

Control de calidad en envases alimentarios cerámicos mediante aprendizaje semi-supervisado con SVM de clase única (OCSVM)

Mjahad, A.^{a,*}, Rosado-Muñoz, A.^a

^aETSE. Universitat de Valencia, Av. Universitat sn, 46100 Burjassot, Valencia, España.

Resumen

La detección de grietas, fisuras y defectos en los envases alimentarios resulta de especial relevancia dadas las implicaciones de salud pública. Un envase defectuoso en el mercado puede suponer intoxicaciones a los consumidores. En cambio, la fiabilidad en la detección de defectos no debe penalizar el volumen de producción. Esta aplicación describe un algoritmo semi-supervisado de detección de defectos en la boca de envases alimentarios cerámicos, en una línea de fabricación con un ritmo de producción de 3000 envases a la hora. El algoritmo es una Máquina de Vectores Soporte (Support Vector Machine - SVM) del tipo "one-class" (clase única) (OCSVM), entrenado solo con envases no defectuosos y aumento de datos, permitiendo así un sencillo entrenamiento de cada tipo de envase. La imagen capturada por la cámara es enmascarada y filtrada con técnicas habituales de visión artificial, para posteriormente extraer características a través de un algoritmo de tipo Autoencoder, y finalmente ser clasificadas por OCSVM. Se alcanza una especificidad del 98,8 %, lo que indica que todos los envases defectuosos son detectados, si bien algunos envases correctos también lo son. Se obtiene un tiempo de procesamiento de menos de 20 ms, lo que permite una detección en tiempo real para el volumen de producción de la fábrica. Este procedimiento permite validar el proceso para su aplicación a otras partes del envase como paredes interiores, exteriores, y fondo.

Palabras clave: Sistemas inteligentes de ayuda a la decisión en la fabricación, Control de plantas de fabricación, Aseguramiento y mantenimiento de la calidad, Sistemas de clasificación para estimación de la calidad, Monitorización de calidad de producto y control del rendimiento

Quality control in ceramic food recipients using one-class SVM (OCSVM) semi-supervised learning

Abstract

Detection of cracks, fissures and defects in food vessels is a very important issue since using defective vessels can lead to public health problems due to poisoning to consumers. However, a detailed quality analysis must not affect productivity. A semi-supervised defect detection One-Class SVM (OCSVM) algorithm for the mouth-rim in ceramic vessels is proposed, able to analyze more than 3000 images/vessels per second. Using a semi-supervised approach, training is made using non-defective vessels only, together with data augmentation techniques. Image preprocessing based on traditional artificial vision techniques (positioning, masking and filtering) and feature extraction using an Autoencoder is applied before the OCSVM in order to improve the results. Specificity of 98.8 % is obtained, showing that defective vessels are properly detected, while some non-defective vessels are detected as defective, too. Detection is done in less than 20ms. This procedure validates the procedure and can be extended to the analysis of other vessel parts (interior and exterior walls, and base).

Keywords: Intelligent decision support systems in manufacturing, Manufacturing plant control, Quality assurance and maintenance, Grading systems and Quality assessment, Monitoring of product quality and control performance

1. Introduction

La industria alimentaria precisa de constantes innovaciones para mantener un alto nivel de calidad en sus productos, sin pe-

nalizar eficiencia y velocidad de producción. Por este motivo, el empleo de algoritmos de inteligencia artificial permite el desarrollo de nuevas aplicaciones. En concreto, el entrenamiento

*Autor para correspondencia: mjahad.azeddine@uv.es

de los algoritmos con datos de clase única (one-class), como la máquina de vectores soporte (OCSVM) (Peccatiello et al., 2023) ofrece la posibilidad de realizar un ajuste de los algoritmos de clasificación en contextos donde el tipo de fallos de calidad es muy extenso y a menudo no es posible entrenar el algoritmo con todos los defectos posibles (burbujas, fisuras, manchas o deformaciones). Entrenando el algoritmo con la clase predominante en el proceso (envases sin defectos en este caso) (Raza et al., 2023) será suficiente para que el algoritmo pueda identificar las alteraciones respecto de un envase normal, frente a otro que presente cualquier tipo de anomalía (Raza et al., 2023). Esta técnica se emplea con éxito en otras aplicaciones tales como detección de intrusión (Martens et al., 2023), detección de SPAM en correo electrónico (Manolache, 2023) o transacciones financieras (Wang et al., 2024).

