos combinado con el aprendizaje semi-supervisado.

Palabras clave: Agrupamiento de enzimas; aprendizaje semi-supervisado; aprendizaje no supervisado; centroides K-medias.

ABSTRACT

The functional classification of enzymes has been a field of great interest for bioinformatics for several years. This classification must take into account the scarce information of some classes, the imbalance between them and the increasing number of enzymes to be classified. In this article we investigate the use of semi-supervised and unsupervised clustering algorithms to group similar enzyme sequences, from the integration of alignment-free protein descriptors based on the *k-mers* method with different *k* values. Four algorithms were

implemented in Spark that group enzymes according to their enzymatic function. These are based on transformations to existing methods such as the Global Logic Combinatorial, the K-means and the Ensemble Clustering. The quality of the clustering was measured using the silhouette index as an internal measure and the F-measure as an external measure. In the experiment, 58 functionally characterized sequences of 501 enzymes of the Glicosil Hidrolasa-70 (GH-70) family (with a high value for biotechnology and that can cause millionaire losses in sugar production) from the CAZy database were taken as reference, with the objective of comparing the results of the implemented grouping methods. There were obtained moderate values of the silhouette index as an internal measure but better than those obtained with the K-means method. The best value of 0.9 of the F-measure of the Ensemble Clustering method combined with semi-supervised learning was achieved.

Keywords: Enzyme clustering; K-mean centroids; unsupervised learning; semi-supervised learning.

Introducción

Las enzimas son macromoléculas biológicas que actúan como catalizadores específicos durante los procesos biológicos, siendo el reconocimiento de su función mediante métodos computacionales robustos un problema abierto en Bioinformática. Una de las principales direcciones trazadas en este sentido está relacionada con considerar el número creciente de enzimas que tienen función validada experimentalmente. El desarrollo de métodos de aprendizaje con manejo de datos desbalanceados y con muestras pequeñas constituye una fuente potencial para la solución del problema (Li et al., 2018). Además, se hace necesario el uso de métodos de aprendizaje para manejar datos masivos cuando se requiere realizar búsquedas de secuencias desconocidas a gran escala, aspecto no considerado en los servidores disponibles y los artículos de referencia consultados (Shen & Chou, 2007).

Un interés considerable de la comunidad científica se expresa en el sitio (<http://www.cazy.org/>) (Lombard et al., 2014) sobre la clasificación funcional de las enzimas cuyo trabajo es modificar y descomponer los

carbohidratos [GHs (hidrolasas de glucósidos) y lyases] y aquellas involucradas en su biosíntesis, GTs (glicosiltransferasas). Típicamente, estas enzimas componen aprox. 1-2% del genoma de cualquier organismo. En el propio sitio, así como en su publicación insigne de referencia (Davies & Sinnott, 2008) se plantea que es necesario mejorar la forma de clasificar dichas enzimas y sus secuencias ya que se presentan incongruencias con las clasificaciones actuales de la Asociación Internacional de Unión de Bioquímica y Biología Molecular con los Números de la Comisión de Enzimas (CE). Se plantea que dichas clasificaciones ni tienen suficiente alcance para reflejar todos los GH, ni reflejan las especificidades estructurales y características mecánicas. Además, los números de la CE no pueden hacer frente a la amplia gama de especificidades. La presencia de divergencia en la evolución de un antepasado común a adquirir nuevas especificidades, y las convergencias en la evolución hacia una enzima similar significa que con frecuencia no hay correlación entre el número de la CE de una clase de enzima y las secuencias de las enzimas que realizan estas reacciones, además muchas de las enzimas no tiene número asociado. A su vez, en la propia referencia, se presenta como un gran desafío, el de clasificar un número creciente de enzimas provenientes de la secuenciación de genomas completos sin afectar el desempeño de esta clasificación. De lo anterior se deduce la necesidad de contribuir a la clasificación funcional de enzimas con nuevos métodos escalables basados en el aprendizaje automatizado capaces de manejar el desbalance en la multi-clasificación y las pocas secuencias clasificadas en las clases. En nuestro país, existe un interés marcado en la clasificación de secuencias de enzimas correspondientes a la familia Glicosil Hidrolasa-70 (GH-70) que están siendo estudiadas desde hace varios años por el Instituto Cubano de Investigaciones de los Derivados de la Caña de Azúcar (ICIDCA) (Fraga Vidal et al., 2011) por la utilidad biotecnológica de las mismas y por el efecto nocivo que pueden llegar a causar en la producción de azúcar, provocando pérdidas millonarias para la economía del país. Es por esto que estas enzimas GH-70 se han tomado en este trabajo como muestra para la validación de nuevos métodos de clasificación funcional en el nivel de subclase CE 3.

Como una tendencia en la clasificación de secuencias de proteínas o enzimas (AK Ong et al., 2007), principalmente en aquellas familias que contienen secuencias homólogas de baja similitud, como secuencias divergentes que pueden realizar una función similar, también conocidas como homólogos remotos, se presenta el uso y la integración de diversos descriptores libres de alineamiento de proteínas o enzimas como los *k-mers* (Davies & Sinnott, 2008; Meng et al., 2016). Específicamente, la integración de descriptores ha permitido

elevar la calidad de la clasificación de ortólogos (secuencias homólogas con un ancestro común, generalmente, con función similar en especies diferentes) en trabajos realizados en el Centro de Investigaciones de Informática de la Universidad Central “Marta Abreu” de Las Villas (UCLV) (Galpert, 2016). A propósito, los descriptores de *k-mers* representan las secuencias como vectores con múltiples componentes asociadas a diferentes propiedades estructurales, y si son integrados con valores de *k* del 2 al 3 y del 2 al 4, constituyen vectores de alta dimensionalidad que han tenido que ser manejados de manera escalable mediante de técnicas de análisis de datos masivos como las disponibles en Apache Spark ^a.

Tomando estos antecedentes y partiendo de la consideración de que la similitud estructural define la similitud funcional, así como que pocas secuencias reportadas dentro de las familias enzimas han sido caracterizadas en cuanto a su actividad enzimática (por ejemplo, 58 de 501 dentro las GH-70), en este trabajo se pretende contribuir al desarrollo de métodos escalables de clasificación funcional de enzimas integrando descriptores libres de alineamiento, en específico, *k-mers*, con el aprendizaje semi-supervisado para conformar grupos de secuencias con patrones estructurales similares aprovechando el conocimiento previo de secuencias caracterizadas funcionalmente. De este modo el texto que sigue se ha dividido en dos partes: la **Metodología Computacional** donde se abordan las técnicas, instrumentos y métodos empleados para la recolección de los datos y los **Resultados y Discusión** donde se presentan y analizan los resultados del estudio y las proyecciones futuras.

Métodos o Metodología Computacional

Este trabajo intenta explorar el uso técnicas bioinformáticas disponibles para caracterizar funcionalmente las enzimas, como los descriptores libres de alineamiento basados en *k-mers*, por lo que el concepto y cálculo de los mismos queda explicado en la subsección **Descriptores libres de alineamiento**. Algunas de herramientas disponibles en el campo del aprendizaje automatizado para agrupar y clasificar las mismas como el aprendizaje no supervisado y semi-supervisado serán tratadas en la subsección **Aprendizaje no supervisado y semi-supervisado**. En la subsección **Nuevos algoritmos de clasificación de enzimas** se detallan las transformaciones realizadas a los algoritmos previamente referenciados. Seguidamente, algunos índices que

permiten validar los algoritmos fueron mencionados en la subsección **Medidas de validación internas y externas**. Por último, la subsección **Experimentación** aparece la descripción del experimento realizado.

