

---

# Caso práctico: aprendizaje autónomo aplicado al funcionamiento de una impresora

---

PID\_00251492

Joan Melià Seguí  
Pere Tuset Peiró

---

Tiempo mínimo de dedicación recomendado: 1 hora

---



Universitat  
Oberta  
de Catalunya

---

*Ninguna parte de esta publicación, incluido el diseño general y la cubierta, puede ser copiada, reproducida, almacenada o transmitida de ninguna forma, ni por ningún medio, sea éste eléctrico, químico, mecánico, óptico, grabación, fotocopia, o cualquier otro, sin la previa autorización escrita de los titulares del copyright.*

## Índice

<b>Introducción</b> .....	5
<b>1. Descripción de la problemática</b> .....	6
<b>2. Resolución del caso</b> .....	8
2.1. Clasificación no supervisada: <i>K-means</i> .....	10
2.2. Clasificación supervisada: KNN .....	12
<b>Conclusiones</b> .....	15
<b>Bibliografía</b> .....	16



## Introducción

Hoy día, la mayoría de los dispositivos y máquinas que funcionan en un entorno doméstico e industrial están basados en sistemas electrónicos. Además, gracias a la evolución tecnológica en el campo de los sensores integrados, la mayoría de estos dispositivos y máquinas están instrumentados y nos ofrecen información sobre su funcionamiento en tiempo real. Por tanto, cada vez más nos encontramos con el hecho de que el problema no reside en la obtención, procesamiento y transmisión de los datos del funcionamiento de un sistema, sino en convertir estos datos en conocimiento del propio sistema que nos permita mejorar su funcionamiento a lo largo de su vida útil.

Un ejemplo concreto de aplicación de dicho conocimiento es el *mantenimiento predictivo*, en el que se busca determinar la condición de un sistema a partir de los datos de funcionamiento del mismo, con el objetivo de predecir cuándo es necesario llevar a cabo la acción de mantenimiento. Esta aproximación a la problemática del mantenimiento se contrapone al modelo de *mantenimiento correctivo* o de *mantenimiento preventivo*, en el que las tareas de mantenimiento se llevan a cabo cuando hay una avería o de manera periódica, sin tener en cuenta el estado real del sistema.

El mantenimiento predictivo permite ahorrar costes respecto a los modelos de mantenimiento correctivo y preventivo. Respecto al primero, hace posible minimizar el tiempo de parada no planificado de una máquina. Respecto al segundo, permite minimizar los costes de las piezas de repuesto. Si bien su aplicación resulta interesante desde los dos puntos de vista, el reto para su implantación en un entorno real es la correcta determinación de los parámetros correctos para el funcionamiento de un sistema y la creación de un modelo matemático a partir de estos, que permita predecir correctamente y con la suficiente anticipación el fallo de una máquina.

## 1. Descripción de la problemática

En el caso práctico del PLA 3 «Caso práctico: detección de gotas de tinta mediante una fotobarrera», hemos visto cómo la detección de gotas mediante un ODD (del inglés, *optical drop detector*) se utilizaba para ejecutar el algoritmo de reemplazo de *nozzles* en una impresora DOD (del inglés, *drop on demand*), y conseguir de este modo una calidad de imagen óptima durante el proceso de impresión, a pesar de los defectos presentes en algunos de los cabezales.

Como es fácil identificar, en este caso particular los datos del sistema son la señal en la salida del ODD, y el conocimiento útil para el correcto funcionamiento del mismo es saber si la gota de tinta está o no presente en la señal adquirida. Así pues, para llevar a cabo la detección de las gotas se establece un umbral de detección en función del valor esperado a la salida del sistema. Este umbral de detección se establece a partir de un proceso de calibración, en el que se obtienen muestras a la salida del sistema para los dos casos. De esta forma, los valores que quedan por encima de dicho umbral se consideran detecciones positivas (presencia de gota), y los valores que quedan por debajo se consideran detecciones negativas (ausencia de gota).

Así pues, el problema de la correcta detección de las gotas de tinta reside en los falsos positivos y los falsos negativos. En el primer caso, cuando el valor de pico a la salida del sistema queda por encima de este umbral a pesar de la ausencia de gota (falso positivo); y en el segundo caso, cuando el valor de pico queda por debajo de dicho umbral a pesar de la presencia de gota (falso negativo). En el caso de un sistema electromecánico como el ODD, los falsos positivos pueden deberse a la presencia de ruido electromagnético, mientras que los falsos negativos pueden ser debidos a la degradación de los elementos mecánicos y electrónicos.