Para el óptimo diseño del clasificador, resulta necesario un adecuado procesamiento previo de los datos de entrada (en este caso, imágenes), resaltando las áreas de interés donde se debe realizar el análisis, o eliminando aquellas zonas de la imagen que no se deben analizar. Las técnicas de enmascarado (Li et al., 2023), (Chen et al., 2023) permiten obtener imágenes modificadas donde únicamente es visible la parte de la imagen que se desea analizar, que será empleada como la entrada para el clasificador.

Por otro lado, el aumento de datos durante el entrenamiento permite ofrecer un mayor número de imágenes al algoritmo para que pueda generalizar mejor su ajuste de parámetros (Xu et al., 2023). En el caso de las imágenes, técnicas habituales de aumento de datos son la modificación del conjunto original de datos con cambios de brillo o intensidad, filtros de color, rotaciones, o escalado.

Este trabajo describe el proceso llevado a cabo para la detección de defectos en la boca de envases cerámicos de uso alimentario, con especial atención en la completa detección de los envases defectuosos a pesar de que ello pueda penalizar la detección de algunos envases correctos como defectuosos. Se describen las diversas etapas de procesamiento previo de la imagen, entrenamiento con datos de clase única, selección de características, y resultados del clasificador.

La sección 2 describe los datos empleados y sus características, además de la metodología seguida para entrenamiento y clasificación en tiempo real. La sección 3 detalla la extracción de características que sirven de entrada al clasificador SVM y la sección 4 muestra los resultados obtenidos con tres variantes. La sección 5 concluye el trabajo.

2. Materiales y Metodología

Se han empleado imágenes de envases cerámicos empleados habitualmente en productos lácteos (natillas, cuajada, yogur) provenientes de la base de datos de la empresa PYGSA clasificadas de forma binaria (correcto/defecto). Las imágenes fueron adquiridas en línea de fabricación, totalizando 704 envases, de los que 472 eran correctos y 232 defectuosos.

Las Figuras 1 y 2 muestran la metodología seguida para el entrenamiento y el posterior uso para la detección en línea. Para el entrenamiento, únicamente se entrena el algoritmo con las imágenes correctas (sin defecto), realizando un aumento de

imágenes para disponer de un mayor número de casos, un enmascarado y detección de área de interés (Region of Interest - ROI) para extraer características únicamente en las zonas relevantes de la imagen, y finalmente realizar el entrenamiento. En caso del funcionamiento en línea (tiempo real), además del enmascarado y detección de áreas de interés (ROI), se añade una etapa de detección de defectos basada en el filtrado de imágenes. Esta etapa permite detectar defectos sin necesidad del algoritmo OCSVM, dejando para éste la discriminación de las imágenes con más riesgo de confusión. Este procedimiento permite reducir el coste computacional y hacer que el algoritmo OCSVM se especialice en la detección de un determinado tipo de fallos.

Para el aumento de datos durante el entrenamiento se realizaron cambios sobre las imágenes originales correctas y así obtener un mayor número de imágenes para el entrenamiento del algoritmo OCSVM. El aumento de datos consistió en realizar cambios en el brillo y contraste (Sakkos et al., 2023), añadir ruido (Abeyasinghe et al., 2023), y rotaciones aleatorias (Alomar et al., 2023). La Figura 3 muestra un ejemplo de cada uno de los cambios realizados. En total se aumentó el conjunto de imágenes correctas con 1000 imágenes, obtenidas sobre el 67 % de las imágenes sin defecto iniciales, el resto se reservó para verificación.