Descriptores libres de alineamiento

Los descriptores libres de alineamiento son métodos de extracción de rasgos estructurales intrínsecos de las secuencias mediante funciones que transforman la secuencia en un vector numérico para posteriormente derivar la similitud de un par de secuencias al comparar dichos vectores numéricos. Estos métodos se conocen como libres de alineamiento y muestran múltiples aplicaciones (Vinga, 2014; Vinga & Almeida, 2003; Zielezinski et al., 2017, 2019). Ejemplo de métodos libres de alineamiento son los basados en frecuencia de palabras (Gunasinghe et al., 2014; Melsted & Pritchard, 2011) los cuales se basan en funciones llamadas descriptores moleculares de la forma:

$D: X \rightarrow \mathbb{R}^m$, donde una secuencia $x \in X$ de longitud n es convertida a un vector de longitud r . De esta forma, los métodos basados en k -tuplas, k -palabras o k -mers, con $k \leq n$, realizan una correspondencia de una secuencia con un vector (1) cuyas componentes $N_{k,i}$, $i = 1, \dots, c^k$ representan la frecuencia de subsecuencias de longitud k , siendo c^k el total de todos los posibles k -mers del alfabeto finito \mathcal{A} de c caracteres.

$$\pi_x^k = \left(\frac{N_{k,1}}{n - k + 1}, \frac{N_{k,2}}{n - k + 1}, \dots, \frac{N_{k,c^k}}{n - k + 1} \right) \quad (1)$$

Como se ha mencionado anteriormente, en este trabajo se ha calculado el descriptor de k -mers para $k = 2, 3$ y 4. La dimensión de cada vector es como máximo $m = 20^k$ por lo que integrar varios valores de k en la comparación de pares de secuencias conlleva a elevar la dimensionalidad del problema de clasificación y buscar la forma de manejar tal dimensionalidad. Al integrar los 2 a 3-mers se obtendría una dimensión de 8400 columnas o rasgos correspondientes a las subsecuencias de longitud dos y tres que se encuentran dentro de las secuencias que se están analizando. Mientras al integrar los 2-mers, 3-mers y 4-mers correspondientes

a las subsecuencias de longitud dos, tres y cuatro se obtendría una dimensión de 168400 columnas. En este trabajo se han combinado las facilidades de escalabilidad de Spark (Assefi et al., 2017) con la agregación de datos para lograr la integración de rasgos, aunque se pudieran explorar en trabajos futuros los métodos de reducción de la dimensionalidad o selección de rasgos relevantes, así como otras formas de representación de las secuencias (Li et al., 2018). Utilizando el enfoque de representación de *k-mers* la comparación de pares de vectores se realiza mediante medidas de similitud o disimilitud entre vectores. En (Galpert, 2016) son mencionadas variantes para calcular la disimilitud (o similitud) entre pares de vectores pero en este caso se ha seleccionado la correlación de Pearson (2) que es una métrica normalizada expresando similitud entre pares de vectores O_i y O_j .

$$\Gamma(O_i, O_j) = \frac{\sum_{k=1}^m (o_{ik} - \overline{atributo_k})(o_{jk} - \overline{atributo_k})}{\sqrt{\sum_{k=1}^m (o_{ik} - \overline{atributo_k})^2 \sum_{k=1}^m (o_{jk} - \overline{atributo_k})^2}} \quad (2)$$

donde $\overline{atributo_k}$ es el valor promedio que toma el $atributo_k$ en el conjunto de datos.

Los vectores representativos de las secuencias conforman un conjunto de datos denominado *Kmers-k* de vectores de valores reales de ocurrencia de subsecuencias de longitud k para cada secuencia de enzima. Se propone concatenar vectores para valores de k diferentes y luego aplicar correlación al vector resultante. Como primera combinación se propone integrar en un mismo conjunto de datos los *Kmers-2* y *Kmers-3* y como segunda combinación, la integración de los *Kmers-2*, *Kmers-3* y *Kmers-4* en otro conjunto.

Aprendizaje no supervisado y semi-supervisado

La agrupación en clústeres es uno de los problemas de análisis de datos más conocidos y estudiados. Constituye un área de investigación clave en el campo del aprendizaje, donde no hay supervisión sobre cómo se debe manejar la información. Podemos definir el agrupamiento particional como la tarea de agrupar los

objetos de un conjunto de datos en k grupos, de modo que se pueda extraer nueva información de ellos. Un conjunto de datos X se compone de n objetos, y cada objeto se describe por u rasgos. Más formalmente, $X = \{X_1, \dots, X_n\}$ con el i -ésimo objeto definido como $X_i = \{X_{[i,1]}, \dots, X_{[i,u]}\}$. Un algoritmo de agrupamiento típico asigna una etiqueta de clase l_i a cada objeto $x_i \in X$. Como resultado, obtenemos el conjunto de etiquetas $L = \{l_1, \dots, l_n\}$ con $l_i \in \{1, \dots, k\}$, que efectivamente divide X en k grupos no superpuestos c_i que forman la partición. El criterio utilizado para asignar un objeto a un grupo dado es la similitud con el resto de los objetos en ese grupo, y la disimilitud con el resto de los objetos del conjunto de datos, y se puede obtener con algún tipo de medición de distancia (Anil Kumar Jain et al., 1999). Se desea que los objetos que pertenezcan al mismo grupo sean tan similares como se pueda y los objetos que pertenezcan a grupos diferentes sean tan diferentes como sea posible (Höppner et al., 1999; Kruse et al., 2007).

En cambio, el aprendizaje semi-supervisado es un paradigma de aprendizaje automatizado que surge de agregar información incompleta al aprendizaje no supervisado (Chapelle et al., 2006). Siguiendo este paradigma podemos incorporar información de fondo al proceso de agrupamiento, lo que resulta en un agrupamiento restringido, que es el tema principal del estudio presentado en (Triguero et al., 2015). El objetivo del agrupamiento restringido es encontrar una partición del conjunto de datos que cumpla con las características adecuadas del resultado de un método de agrupamiento, además de satisfacer un determinado conjunto de restricciones (González-Almagro et al., 2020). En otras palabras, el aprendizaje semi-supervisado es una rama del aprendizaje automatizado que resulta de combinar el aprendizaje supervisado y el no supervisado (Chapelle et al., 2006; Xiaojin Zhu, 2005). En el agrupamiento semi-supervisado, la información supervisada se puede tomar de diferentes formas, por ejemplo, pueden aplicarse restricciones must-link (se sabe que dos objetos están en el mismo grupo) y cannot-link (dos objetos se sabe que están en diferentes grupos) (Lange et al., 2005). También es posible que algunas asignaciones de grupos se conozcan de antemano. Un ejemplo para la incorporación de este último tipo de información es el uso de datos etiquetados para la “siembra en racimo”, como en (Basu et al., 2002), donde propusieron inicializar los grupos basados en los objetos para los que se conocen asignaciones de grupo.

En el problema de clasificación de las enzimas, al considerar la clasificación previa de algunas secuencias en la descripción detallada de la función enzimática expresada a través de la etiqueta CE resulta conveniente utilizar el aprendizaje semi-supervisado al ser pocas las secuencias etiquetadas. Como se había mencionado en la Introducción, en la experimentación de este trabajo se utiliza el conjunto de datos de enzimas GH-70 donde existen seis grupos de actividad enzimática los cuales serán inicializados con las 58 enzimas clasificadas, de 501 disponibles, en el sitio web [CAZy.org/GH70_characterized^b](http://CAZy.org/GH70_characterized), antes de comenzar el proceso de agrupamiento. La información de etiquetado previo también se utiliza en la etapa de validación mediante el uso de índices o medidas de validación externa que pueden ser combinados con índices de validación interna (Halkidi et al., 2002; Koutroumbas & Theodoridis, 2008) indicando en qué grado el agrupamiento es correcto o no (Höppner et al., 1999).