Con este criterio, en el PLA 3 hemos visto cómo el procesado de la señal en el dominio digital, mediante un filtro adaptado, nos permitía separar la señal de interés del ruido presente en la misma incluso en unas condiciones subóptimas, minimizando así la probabilidad de falsos positivos y falsos negativos. Si bien el procesado de la señal es un paso fundamental para facilitar el tratamiento de los datos, el problema de la clasificación y detección automática sigue siendo relevante, por dos motivos principales.

En primer lugar, los valores de umbral de detección de gota son diferentes entre distintas unidades del mismo producto, debido a las tolerancias propias de los componentes mecánicos y electrónicos con los que son fabricadas. Además, hay que tener en cuenta que los componentes evolucionan a lo largo del tiempo, debido a las condiciones del entorno y al envejecimiento. Por tanto, un proceso de calibración único, llevado a cabo en el laboratorio para todas las unidades del mismo producto, resulta insuficiente.

En segundo lugar, la mayoría de los sistemas incorporan múltiples sensores para medir un mismo parámetro físico. Este nivel de redundancia permite combinar información de diferentes fuentes y llevar a cabo un proceso de detección más preciso. Si bien para el estudio de un sistema con única variable de interés el proceso se puede llevar a cabo manualmente, en sistemas con múltiples fuentes, el volumen de variables que hay que tratar y sus relaciones de interdependencia pueden hacerlo complejo para una persona.

Teniendo en cuenta esto, en este caso práctico nos centraremos en el uso de técnicas de aprendizaje automático para llevar a cabo la clasificación y detección de manera automática de los parámetros de interés de un sistema. Para ello, seguiremos con el ejemplo de las impresoras basadas en la tecnología TIJ (*thermal inkjet*) y nos centraremos en la clasificación y detección de los colores de tinta utilizados por la impresora (negro, cian, magenta y amarillo), a partir de dos parámetros físicos de las gotas: el volumen y la velocidad de las gotas.

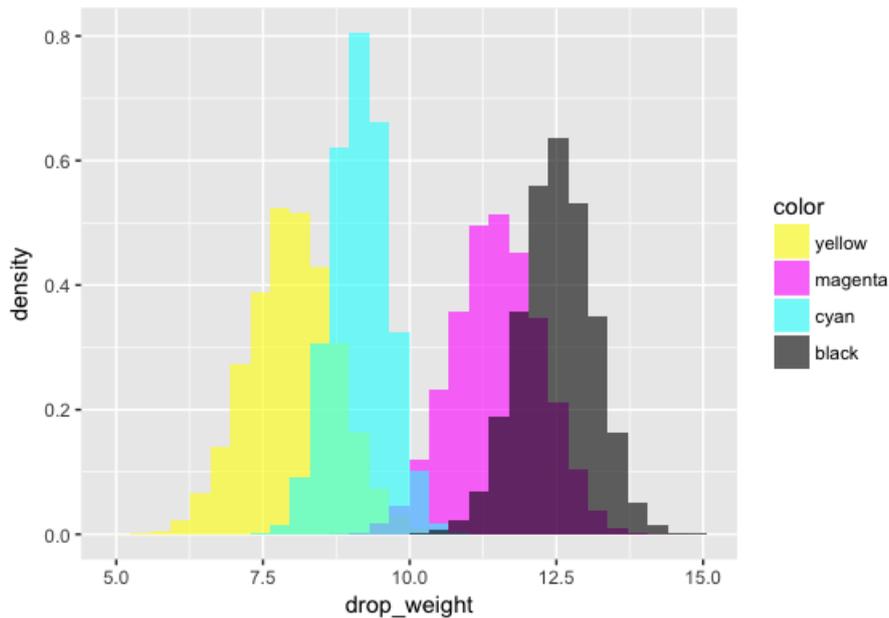
Antes que nada, es importante destacar que, si bien estos parámetros físicos de la tinta no los podemos obtener directamente, se pueden derivar fácilmente a partir de la señal obtenida del ODD. Por un lado, la velocidad de la gota la podemos obtener a partir del tiempo transcurrido desde su disparo hasta su detección en la señal capturada en el sensor. En este caso, hay que tener en cuenta que la distancia entre el cabezal de impresión y el ODD está calibrada y fijada durante la producción de la máquina, y que el proceso de disparo de la gota está sincronizado con el inicio de la adquisición de los datos. Por otro lado, el volumen de la gota viene determinado por las propiedades químicas de cada tinta. En este caso, el dato lo podemos derivar a partir de la amplitud de pico a la salida del filtro adaptado, pero hay que tener en cuenta que el estado de la resistencia juega un papel importante en la magnitud de la señal.