Para reducir el número de píxeles que el algoritmo debe analizar y dado que la boca del envase sólo ocupa una parte de la imagen, se realizó un enmascarado de la imagen para eliminar las secciones donde no aparece la zona a analizar. Con ello, el algoritmo recibe únicamente las zonas relevantes de la imagen, incrementando su especificidad y reduciendo la complejidad de la SVM que a su vez mejora el tiempo de cómputo. El enmascarado se realizó de modo que se aplicó el mismo color a todos los píxeles (negro en este caso), tanto interiores como exteriores a la boca del envase. Posteriormente, a través de la detección del área de interés (ROI), se recortó la imagen para reducirla únicamente al área donde se encuentra la boca del envase.

La detección del área de interés (ROI) se realizó con métodos de procesamiento de imágenes dado que, debido a la velocidad de la línea de producción, la captura de imágenes no es exactamente la misma para todos los envases, pudiendo haber ligeros desplazamientos de la posición del envase en cada captura, por lo que no era posible hacer una detección de ROI fija para todas las capturas.

La Figura 4 muestra la imagen original (izquierda) y la imagen después de aplicar el enmascarado y selección de área de interés (derecha).

Finalmente, la etapa previa a la aplicación del algoritmo OCSVM es la identificación de las características más importantes de la imagen a la hora de detectar los defectos en la boca. En este caso se ha optado por la selección de características de la imagen en lugar de realizar un análisis completo de la imagen por parte del algoritmo dado que el tiempo de cómputo del algoritmo es menor y mejora la capacidad del clasificador para adaptarse a diferentes variaciones en la imagen. Esta metodología permite mayor adaptabilidad a las variaciones, y extrae las principales características, eliminando posibles redundancias que lleven a confusión para el algoritmo.



Figura 1: Metodología de entrenamiento del algoritmo de detección OCSVM.




Figura 2: Metodología para la clasificación en línea (tiempo real) de defectos en la boca del envase mediante filtrado de imágenes y el algoritmo OCSVM.




Figura 3: Procedimientos para el aumento de datos en la fase de entrenamiento del algoritmo OCSVM.

La extracción de características se ha realizado con un algoritmo de tipo Autoencoder entrenado con 100 épocas, lotes de tamaño 32 y error cuadrático medio (MSE) como función de coste. Se trata de un Autoencoder básico con una única capa oculta (codificadora) y una capa de salida (decodificadora). La capa codificadora es de 5 neuronas y función de activación ReLU para reduce la entrada a un espacio latente de baja dimensión. La capa decodificadora posee la misma dimensión que la entrada con función de activación sigmoide para reconstruir la entrada desde el espacio latente. El objetivo es minimizar la diferencia entre la entrada original y su reconstrucción, aprendiendo una compresión eficiente que conserve las características principales. Se ha empleado el optimizador Adam. La Tabla 1 muestra los detalles principales del algoritmo Autoencoder

y el proceso de entrenamiento del conjunto de Autoencoder y OCSVM, así como el tamaño de imagen de entrada, parámetros de salida y tipo de entrenamiento llevado a cabo. Esta misma tabla muestra además la cantidad de imágenes empleadas para el entrenamiento (únicamente imágenes sin defectos, provenientes del conjunto de datos y el aumento de datos realizado) y la verificación (imágenes con y sin defecto). Se empleó el 67 % para entrenamiento y el resto para verificación.




Figura 4: Imagen original (izquierda) e imagen resultante tras el enmascarado y detección ROI (derecha). Únicamente el área interior al rectángulo rojo es empleada para la detección de defectos.

Tabla 1: Detalles de configuración del modelo Autoencoder empleado para extraer características de la imagen y servir como entrada del algoritmo OCSVM (arriba). Número de imágenes originales, cantidad empleada en aprendizaje incluyendo aumento de datos, y test (abajo).