Para el agrupamiento semi-supervisado que se propone, primero es necesario profundizar en los siguientes tres algoritmos:

1. El algoritmo Combinatorio Lógico Global (Global Logical Combinatorial, GLC+) en (Ruiz-Shulcloper, s. f.; Ruiz-Shulcloper & Sánchez-Díaz, 2001). Este es un método de agrupamiento incremental que construye componentes conexas a partir de descripciones mezcladas e incompletas de objetos representadas en espacios no necesariamente métricos. Este método puede ser aplicado a muy grandes volúmenes de datos y por su naturaleza incremental permite inicializar los grupos con las secuencias etiquetadas e ir incrementando los mismos según las comparaciones de similitud entre la secuencia a analizar en cada paso y el resto de las secuencias por lo que puede ser transformado a agrupamiento semi-supervisado.
2. El algoritmo de agrupamiento no supervisado K-medias realiza la construcción de particiones (grupos) del conjunto de datos sobre la base del perfeccionamiento de algún índice, conocido también como función objetivo. En esencia, divide n objetos en un número positivo k de grupos, generalmente especificado a priori. El objetivo de este tipo de métodos es encontrar la mejor división de los datos en k grupos basada en una medida de similitud dada y conservar el espacio de particiones posibles en k subconjuntos solamente. La mayoría de los algoritmos que siguen esta técnica son esencialmente

basados en prototipos, comienzan con una partición inicial, usualmente aleatoria, y proceden con su refinamiento (Han & Kamber, 2001). Este algoritmo funciona mejor con grupos que tienen forma convexa y requiere que el número de grupos a obtener se especifique a priori, por tanto requiere un cierto conocimiento del dominio, ya que es sensible a cómo se realizó inicialmente la partición. El algoritmo K-medias tiene una complejidad temporal $O(Ikn)$, donde I se utiliza para indicar número de iteraciones, n el número de objetos y k el número de grupos. (Xiong et al., 2006), El K-medias también puede ser utilizado seleccionando previamente los centroides de los grupos como aparece en (Arai & Barakbah, 2007; Khan & Ahmad, 2004).. El algoritmo K-medias ofrece mejores resultados solo cuando las particiones iniciales están cerca de la solución final. (Anil K. Jain & Dubes, 1988).

3. El Ensamblado de Agrupamientos (Ensemble Clustering, EC) utilizado en (Abdallah & Yousef, 2020). Este método de agrupamiento reemplaza el espacio de datos por un espacio categórico basado en agrupación de conjuntos. El nuevo espacio categórico se define mediante el seguimiento de la membresía de los objetos en múltiples ejecuciones de algoritmos de agrupamiento.

En la subsección siguiente se explicarán en detalles los cuatro algoritmos semi-supervisados propuestos que resultan de transformar y combinar los tres algoritmos anteriores.

Nuevos algoritmos de agrupamiento de enzimas

De los tres algoritmos mencionados en la **Subsección: Aprendizaje no supervisado y semi-supervisado** se diseñó y modificó el código del método GLC+ convirtiéndolo en semi-supervisado ya que en su forma original la cantidad de grupos que se pueden formar con el método GLC+ es indeterminada, pero al ser reformado se limitó esta cantidad a seis grupos posibles a formar, correspondientes a la actividad enzimática. Además, en el GLC+ original los grupos comienzan vacíos y se van incrementando objetos O_i , cada vez que encuentran un objeto O_j semejante que pertenezca al agrupamiento G_k que cumplan la condición expresada en (3) donde $\Gamma(O_i, O_j)$ representa la similitud entre los objetos O_i y O_j , y β_0 , el umbral de similitud.

$$\Gamma(O_i, O_j) \geq \beta_0 \quad (3)$$

En el caso del GLC+semi-supervisado se tienen los grupos inicialmente con algunas enzimas de las que se conoce su clasificación.

El pseudocódigo para este algoritmo de agrupamiento GLC+semi-supervisado aplicando como medida de similitud la expresada en (2) se muestra a continuación:

Entrada: Enzimas E, Arreglo de Vectores de los $Kmers_k$, Enzimas clasificadas $v:(c,n) \rightarrow V$; donde $c \in E$ es la enzima clasificada y n el grupo al que pertenece, β_0	
Salida: Nuevos clasificados $g:(e,n) \rightarrow G$; donde $e \in E$ es la enzima sin clasificar y n el grupo en el que será clasificada.	
Begin	
$Kmers_{integrado} = \bigcup_{k=2}^n Kmers_k$, con $n \in [3,4]$	P1
Forall $e \in E$ do	P2
<i>/* Verificar que la enzima no está entre las clasificadas */</i>	
Forall $(c, n) \in V$ if $(c \neq e)$ then	P3
$corr = corr_Pearson(Kmers_{integrado}(e), Kmers_{integrado}(c))$	P4
<i>/* Se guarda en maxCorr la mayor correlación encontrada */</i>	
If $(corr \geq \beta_0)$ then	P5
$maxCorr = \text{Max}(corr, maxCorr)$	P6
End	
End	
<i>/* Añadir a los nuevos clasificados el par (e, n) donde n ∈ [1,6] toma el número del grupo de la enzima clasificada c que tuvo la mayor correlación con e */</i>	
Añadir a G el par (e, n)	P7
End	
End	

Fig. 1 – Pseudocódigo del GLC+semi-supervisado.

En P1 se produce la concatenación de los vectores $Kmers_k$ resultando un $Kmers_{integrados}$ de 2 al 3-mers y de 2 al 4-mers para diferentes corridas del algoritmo. En P5 se verifica que el resultado de la correlación de Pearson entre los dos vectores cumpla con la expresión (3). El valor de β_0 se calcula a partir de la matriz de semejanza entre todas las m secuencias de enzimas utilizando la expresión **¡Error! No se encuentra el origen de la referencia.**, ver (Ruiz-Shulcloper, s. f.) para más detalles.

$$\beta_0 = \underset{i \neq j}{\text{Min}} \{ \underset{j=i+1 \dots m}{\text{Max}} \{ \Gamma(O_i, O_j) \} \} \quad (4)$$

En P6 se determina con cual enzima de las etiquetadas de los seis grupos tiene mayor valor de similitud y es en ese grupo donde encontró la más similar que en P7 se agrupa a la enzima que se está analizando.

Se proponen cuatro nuevos métodos de agrupamiento semi-supervisado:

El primero, **EC_GLC+semi-supervisado** es el resultado de combinar el Ensamblado de Agrupamientos y el GLC+semi-supervisado, este comienza preparando un nuevo conjunto de datos como resultado de aplicar el Ensamblado de Agrupamientos para luego agrupar usando el GLC+semi-supervisado que ya incorpora información de fondo al proceso y hace que se cumplan las restricciones que se explicaron previamente.

El segundo denominado **GLC+semi-supervisado_centroides_K-medias** parte de ejecutar el GLC+semi-supervisado, determinar los centroides de esos grupos generados que ya aprovecha la información de las enzimas etiquetadas y aplicar finalmente K-medias fijándole esos centroides antes de iniciar el agrupamiento no dejando que sea la selección de los centroides de manera aleatoria, característica intrínseca del agrupamiento no supervisado que realiza el K-medias.