## 2. Resolución del caso

El primer paso para resolver el problema de clasificación automática es visualizar la distribución estadística de las dos variables para cada color de tinta de la impresora, para entender su comportamiento. Las figuras 1 y 2 muestran la función de distribución de probabilidad (PDF, del inglés *probability distribution function*) para el volumen y la velocidad de las gotas de tinta según su color.

Como se puede observar, en los dos casos la distribución de los valores sigue una distribución gaussiana en la que el valor medio de los dos parámetros coincide con su valor esperado, y las variaciones en torno a este valor esperado se deben a las diferencias del proceso de disparo entre gotas sucesivas y los errores introducidos por el propio sistema de medida.

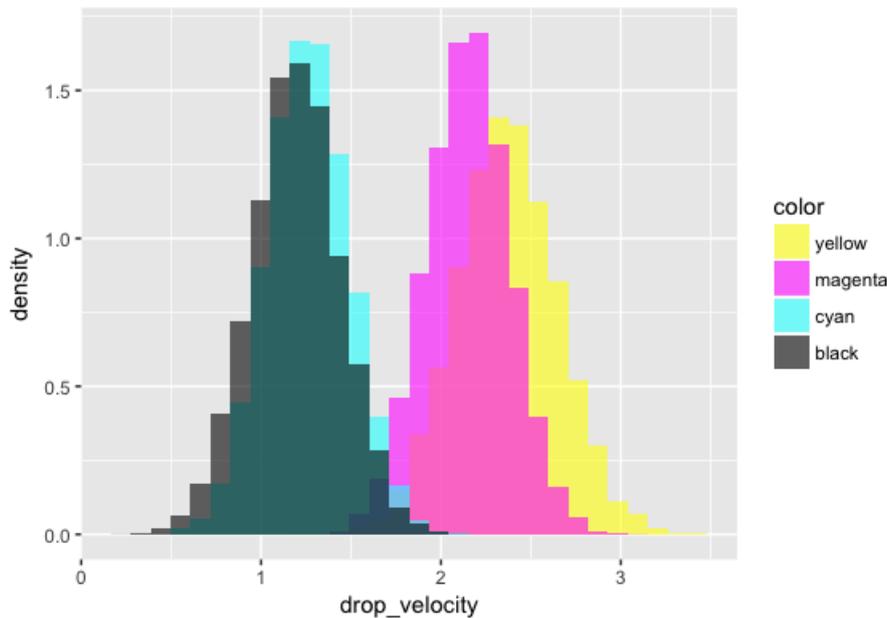
Figura 1. La distribución de los volúmenes de las gotas solo permite distinguir parcialmente los diferentes colores.



Fuente: Elaboración propia.

Un aspecto importante que hay que destacar de estas figuras es que para los dos parámetros, las distribuciones se superponen. En un ámbito práctico, esto supone que no se puede identificar de manera unívoca cada color de tinta, utilizando para ello una sola variable. En concreto, si se utiliza el punto de intersección entre dos de las distribuciones como método para clasificar por colores las gotas, nos podemos encontrar con los siguientes problemas:

Figura 2. La distribución de las velocidades de las gotas no permite distinguir los diferentes colores.



Fuente: Elaboración propia.

- **Área de intersección:** si el área de intersección de dos distribuciones es grande en relación con el total, las gotas que entren en esa área no se podrán clasificar correctamente.
- **Variabilidad temporal:** si la distribución de los valores cambia con el tiempo, el punto de intersección cambiará, por lo que la clasificación empeorará gradualmente.

Una posible solución para este tipo de problemas pasa por utilizar técnicas de aprendizaje automático. Como se ha visto a lo largo de este apartado, hay distintos métodos de aprendizaje automático. Estos métodos se pueden clasificar entre métodos de aprendizaje supervisado y aprendizaje no supervisado.