Tamaño imagen (800,800,3)	Núm. caract. 1920000	Func. coste MSE	Épocas 100
Núm. imágenes	Sin defecto	Con defecto	
Conjunto de Datos	472	222	
Entrenamiento	1316	0	
Test	156	171	

Respecto del algoritmo OCSVM, se ha empleado la función

Radial Basis Function - RBF' como kernel, y un valor $\nu = 0,01$ para hacer un modelo más estricto.

3. Detección de defectos mediante procesamiento de imágenes.

Determinados defectos en el envase pueden ser detectados mediante técnicas de filtrado de imágenes habitualmente empleadas en visión artificial sin necesidad del uso de técnicas de inteligencia artificial. El empleo de este tipo de filtros permite la detección temprana de fallos y evita que el algoritmo OCSVM tenga que ser entrenado para un gran número de fallos, pudiendo así especializarse en la detección de defectos más específicos y generalmente más difíciles de detectar mediante técnicas de procesamiento de imágenes.

La detección de defectos a través de la imagen es posible mediante el empleo de técnicas de procesamiento de imagen tales como filtrado, detección de contornos, umbrales de intensidad, etc. Una detección de defectos mediante estas técnicas permite la detección de defectos prominentes y claramente visibles.

Una vez se ha enmascarado y ubicado el área de interés en la imagen, se ha desarrollado un algoritmo de procesamiento de imágenes basado en un umbral de color en el canal rojo, dado el color del envase cerámico de esta aplicación. Posteriormente se ha aplicado la detección de contorno para establecer claramente el área ocupada por la boca del envase y un filtro de "dilation"(dilatación) para binarizar la imagen por umbral y obtener las zonas que no corresponden a los valores habituales ofrecidos por las imágenes sin defectos, obteniendo así una clasificación del envase. La Figura 5 muestra un ejemplo donde se aprecia la detección del defecto obtenida mediante el uso de procesamiento de la imagen.




Figura 5: Imagen original, detección del área de interés, y detección del defecto con filtros de imagen.

En cualquier caso, el algoritmo de procesamiento de imagen desarrollado ha tenido en cuenta la detección de defectos importantes, de modo que ninguna imagen sin defecto pueda ser clasificada como defectuosa dado que se delega la clasificación final en el algoritmo OCSVM, encargado de la clasificación minuciosa de los defectos.

4. Resultados

Para establecer una comparativa, se han analizado los resultados de detección de defectos empleando los siguientes análisis:

- Detección de defectos mediante procesamiento de imagen. Se obtiene el valor indicativo de los defectos detectados mediante esta técnica y se verifica que no se detectan como defectuosos los envases sin defecto.
- Detección de defectos mediante OCSVM. Se analiza el resultado del algoritmo OCSVM sin el paso previo del procesamiento de imagen, pero con la extracción de características proporcionada por el Autoencoder.
- Detección de defectos combinando procesamiento y Autoencoder+OCSVM. Resultado combinado de la detección primera de defectos por parte del algoritmo de procesamiento, y en caso de no detectar defecto por parte de éste, el algoritmo OCSVM se encarga de proporcionar el resultado de la clasificación. De este modo, no todas las imágenes son analizadas por OCSVM sino sólo las que el algoritmo de procesamiento ha detectado como no defectuosas.

Para evaluar los resultados de clasificación, se han empleado las métricas habituales (Zhu et al., 2023): sensibilidad y especificidad. La Tabla 2 muestra los resultados de los tres análisis realizados.

Tabla 2: Resultados comparativos de detección de defectos en la boca de envases alimentarios cerámicos empleando únicamente técnicas tradicionales de procesamiento y filtrado de imágenes, únicamente el clasificador Autoencoder+OCSVM, y la combinación de ambos.