El tercero denominado **EC_GLC+semi-supervisado_centroides_K-medias** parte del resultado obtenido por el primer método propuesto, determinar los centroides de esos grupos generados que ya aprovecha la información de las enzimas etiquetadas y aplicar finalmente K-medias fijándole esos centroides antes de iniciar el agrupamiento.

El cuarto y último método, que denominaremos **Centroides_aleatorios_de_enzimas_etiquetadas_K-medias** parte de seleccionar una de las mejores combinaciones de los centroides escogidos aleatoriamente del grupo de enzimas etiquetadas y luego aplica K-medias con esos centroides.

EC_GLC+semi-supervisado

El algoritmo de transformación *Ensemble Clustering* (EC) consiste en ejecutar un algoritmo de agrupamiento (o múltiples algoritmos) varias veces con diferentes valores de parámetros donde cada ejecución produce una dimensión categórica (característica o rasgo) de los datos. Por ejemplo, ejecutar el algoritmo K-medias con diferentes valores de $k = 1, \dots, N$, generará un nuevo vector de datos con dimensión N . En otras palabras, dos objetos en el espacio del EC son idénticos si fueron asignados a los mismos grupos en toda iteración ($k = 1, \dots, N$). Todos los objetos que caen en el mismo clúster en las diferentes ejecuciones del agrupamiento constituyen un solo grupo y están representados por un solo objeto. Esta última aseveración será transformada ya que el objetivo que se pretende alcanzar no es el de crear tantos grupos como sea posible sino solamente los grupos conocidos de acuerdo a la clasificación de enzimas es por ello que se decide combinarlo con el GLC+semi-supervisado que previamente fue transformado para cumplir esa condición. Lo anterior se logra comparando los nuevos vectores que se generaron con los vectores asociados de las enzimas clasificadas, y los que resulten con mayor correlación se pueden considerar como del grupo al que pertenece la enzima clasificada de referencia. El número N de iteraciones a realizar es un parámetro ajustable iterativamente hasta que se logre un valor adecuado del índice de silueta.

GLC+semi-supervisado_centroides_K-medias

En el segundo método propuesto el proceso comienza con la ejecución del GLC+semi-supervisado, luego determina los centroides de esos grupos generados con la librería MLlib de Spark la cual en la sección Estadísticas proporciona la media de un conjunto de vectores. De este modo se calculan nuevos vectores centroides por cada uno de los seis grupos de actividad enzimática y esta información se le suministra al K-medias implementado también en la misma librería de Spark para fijarle los centroides a partir de los cuales comienza el agrupamiento.

EC_GLC+semi-supervisado_centroides_K-medias

En el tercer método propuesto el proceso comienza con la ejecución del Ensamblado de Agrupamientos, a ese nuevo conjunto de datos se le aplica el GLC+semi-supervisado, luego se determina los centroides de esos grupos generados con la librería MLlib de Spark. De este modo se calculan nuevos vectores centroides por

cada uno de los seis grupos de actividad enzimática y esta información se le suministra al K-medias para fijarle los centroides, a partir de los cuales comienza el agrupamiento.

Centroides_aleatorios_de_enzimas_etiquetadas_K-medias

En el último método propuesto el proceso comienza al hacer combinaciones de seis enzimas escogidas aleatoriamente de los seis grupos de enzimas etiquetadas, se aplicó K-medias con esos centroides aleatorios, y se escogió aquella combinación que al calcularle el índice de silueta diera el mayor valor con relación al resto de las combinaciones.

Medidas de validación internas y externas

Las medidas internas se utilizan para medir la densidad y la cohesión entre pares de objetos de un mismo grupo. Se escogió como medida interna para validar los resultados de este trabajo el índice de silueta que es el promedio, sobre todos los grupos, del ancho de la silueta de sus puntos. Si x es un objeto en el clúster C_k y n_k es el número de objetos en C_k , entonces, el índice de silueta de x está definido por la relación expresada en (5):

$$S(x) = \frac{b(x) - a(x)}{\max[b(x), a(x)]} \quad (5)$$

Donde $a(x)$ en **¡Error! No se encuentra el origen de la referencia.** es el promedio de las distancias entre x y todos los otros objetos en C_k y $b(x)$ en **¡Error! No se encuentra el origen de la referencia.** es el mínimo de los promedios de las distancias $d(x, y)$ entre x y los objetos de los otros clústeres.

$$a(x) = \frac{1}{n_k - 1} \sum_{y \in C_k, y \neq x} d(x, y) \quad (6)$$

$$b(x) = \min_{h=1, \dots, K, h \neq k} \left[\frac{1}{n_h} \sum_{y \in C_h} d(x, y) \right] \quad (7)$$

Finalmente, el índice de silueta global **¡Error! No se encuentra el origen de la referencia.** está definido como sigue, siendo K el número de clústeres y n_k la cantidad de objetos en cada clúster:

$$S = \frac{1}{K} \sum_{k=1}^K \left[\frac{1}{n_k} \sum_{x \in C_k} S(x) \right] \quad (8)$$

Para un objeto x dado, el ancho de su silueta varía de -1 a 1. Si el valor está cerca de -1, significa que el objeto está más cerca, en promedio, de otro grupo que de aquél al que pertenece. Si el valor es cercano a 1, significa que la distancia promedio a su propio grupo es significativamente menor que a cualquier otro grupo. Valores altos del índice silueta global indican grupos más compactos y bien separados. El cálculo de este índice tiene una alta complejidad; sin embargo, investigaciones actuales lo utilizan para la validación del agrupamiento (Brun et al., 2007). En este trabajo se utilizó para guiar el agrupamiento en el Ensamblado de Agrupamientos (EC) ya que sirvió de indicador para determinar cuántas ejecuciones N del algoritmo de agrupamiento K -medias serían necesarias para lograr grupos más separados y compactos.

Por otra parte, las medidas externas se basan en las etiquetas conocidas. Algunas medidas externas utilizan las ideas de precisión (precision) y cubrimiento^c (recall) del campo de la recuperación de información y las adaptan a la validación del agrupamiento. La precisión (Pr) y el cubrimiento (Re) se calculan mediante las expresiones **¡Error! No se encuentra el origen de la referencia.** y **¡Error! No se encuentra el origen de la referencia.**, respectivamente, para un grupo j y una clase i dados, donde n_{ij} es el número de objetos de la clase i en el grupo j , n_j es el número de objetos del grupo j y n_i es el número de objetos de la clase i .

$$Pr(i, j) = \frac{n_{ij}}{n_j} \quad (9)$$

$$Re(i, j) = \frac{n_{ij}}{n_i} \quad (10)$$

La medida-F (*F-measure*) se obtiene calculando la media armónica de precisión y cubrimiento como se aprecia en **¡Error! No se encuentra el origen de la referencia..**

$$F - Measure(i, j) = \frac{1}{\alpha(1/Pr(i, j)) + (1 - \alpha)(1/Re(i, j))} \quad (11)$$

Si $\alpha = 1$ entonces $F - Measure(i, j)$ coincide con precisión, y si $\alpha = 0$ entonces $F - Measure(i, j)$ coincide con cubrimiento. En el caso que $\alpha = 0.5$ significa igual peso para precisión y cubrimiento (Baeza-Yates & Frakes, 1992). Un valor global, de la medida-F global (Overall F-measure; OFM), se calcula mediante el promedio de los valores por clase de la medida-F sobre todos los grupos (Steinbach et al., 2000). Esta medida-F intenta capturar cuánto los grupos del agrupamiento obtenido se hacen corresponder correctamente con los grupos de referencia o clases incluso cuando existe desbalance en la cantidad de objetos por clase (Rosell et al., 2004). En resumen, las medidas externas: precisión, cubrimiento y medida-F fueron utilizadas para medir la calidad de los agrupamientos obtenidos en este trabajo.