Por un lado, en el aprendizaje supervisado se utiliza un conjunto de muestras previamente etiquetadas con el resultado obtenido (ya sea una clasificación o una predicción) para entrenar un algoritmo. Una vez entrenado, el algoritmo podrá clasificar o predecir el resultado sobre nuevas muestras introducidas en el sistema. En cambio, el aprendizaje no supervisado simplemente divide un conjunto de muestras en función de algún parámetro, como por ejemplo la proximidad entre las muestras.

En general, el aprendizaje supervisado permite, en aquellos casos en los que se dispone de datos previamente etiquetados, un mejor resultado de la clasificación. Desde métodos sencillos como la regresión lineal, a métodos más complejos como las redes neuronales o el *deep learning*, encontramos un variado conjunto de métodos más o menos complejos en función del tipo de resultado (predicción, o clasificación de una, dos o múltiples clases) y del número y características de las variables de entrada.

En este caso, el objetivo es poder detectar el color de unas gotas de tinta a partir de parámetros como el volumen o la velocidad de las propias gotas. De este modo, nos encontramos con un problema de clasificación de cuatro clases: negro, cian, magenta y amarillo. En los siguientes subapartados, se intentará resolver el problema de la clasificación mediante un método de clasificación no supervisado, y un método de clasificación supervisado.

## 2.1. Clasificación no supervisada: *K-means*

*K-means* es una manera sencilla de dividir un conjunto de datos en  $K$  grupos diferentes y no superpuestos. El único requisito es definir  $K$ , es decir, el número de grupos en los que se quiere dividir el conjunto de datos (en nuestro caso, los cuatro colores básicos: amarillo, cian, magenta y negro). El método estadístico para conseguirlo es muy sencillo: se trata de buscar aquellos grupos en los que la distancia entre observaciones dentro de cada grupo sea la mínima posible. La distancia entre observaciones se puede calcular de diferentes maneras, y la más popular es la distancia euclidiana.

La solución exacta del agrupamiento de datos en  $K$  grupos es muy compleja, ya que existen casi  $K^n$  posibles agrupamientos para  $n$  observaciones (especialmente si  $n$  es muy grande). Una solución aproximada (generalmente, una buena solución) puede obtenerse a partir del algoritmo siguiente:

- 1) Asignar aleatoriamente un número, de 1 a  $K$ , a cada observación.
- 2) Iterar los puntos  $a$ ) y  $b$ ) siguientes hasta que el agrupamiento no cambie:
  - a) Para cada uno de los  $K$  grupos, calcular su centroide.
  - b) Asignar cada observación al grupo cuyo centroide sea más cercano (es decir, la menor distancia euclidiana).

Ref: **James, G.; Witten, D.; Hastie, T.; Tibshirani, R.** (2013). *An introduction to statistical learning*. Nueva York: Springer.

La solución aportada por este algoritmo es aproximada, y depende de la asignación aleatoria inicial, por lo que se recomienda repetir el experimento varias veces y elegir la mejor solución. Para más información sobre el algoritmo *K-means*, se puede consultar el material «Gestión de los datos y su uso: aprendizaje autónomo» de este PLA.

Teniendo en cuenta esto, hemos cargado los datos en el software de computación estadística R, y se ha utilizado la función `kmeans`, que implementa el algoritmo *K-means*.

Además de las muestras que hay que clasificar en sí, es necesario proporcionar al algoritmo dos parámetros adicionales:

### Distancia euclidiana

La distancia euclidiana (o euclídea) es la distancia ordinaria entre dos puntos de un espacio  $n$ -dimensional. Por ejemplo, la distancia  $d$  entre dos puntos  $(x_1, y_1)$  y  $(x_2, y_2)$  de un plano (dos dimensiones) es:

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

### Definición de centroide

El centroide, o baricentro, es el punto de intersección de los elementos que forman un grupo.

- El número de *clusters* o grupos para agrupar las muestras. En nuestro caso, sabemos que debemos agrupar las muestras en cuatro *clusters* relativos a los cuatro colores: amarillo, magenta, cian y negro.
- La cantidad de iteraciones que hay que hacer, buscando la mínima distancia entre centroides y muestras de cada grupo. Se utilizan 20, que deben ser suficientes para la gran mayoría de los casos.