Experimentación

En el conjunto de datos utilizado en la experimentación se tienen 501 enzimas GH-70, de ellas 58 clasificadas pertenecientes a: 43 del primer grupo, dos del segundo grupo, dos del tercer grupo, cuatro del cuarto grupo, dos del quinto grupo y una del sexto grupo. De las 58 enzimas, la enzima “CDX66820.1” tiene doble clasificación lo que significa que tiene doble actividad enzimática, y no se utilizó entre las clasificadas para no introducir confusión durante el agrupamiento. Por otra parte, las enzimas: “P08987” y “P49331” no se encuentran entre las 501 secuencias de las enzimas para clasificar. De lo anterior se deriva que de las 58 clasificadas serán utilizadas 55 enzimas.

Con el objetivo de esclarecer el flujo de procesos seguido en el agrupamiento durante la experimentación, la (Fig. 2) muestra la entrada de secuencias al proceso de extracción de rasgos mediante los descriptores libres de alineamiento, en este caso, los *k-mers*, la integración de los mismos, la transformación de datos en el

Ensamblado de Agrupamientos, la secuencia a seguir en cada método propuesto y la ubicación final de las enzimas en los grupos de actividad enzimática reportados en CAZY.

Al realizar varias iteraciones con el Ensamblado de Agrupamientos, se encontró que para valores de k (número de grupos a formar con el algoritmo K-medias) entre 45 y 50 los valores del índice de silueta oscilaban entre 0.56 aproximadamente siendo éste el valor más alto en comparación a -0.0097 que es el valor más bajo encontrado, el cual indica demasiados o muy pocos elementos similares en el grupo. Por esta razón, se escogió N igual 50 como el número de ejecuciones a realizar. Para proceder a aplicar el *Ensemble Clustering* se realizaron corridas del K-medias para k desde 2 hasta 50, para los *Kmers_{integrados}* de 2 al 3-*mers* y de 2 al 4-*mers*. Cada corrida se guardó en un archivo de tipo CSV, los cuales fueron integrados en un archivo por cada *Kmers_{integrados}*.

Los resultados obtenidos por los cuatro métodos con las distintas medidas de validación se exponen en la sección de **Resultados y Discusión**.

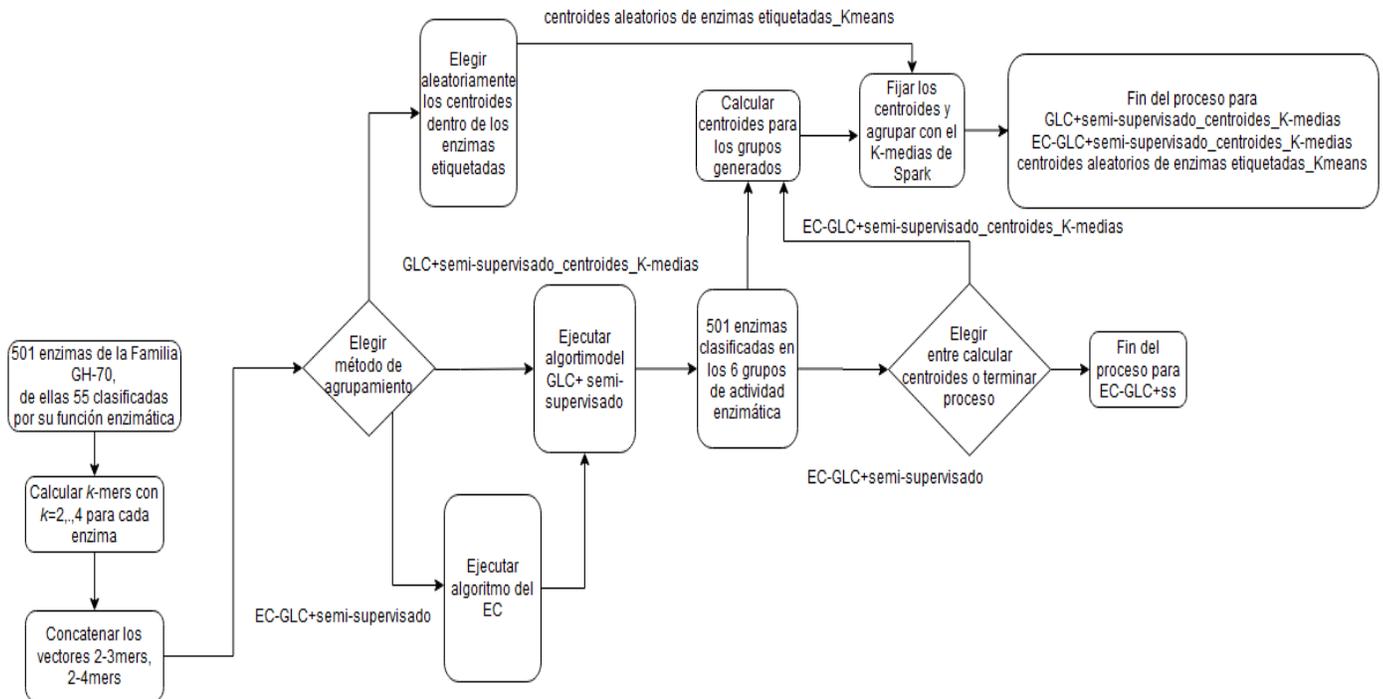


Fig. 2 – Flujo de procesos del agrupamiento de enzimas.

Resultados y Discusión

Los cuatro métodos propuestos en la sección anterior fueron implementados en lenguaje de programación Scala. Se utilizaron además las librerías MLlib y ML implementadas en Spark para el análisis de grandes volúmenes de datos como los *k-mers*, así como el K-medias para realizar agrupamientos y el cálculo de (2) por pares de vectores implementado en Spark.

En la (Tabla 1) se muestra la predicción obtenida por los cuatro métodos de agrupamiento semi-supervisados propuestos.

Tabla 1 - Predicción realizada por los cuatro métodos de agrupamiento semi-supervisados.

Grupos	Enzimas etiquetadas por grupo antes del agrupamiento	EC_GLC+semi-supervisado		GLC+semi-supervisado_centroides_K-medias	
		Kmers2-3	Kmers2-4	Kmers2-3	Kmers2-4
Grupo 1	43	419	442	61	21
Grupo 2	2	9	7	13	13
Grupo 3	2	4	3	59	15
Grupo 4	5	50	26	53	122
Grupo 5	2	9	16	236	217
Grupo 6	1	10	7	79	113
Total	55	501	501	501	501
Grupos	Enzimas etiquetadas por grupo antes del agrupamiento	EC_GLC+semi-supervisado centroides_K-medias		Centroides_aleatorios_de_enzimas_etiquetadas_K-medias	
		Kmers2-3	Kmers2-4	Kmers2-3	Kmers2-4
Grupo 1	43	88	21	84	269
Grupo 2	2	61	58	18	61
Grupo 3	2	57	13	60	19
Grupo 4	5	215	22	302	85
Grupo 5	2	67	63	13	7
Grupo 6	1	13	324	24	60
Total	55	501	501	501	501

Como se puede apreciar en el método EC_GLC+semi-supervisado: el 85.9% de las enzimas fueron ubicadas en el grupo uno, el 1.59% en el grupo dos, el 0.69% en el grupo tres, el 7.58% en el grupo cuatro, el 2.49% en el grupo cinco y el 1.69% en el grupo seis, siendo la mayoría de las enzimas clasificadas en el grupo uno y en segundo lugar, en el grupo cuatro. Esta predicción es similar a la proporción de ubicación por grupo de las 55 enzimas clasificadas, donde el 78% de las clasificadas están en el grupo uno y el 9.09% está en el grupo cuatro. El resto de las clasificadas solo posee una o dos enzimas en los grupos dos, tres y seis. Por su parte el método GLC+semi-supervisado_centroides_K-medias obtiene 8.18% de enzimas clasificadas en grupo uno, 2.59% en el grupo dos, 7.38% en el grupo tres, 17.46% en grupo cuatro, 45.20% en grupo cinco y 19.15% en grupo seis, ubicando la mayor parte de las enzimas entre los grupos cinco y seis, resultados no similares a la proporción de ubicación por grupo de las enzimas previamente etiquetadas. En el caso del método EC_GLC+semi-supervisado_centroides_K-medias el 10.87% fue ubicado en el grupo uno, el 11.87% en el

grupo dos, el 6.98 % en el grupo tres, el 23.65% en el grupo cuatro, el 12.97% en el grupo cinco y el 33.63% en el grupo seis, por lo que la mayor cantidad de enzimas fueron ubicadas en los grupos seis y cuatro, lo cual dista de la proporción original de las etiquetadas. Por último, en el caso del método Centroides_aleatorios_de_enzimas_etiquetadas_K-medias, el 35.22% fueron asignadas en el grupo uno, el 7.88% en el grupo dos e igual % en el grupo tres, el 38.62% en el grupo cuatro, el 1.99% en el grupo cinco y el 8.38% en el grupo seis, ubicando la mayor cantidad de enzimas entre los grupos uno y tres, lo cual se acerca un poco más a la proporción de los datos etiquetados.

En las predicciones realizadas por los cuatro métodos propuestos para las enzimas de las que ya se conoce su clasificación se encontró que en el caso del método EC_GLC+semi-supervisado con el uso de los *k-mers* del 2 al 3 y del 2 al 4 se realizó una incorrecta clasificación en la enzima “AAU08015.1” que se conoce previamente pertenece al grupo dos y fue ubicada erróneamente en el grupo cinco, el resto de las enzimas fueron ubicadas correctamente.

Por su parte, en el caso del método GLC+semi-supervisado_centroides_K-medias en la mayoría de las enzimas se realizó una incorrecta clasificación sólo realizó una correcta clasificación en las enzimas siguientes:

Con el uso de los *k-mers* del 2 al 3

1. “BAA26114.1”, “AAN58705.1” que se conoce previamente que pertenecen al grupo uno y fueron ubicadas en ese mismo grupo.
2. “CDX66896.1”, “ABP88726.1” que se conoce previamente que pertenece al grupo cinco y fueron ubicadas en ese mismo grupo.
3. “AOR73699.1” fue clasificada correctamente en el grupo seis

Con el uso de los *k-mers* del 2 al 4

1. “AJE22990.1”, “ACB62096.1” que se conoce previamente que pertenecen al grupo cuatro y fueron ubicadas en ese mismo grupo.

2. “CDX66896.1”, “ABP88726.1” que se conoce previamente que pertenecen al grupo cinco y fueron ubicadas en ese mismo grupo.

En el caso del método EC_GLC+semi-supervisado_centroides_K-medias en la mayoría de las enzimas se realizó una incorrecta clasificación sólo realizó una correcta clasificación en las enzimas siguientes:

Con el uso de los *k-mers* del 2 al 4

1. “BAA90527.1”, “AAS79426.1”, “CCK33643.1” que se conoce previamente que pertenecen al grupo uno y fueron ubicadas en ese mismo grupo.

En el caso del método Centroides_aleatorios_de_enzimas_etiquetadas_K-medias en la mayoría de las enzimas se realizó una incorrecta clasificación sólo realizó una correcta clasificación en las enzimas siguientes:

Con el uso de los *k-mers* del 2 al 4

1. “CAA77898.1”, “AAA26896.1”, “AAA26898.1”, “BAA14241.1”, “BAA02976.1”, “AAC41412.1”, “AAC41413.1”, “AAB95453.1”, “AAD10952.1”, “BAA90527.1”, “CAB76565.1”, “AAG38021.1”, “AAG61158.1”, “BAC07265.1”, “AAN58619.1”, “AAN38835.1”, “AAS79426.1”, “AAQ98615.2”, “AAX76986.1”, “ABC75033.1”, “ABF85832.1”, “BAF62337.1”, “BAF96719.1”, “ACA83218.1”, “ACK38203.1”, “ACT20911.1”, “ACY92456.2”, “ADB43097.3”, “CCF30682.1”, “AFP53921.1”, “CCK33643.1”, “CCK33644.1”, “AHU88292.1”, “CDX67012.1”, “CDX66895.1”, “CDX66641.1”, “AKE50934.1” que se conoce previamente que pertenecen al grupo uno y fueron ubicadas en ese mismo grupo.

Como se había mencionado en la sección anterior, se utiliza para validar el agrupamiento el índice de silueta como medidas interna y como medida externa: precisión, cubrimiento y medida-F. En la (Tabla 2) se aprecian los valores calculados para el índice de silueta de los dos métodos con sus respectivas dos combinaciones de los *k-mers*.

Tabla 2 -Valores del índice de silueta de los cuatro métodos de agrupamiento propuestos.

Medidas Internas/Índice de silueta				
Grupos	EC_GLC+semi-supervisado		GLC+semi-supervisado_centroides_K-medias	
	Kmers 2-3	Kmers 2-4	Kmers 2-3	Kmers 2-4
Grupo 1	6,17E-04	0,0104	0,4995	0,3773
Grupo 2	0,4839	0,8148	0,0823	0,0381
Grupo 3	0,2497	0,3778	0,3794	0,2614
Grupo 4	0,0664	0,1352	6,80E-04	0,1813
Grupo 5	0,3168	0,1671	-0,0204	-0,0625
Grupo 6	-0,0074	0,4416	0,181	0,1325
Global	0,185	0,3245	0,1871	0,1547
Grupos	EC_GLC+semi-supervisado_centroides_K-medias		Centroides_aleatorios_de_enzimas_etiquetadas_K-medias	
	Kmers 2-3	Kmers 2-4	Kmers 2-3	Kmers 2-4
Grupo 1	0,322	0,229	0,2067	-0,0677
Grupo 2	0,4995	0,4943	0,4169	0,4825
Grupo 3	0,032	0,1801	0,4442	0,5238
Grupo 4	-5,81E-02	0,5551	7,76E-02	0,1584
Grupo 5	0,2108	0,2905	0,1174	0,7666
Grupo 6	0,0823	0,1401	0,1248	0,4021
Global	0,1814	0,3149	0,2313	0,3776

El valor más bajo del índice de silueta por grupo en el caso del método EC_GLC+semi-supervisado lo tiene el grupo seis con el uso de los *k-mers* 2 al 3, en el método GLC+semi-supervisado_centroides_K-medias lo tiene el grupo cinco con el uso del *k-mers* del 2 al 4, en el método EC_GLC+semi-supervisado_centroides_K-medias se obtuvo en el grupo cuatro con el uso de 2 a 3-*mers*, en el método Centroides_aleatorios_de_enzimas_etiquetadas_K-medias en el grupo uno con el uso de los *k-mers* del 2 al 4, estos valores bajos sombreados en Negrita en la (Tabla 2) indican que las enzimas están más cerca, como promedio, de otro grupo que de éste donde fueron ubicadas. Por otro lado el valor más bajo del índice de silueta global lo tiene el método GLC+semi-supervisado_centroides_K-medias con el uso de los *k-mers* del 2 al 4 y el valor más alto se logró en el método Centroides_aleatorios_de_enzimas_etiquetadas_K-medias seguido del EC_GLC+ semi-supervisado con el uso de los 2 a 4-*mers* en ambos casos.