Los resultados de aplicar *K-means* en función del volumen de gota y velocidad de gota se pueden consultar en la tabla 1 y la tabla 2, respectivamente, que presentan las matrices de confusión de la clasificación. Idealmente, la diagonal de celdas debería indicar 10.000 muestras clasificadas, y 0 en el resto (es decir, en este caso no existirían falsos positivos o falsos negativos). En la agrupación basada en el volumen de gota, se obtiene una exactitud de clasificación del 78 %, mientras que usando la velocidad de gota apenas se llega al 31 %. La distribución de los datos hace que en el segundo caso se obtenga una clasificación completamente errónea (inferior a «lanzar una moneda al aire»). La agrupación basada en el volumen de gota es aceptable, pero está lejos de ofrecer un resultado válido en un ámbito industrial.

#### Matriz de confusión

Una matriz de confusión contiene información sobre el desempeño de un sistema de clasificación, y especifica la cantidad de muestras reales y clasificadas en cada clase. A partir de los resultados de la matriz de confusión, se pueden obtener otros parámetros como la exactitud de la clasificación o la *F-score*.

Tabla 1. Matriz de confusión a partir de los *clusters* obtenidos mediante el volumen de gota

<i>K-means</i>	yellow	magenta	cyan	black
yellow	7136	0	649	0
magenta	16	6919	128	1942
cyan	2848	461	9223	3
black	0	2620	0	8055

Tabla 2. Matriz de confusión a partir de los *clusters* obtenidos mediante la velocidad de gota

<i>K-means</i>	yellow	magenta	cyan	black
yellow	5918	2552	0	0
magenta	0	1	4445	5552
cyan	3948	7007	165	119
black	134	440	5390	4329

Finalmente, repetimos la agrupación usando las dos variables simultáneamente, y obtenemos un espacio bidimensional de muestras. La tabla 3 muestra la matriz de confusión correspondiente a la agrupación, que obtiene un 88,5 % de exactitud en la clasificación. En este caso, se mejoran los resultados anteriores, pero siguen lejos de proporcionar una solución válida en un ámbito industrial, donde se espera una clasificación con una precisión próxima al 99 %. De todos modos, si se representa gráficamente la distribución bidimensional de muestras junto con la clasificación obtenida mediante *K-means* (figura 3), se puede ver con facilidad que el resultado no es óptimo.

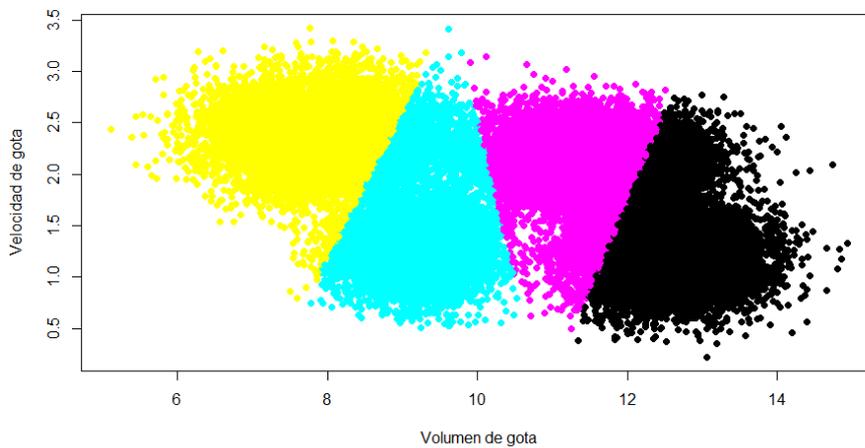
Por último, es importante mencionar que la agrupación obtenida mediante *K-means* en este ejemplo no identifica la muestra a un color específico, sino que indica todas

las muestras que deberían ser del mismo color. La asignación de colores se ha hecho, en este caso, de forma arbitraria.

Tabla 3. Matriz de confusión a partir de los *clusters* obtenidos mediante el volumen de gota

<i>K-means</i>	yellow	magenta	cyan	black
yellow	8661	0	155	0
magenta	37	7976	49	1013
cyan	1302	341	9796	12
black	0	1683	0	8975

Figura 3. Clasificación obtenida a partir del método *K-means*.



Fuente: Elaboración propia.

## 2.2. Clasificación supervisada: KNN

Como se ha podido comprobar en el apartado anterior, incluso obteniendo unos resultados aceptables, el aprendizaje automático no supervisado no nos ofrece un resultado óptimo y adecuado para un caso práctico en un ámbito industrial. Por este motivo, repetiremos el ejercicio con un método de aprendizaje automático supervisado.