Aunque los valores del índice de silueta global para ambos métodos no son significativamente buenos por no estar por encima de 0.5 o más próximos a 1, se pudieran considerar como valores moderados, similares a los ofrecidos por el K-medias implementado en la librería ML de Spark, que al agrupar las enzimas usando *k-mers* 2 y 3 obtiene un índice de silueta de 0.19711619160997274 y 0.12133373673005655 con el uso de los *k-mers* del 2 al 4, valores similares, e incluso más bajos, que los obtenidos por algunos de los cuatro métodos con el uso de los 2 a 4-*mers*. Además, señalar que esta familia de enzimas posee enzimas muy similares a algunas que incluso tienen doble clasificación, como el caso de una de las etiquetadas que no se empleó para no generar confusión durante el agrupamiento, es decir, que tienen características que las pueden ubicar en más de un grupo al mismo tiempo. Todo esto explica los valores bajos del índice de silueta.

En el caso de las medidas externas, a continuación se muestran en (Tabla 3) los valores obtenidos para los dos métodos propuestos.

Tabla 3 -Valores de las medidas externas para los dos métodos de agrupamiento propuestos.

Medidas externas	EC-GLC+semisupervisado con <i>Kmers</i> 2-3							EC-GLC+semisupervisado con <i>Kmers</i> 2-4						
	G1	G2	G3	G4	G5	G6	Global	G1	G2	G3	G4	G5	G6	Global
Precisión	1	1	0,5	1	1	1	0,91	1	1	0,5	1	1	1	0,91
Cubrimiento	1	1	1	1	0,66	1	0,94	1	1	1	1	0,66	1	0,94
Medida-F	1	1	0,66	1	0,8	1	0,91	1	1	0,66	1	0,8	1	0,91
Medidas externas	GLC+semi-supervisado_centroides_K-medias con <i>Kmers</i> 2-3							GLC+semi-supervisado_centroides_K-medias con <i>Kmers</i> 2-4						
	G1	G2	G3	G4	G5	G6	Global	G1	G2	G3	G4	G5	G6	Global
Precisión	0,04	0	0	0	1	1	0,34	0	0	0	0,4	1	0	0,23
Cubrimiento	1	0	0	0	0,05	0,25	0,21	0	0	0	1	0,06	0	0,17
Medida-F	0,08	0	0	0	0,10	0,4	0,09	0	0	0	3	0,2	0	0,53
Medidas externas	EC_GLC+semi-supervisado_centroides_K-medias con <i>Kmers</i> 2-3							EC_GLC+ssemi-supervisado_centroides_K-medias con <i>Kmers</i> 2-4						
	G1	G2	G3	G4	G5	G6	Global	G1	G2	G3	G4	G5	G6	Global
Precisión	0	0	0	0	0	0	0	0,06	0	0	0	0	0	0,01
Cubrimiento	0	0	0	0	0	0	0	1	0	0	0	0	0	0,16
Medida-F	0	0	0	0	0	0	0	0,13	0	0	0	0	0	0,02

Medidas externas	Centroides_aleatorios_de_enzimas_etiquetadas_K-medias con <i>Kmers</i> 2-3							Centroides_aleatorios_de_enzimas_etiquetadas_K-medias con <i>Kmers</i> 2-4						
	G1	G2	G3	G4	G5	G6	Global	G1	G2	G3	G4	G5	G6	Global
Precisión	0	0	0	0	0	0	0	0,86	0	0	0,6	0	0	0,24
Cubrimiento	0	0	0	0	0	0	0	0,86	0	0	0,75	0	0	0,26
Medida-F	0	0	0	0	0	0	0	0,86	0	0	0,66	0	0	0,25

Como se puede apreciar los valores obtenidos para las medidas externas del método EC-GLC+ semi-supervisado fueron significativamente buenas con el uso de las dos combinaciones de *k-mers* con valores por encima de 0.91 en el peor de los casos. En Cubrimiento se obtuvieron los mejores valores con 0.94 en los dos casos.

En el caso del método GLC+semi-supervisado_centroides_K-medias los resultados no fueron positivos y fueron realmente muy bajos, con valores por debajo de 0.5. El peor valor se obtuvo en la medida-F con el uso de los *k-mers* del 2 al 3, sin embargo, en Precisión y Cubrimiento con el uso de estos *k-mers* se obtuvieron valores más altos que con el uso de los *k-mers* del 2 al 4.

En el caso de los método EC_GLC+semi-supervisado_centroides_K-medias y Centroides_aleatorios_de_enzimas_etiquetadas_K-medias los resultados tampoco fueron positivos. Al no obtener ninguna enzima de las etiquetadas bien clasificada con el uso de los *k-mers* del 2 al 3 entonces fue imposible obtener un valor mayor que cero para las tres medidas externas y con el uso de los *k-mers* del 2 al 4 se obtuvieron valores muy por debajo 0.30 de manera global. De manera general los valores de las medidas externas obtenidos en el primer método fueron mucho mejores que los obtenidos con los restantes métodos.

Conclusiones

Con la propuesta de cuatro algoritmos para el agrupamiento que permiten incluir información disponible sobre el conjunto de datos, es posible realizar el agrupamiento de manera semi-supervisada. En los cuatro métodos se obtuvieron 6 clústeres correspondientes a la actividad enzimática.

Al validar el agrupamiento resultaron aceptables los valores del índice de silueta ofrecido por los cuatro métodos pero con el uso de los 2 a 4-*mers* e incluso mejores que los obtenidos por el K-medias de Spark. El mejor valor de silueta (0.37) se obtuvo con Centroides_aleatorios_de_enzimas_etiquetadas_K-medias. En la validación externa fueron promisorios los valores obtenidos por el método EC-GLC+semi-supervisado para los índices considerados, predominando el valor 0.91 en la medida-F para las distintas combinaciones de *k-mers*. El uso de otras medidas de similitud, y/o de otras formas de agregación o integración de la información basadas en la reducción de la dimensionalidad o la selección de los rasgos relevantes, junto a mejoras en el agrupamiento, pudieran mejorar los valores de los índices de validación para la clasificación de la actividad enzimática.

Por otra parte, el uso de Spark garantiza el manejo de rasgos de alta dimensionalidad como los *k-mers*, que permiten extraer información de la estructura de las secuencias, y además, deberá garantizar la escalabilidad de los algoritmos cuando se incremente el número de procesadores y de secuencias a clasificar, así como obtener bajos tiempos de ejecución en un clúster de computadoras.

Referencias

- Abdallah, L., & Yousef, M. (2020). *GrpClassifierEC: a novel classification approach based on the ensemble clustering space*.
- AK Ong, S., Huang Lin, H., Zong Chen, Y., Rong Li, Z., & Cao, Z. (2007). Efficacy of different protein descriptors in predicting protein functional families. *BMC Bioinformatics*, 8(300). <https://doi.org/10.1186/1471-2105-8-300>.
- Arai, K., & Barakbah, A. R. (2007). Hierarchical K-means: an algorithm for centroids initialization for K-means. *Reports of the Faculty of Science and Engineering, Saga Univ. Saga University, Vol. 36*(No.1).
- Assefi, M., Behraves, E., Liu, G., & Tafti, A. P. (2017). Big Data Machine Learning using Apache Spark

MLlib. *Conference: IEEE Big Data*. <https://doi.org/10.1109/BigData.2017.8258338>

Baeza-Yates, R., & Frakes, W. B. (1992). *Information Retrieval: Data Structures and Algorithms* (P. Hall (ed.); 1 (22 de j)).