Uno de los métodos de aprendizaje automático supervisado más sencillos es el *K-nearest neighbors* (KNN). Este método de clasificación trata de estimar la distribución condicional a partir de muestras  $x$ , para luego clasificar una muestra en la clase con mayor probabilidad estimada. A partir de un valor de  $K$  entero y positivo, y una muestra  $x_0$ , el clasificador KNN identifica las  $K$  muestras más cercanas (de ahí su nombre, *K-nearest neighbors*) a  $x_0$  en el conjunto de datos de entrenamiento. Para ello, generalmente se utiliza la distancia euclidiana. Una vez calculadas las distancias, se estima la probabilidad condicional de que la muestra  $x_0$  pertenezca a la clase  $C$  a partir de la fracción de muestras cercanas pertenecientes a  $C$ .

### *K-nearest neighbors*

Desarrollar en profundidad el método de  $K$  vecinos más cercanos queda fuera de los objetivos de este caso práctico. Los estudiantes interesados en los detalles pueden consultar [James y otros (2013) James, Witten, Hastie y Tibshirani].

Así pues, para evaluar el método de aprendizaje automático supervisado KNN como clasificador, disponemos de un conjunto de 10.000 muestras de gotas de los cuatro colores básicos: negro, cian, magenta y amarillo. El conjunto de 40.000 muestras incluye dos parámetros, el volumen y la velocidad de la gota, además de la etiqueta de la clase correspondiente (uno de los cuatro colores).

Igual que en el caso anterior, hemos cargado los datos en el software de computación estadística R, y se ha utilizado la función `knn`, que implementa el algoritmo de KNN. En concreto, se han utilizado 30.000 muestras como conjunto de entrenamiento, y se ha evaluado la correcta clasificación del sistema sobre las 10.000 muestras restantes.

La tabla 4 y la tabla 5 muestran la matriz de confusión resultado de aplicar KNN utilizando una sola variable. En este caso, el valor ideal de la diagonal de celdas debería ser aproximadamente 2.500 (y 0 en el resto). KNN devuelve una exactitud de clasificación del 74 % si se basa en el volumen de la gota, y del 54 % en el caso de la velocidad, utilizando en los dos casos un valor arbitrario de  $K = 4$ . Resulta evidente que la exactitud de clasificación obtenida no es suficiente para nuestro objetivo.

**R Project**

<https://www.r-project.org/>

Tabla 4. Matriz de confusión a partir de la clasificación mediante el volumen de gota

KNN	yellow	magenta	cyan	black
yellow	1903	8	453	0
magenta	13	1679	87	670
cyan	575	78	1949	0
black	0	695	0	1890

Tabla 5. Matriz de confusión a partir de la clasificación mediante la velocidad de gota

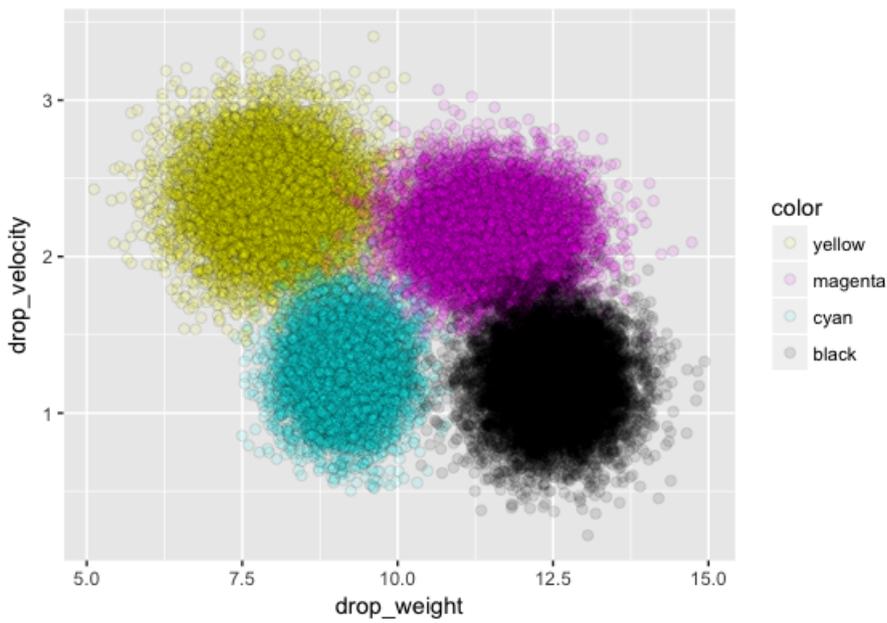
KNN	yellow	magenta	cyan	black
yellow	1449	937	8	9
magenta	1010	1428	68	53
cyan	16	62	1265	1223
black	16	33	1148	1275

Para mejorar el resultado, se puede utilizar KNN con las dos variables y, en consecuencia, un espacio bidimensional. En este caso, la exactitud de clasificación aumenta hasta el 97,5 % usando también  $K = 4$ . Al utilizar las dos variables, las muestras se distribuyen en un plano bidimensional, lo que permite una mejor clasificación. La tabla 6 muestra la matriz de confusión del resultado de clasificación de las 10.000 muestras. La figura 4 muestra gráficamente la clasificación efectuada mediante KNN.

Tabla 6. Matriz de confusión

KNN	yellow	magenta	cyan	black
yellow	2446	20	25	0
magenta	23	2367	10	61
cyan	22	16	2450	7
black	0	57	4	2492

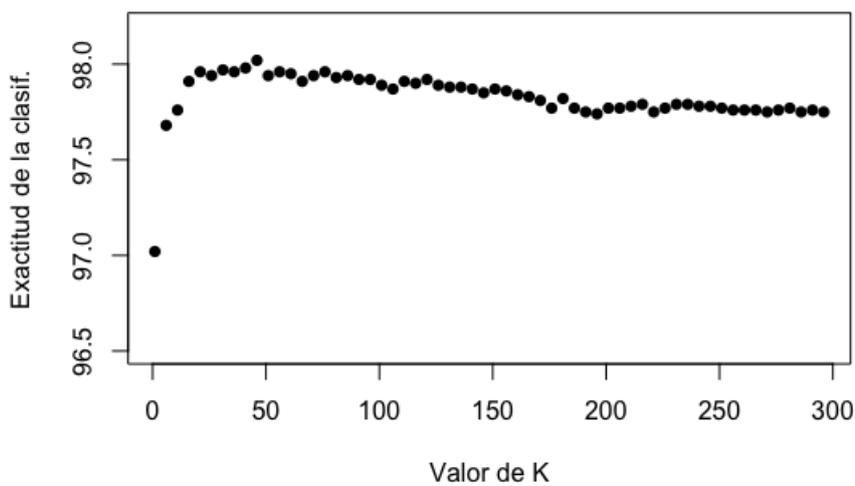
Figura 4. Distribución de las muestras a partir de dos variables.



Fuente: Elaboración propia.

A pesar de obtener un buen valor de exactitud en la clasificación utilizando un valor de  $K = 4$ , se puede optimizar aún más el resultado evaluando KNN con diferentes valores de  $K$ . La figura 5 muestra cómo en  $K \approx 45$  se obtiene un valor óptimo de exactitud de clasificación del 98 %, a partir del cual decrece.

Figura 5. El valor de  $K$  determina la exactitud de la clasificación mediante KNN.



Fuente: Elaboración propia.

## Conclusiones

En este caso práctico, se han evaluado dos métodos de aprendizaje automático, *K-means* y KNN, para la clasificación automática de gotas de tinta a partir de dos parámetros físicos, el volumen y la velocidad de las gotas, derivados de la información adquirida a través del ODD de una impresora DOD.

Por un lado, *K-means* es un método no supervisado que agrupa muestras a partir de minimizar la distancia entre ellas. Tiene la ventaja de ser un método muy sencillo y simple de agrupación, pero no permite identificar una muestra con un color específico, solo decidir si una muestra pertenece a un grupo u otro. Por otro lado, KNN es un método de clasificación supervisado que clasifica una muestra a partir de la distancia a otras muestras previamente etiquetadas. En este caso, sí es posible asignar una muestra a una clase en concreto (gracias al entrenamiento previo del algoritmo).

Después de evaluar los dos métodos, se opta por utilizar KNN ya que ofrece una mejor clasificación (98 % de exactitud en la clasificación, un 10 % mejor que usando *K-means*), y la capacidad de identificar las muestras a un color específico de forma automática. Además, el caso práctico también nos permite recalcar la importancia de llevar a cabo un proceso de calibración de manera periódica, para obtener un juego de muestras actualizado que nos permita llevar a cabo el proceso de entrenamiento y asegurar que la detección resulte óptima.

## **Bibliografía**

**James, G.; Witten, D.; Hastie, T.; Tibshirani, R.** (2013). *An introduction to statistical learning*, volumen 6. Springer.