Basu, S., Banerjee, A., & Mooney, R. (2002). Semi-supervised Clustering by Seeding. *Proceedings of the 19th International Conference on Machine Learning*, 27-34.

Brun, M., Sima, C., Hua, J., & Lowey, J. (2007). Model-based evaluation of clustering validation measures. *Pattern Recognition*. <https://doi.org/10.1016/j.patcog.2006.06.026>

Chapelle, O., Schölkopf, B., & Zien, A. (2006). *Semi-Supervised Learning*.

Davies, G. J., & Sinnott, M. L. (2008). The sequence-based classifications of carbohydrate-active enzymes. Sorting the diverse. *Regulars Biochemical Journal Classic Papers*, 27-32.

Fraga Vidal, R., Martínez, A., Moulis, C., Escalier, P., Morel, S., Remaud-Simeon, M., & Monsan, P. (2011). A novel dextransucrase is produced by *Leuconostoc citreum* strain B/110-1-2: An isolate used for the industrial production of dextran and dextran derivatives. *Journal of Industrial Microbiology and Biotechnology*, 38(9), 1499-1506. <https://doi.org/10.1007/s10295-010-0936-x>

Galpert, D. (2016). *Contribuciones al enfoque de comparación par a par en la detección de genes ortólogos*.

González-Almagro, G., Luengo, J., Cano, J.-R., & García, S. (2020). DILS: constrained clustering through Dual Iterative Local Search. *Computers and Operations Research*. <https://doi.org/https://doi.org/10.1016/j.cor.2020.104979>

Gunasinghe, U., Alahakoon, D., & Bedingfield, S. (2014). Extraction of high quality k-words for alignment-free sequence comparison. *Journal of Theoretical Biology*, 358, 31-51. <https://doi.org/10.1016/j.jtbi.2014.05.016>

Halkidi, M., Batistakis, Y., & Vazirgiannis, M. (2002). *Clustering validity checking methods: part II*.

Han, J., & Kamber, M. (2001). Data mining: concepts and techniques. En *Data Management Systems*. , San Francisco: Morgan Kaufmann.

Höppner, F., Klawonn, F., Kruse, R., & Runkler, T. (1999). *Fuzzy Cluster Analysis: Methods for Classification, Data Analysis and Image Recognition*.

Jain, Anil K., & Dubes, R. C. (1988). Algorithms for Clustering Data. *Prentice Hall, Englewood Cliffs*.

Jain, Anil Kumar, Murty, M. N., & Flynn, P. J. (1999). Data clustering: a review. *ACM Computing Surveys*.

<https://doi.org/https://doi.org/10.1145/331499.331504>

Khan, S. S., & Ahmad, A. (2004). Cluster center initialization algorithm for K-means clustering. *Elsevier B.V.*

<https://doi.org/doi:10.1016/j.patrec.2004.04.007>

Koutroumbas, K., & Theodoridis, S. (2008). *Pattern Recognition*. Academic Press.

Kruse, R., Döring, C., & Lesot, M. (2007). *Fundamentals of Fuzzy Clustering, in Advances in Fuzzy Clustering and its Applications* (J. Valente). <https://doi.org/https://doi.org/10.1002/9780470061190.ch1>

Lange, T., Law, M. H. C., Jain, A. K., & Buhmann, J. M. (2005). Learning With Constrained and Unlabelled Data. *In Proceedings of the 2005 IEEE conference on computer vision and pattern recognition*, 731–738.

Li, Y., Wang, S., Umarov, R., Xie, B., Gao, M. F., & Xin, L. L. (2018). IDEEPre: sequence-based enzyme EC number prediction by deep learning. *Bioinformatics*, 34((5)), 760–769.

<https://doi.org/10.1093/bioinformatics/btx680>

Lombard, V., Ramulu, H. G., Drula, E., Coutinho, P. M., & Henrissat, B. (2014). *The carbohydrate-active enzymes database (CAZy) in 2013*. <https://doi.org/10.1093/nar/gkt1178>

Melsted, P., & Pritchard, J. k. (2011). Efficient counting of k-mers in DNA sequences using a bloom filter. *BMC Bioinformatics*, 12(333), 1-7.

Meng, X., Gangoiti, J., Bai, Y., Pijning, T., Leeuwen, S. S. Van, & Dijkhuizen, L. (2016). Structure–function relationships of family GH70 glucansucrase and 4,6- α -glucanotransferase enzymes, and their evolutionary relationships with family GH13 enzymes. *Cellular and Molecular Life Sciences*, 73(14), 2681–2706. <https://doi.org/10.1007/s00018-016-2245-7>

Rosell, M., Nada, K., Kann, V., & Litton, J.-E. (2004). Comparing comparisons: Document clustering evaluation using two manual classifications. *Proceedings of the International Conference on Natural Language Processing (ICON 2004)*.

Ruiz-Shulcloper, J. (s. f.). Capítulo 10.- clasificación no supervisada: Algoritmos de estructuración de espacios cartesianos. En *Reconocimiento lógico combinatorio de patrones: teoría y aplicaciones*.

Ruiz-Shulcloper, J., & Sánchez-Díaz, G. (2001). A clustering method for very large mixed data sets. En *Proceedings 2001 IEEE International Conference on Data Mining*. IEEE. <https://doi.org/10.1109/ICDM.2001.989590>

Shen, H.-B., & Chou, K.-C. (2007). EzyPred: A top–down approach for predicting enzyme functional classes

and subclasses. *Biochemical and Biophysical Research Communications*, 364, 53–59.

Steinbach, M., Karypis, G., & Kumar, V. (2000). A Comparison of Document Clustering Techniques. *Proceedings of 6th ACM SIGKDD World Text Mining Conference*.

Triguero, I., García, S., & Herrera, F. (2015). Self-labeled techniques for semi-supervised learning: taxonomy, software and empirical study. *Knowledge and Information systems*, 42((2)), 245–284.

Vinga, S. (2014). Alignment-free methods in computational biology. *BRIEFINGS IN BIOINFORMATICS*, 15(3), 341-342.

Vinga, S., & Almeida, J. S. (2003). *Alignment-free sequence comparison*. 19(4)(Bioinformatics), 513-523.

Xiaojin Zhu. (2005). *Semi-Supervised Learning Literature Survey* (U. of W.-M. D. of C. Sciences (ed.)).

Xiong, H., Wu, J., & Chen, J. (2006). K-means clustering versus validation measures: a data distribution perspective. En A. Press. (Ed.), *Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining*.

Zielezinski, A., Girgis, H. Z., Bernard, G., Leimeister, C.-A., Tang, K., Dencker, T., Lau, A. K., Röhling, S., Choi, J. J., Waterman, M. S., Comin, M., Kim, S.-H., Vinga, S., Almeida, J. S., Chan, C. X., James, B. T., Sun, F., Morgenstern, B., & Karlowski, W. M. (2019). Benchmarking of alignment-free sequence comparison methods. *Genome Biology*.

Zielezinski, A., Vinga, S., Almeida, J., & Karlowski, W. M. (2017). Alignment-free sequence comparison: benefits, applications, and tools. *Genome Biol*, 18(1), 186.

Conflicto de interés

El autor autoriza la distribución y uso de su artículo.

Notas

^a <http://spark.apache.org/>

^b http://www.cazy.org/GH70_characterized.html

^c En este documento se utiliza cubrimiento como traducción de la medida recall.