Método detección	Sensib.(%)	Especif.(%)
Procesado imagen	100	22,1
Autoenc+OCSVM	76,2	97,0
Procesado+Autoenc+OCSVM	89,4	98,8

A la vista de los resultados, se observa cómo las técnicas de filtrado consiguen detectar algunos defectos, sin detección errónea de envases sin defecto (sensibilidad=100 %), si bien, como era esperable, la detección de defectos es baja (especificidad=22,1 %), pero robusta. Analizando el clasificador Autoencoder+OCSVM sin el paso previo del filtrado de imágenes, vemos que la especificidad es alta (97,0 %), aunque por contra, la sensibilidad ha bajado (76,2 %) debido a que el clasificador no es capaz de separar correctamente todas las imágenes sin defecto. Como es esperable, al unir ambas técnicas, la sensibilidad aumenta hasta el 89,4 %, y la especificidad también aumenta (98,8 %).

5. Conclusiones

El conjunto de datos empleado ha sido reducido (694 imágenes); en cambio, este trabajo muestra las posibilidades que ofrece la técnica de entrenamiento de clase única (one-class o single-class) para aplicaciones donde una de las clases es predominante y el resto de clases son escasas y con gran variabilidad. Este caso es habitual en la detección de calidad en la producción industrial donde la mayor parte de los productos son correctos. Además, se ha empleado la técnica de aumento de datos para incrementar el número de imágenes sin defecto.

Esta técnica permite un rápido entrenamiento de los algoritmos de aprendizaje automático ya que no es necesario obtener un conjunto de datos de entrenamiento extenso, variado y balanceado. Por otra parte, resulta conveniente añadir técnicas de selección de características a los algoritmos entrenados con clase única, así como elementos de filtrado y homogeneización de datos de entrada, tales como filtrado y enmascarado en el caso de imágenes. También es recomendable el empleo de algoritmos de extracción de características que sirven de entrada al clasificador, mejorando su flexibilidad y adaptación a cambios. Todo ello consigue un mejor rendimiento del algoritmo que permite un tiempo de ejecución factible para su análisis en tiempo real (alrededor de 3000 envases por hora).

En resumen, si bien la técnica de clase única resulta conveniente, es recomendable hacer un análisis detallado del tipo de detección a realizar para definir correctamente la combinación de técnicas que obtengan el mejor resultado.

Agradecimientos

Agradecer a la empresa Pygsagroup por facilitar las imágenes que han servido para realizar este trabajo (<https://www.pygsagroup.com/>).

Referencias

Abeyasinghe, A., Tohmuang, S., Davy, J. L., Fard, M., 2023. Data augmentation on convolutional neural networks to classify mechanical noise. *Applied Acoustics* 203, 109209.

Alomar, K., Aysel, H. I., Cai, X., 2023. Data augmentation in classification and segmentation: A survey and new strategies. *Journal of Imaging* 9 (2), 46.

Chen, H., Gu, J., Liu, Y., Magid, S. A., Dong, C., Wang, Q., Pfister, H., Zhu, L., 2023. Masked image training for generalizable deep image denoising. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. pp. 1692–1703.

Li, Z., Chen, H., Jing, N., Li, J., 2023. Remainnet: explore road extraction from remote sensing image using mask image modeling. *Remote Sensing* 15 (17), 4215.

Manolache, A., 2023. Deep anomaly detection in text. *arXiv preprint arXiv:2401.02971*.

Martens, T., Perini, L., Davis, J., 2023. Semi-supervised learning from active noisy soft labels for anomaly detection. In: *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. Springer, pp. 219–236.

Peccatiello, R. B., Gondim, J. J. C., Garcia, L. P. F., 2023. Applying one-class algorithms for data stream-based insider threat detection. *IEEE Access*.

Raza, A., Tran, K. P., Koehl, L., Li, S., 2023. Anofed: Adaptive anomaly detection for digital health using transformer-based federated learning and support vector data description. *Engineering Applications of Artificial Intelligence* 121, 106051.

Sakkos, D., Ho, E. S., Shum, H. P., Elvin, G., 2023. Image editing-based data augmentation for illumination-insensitive background subtraction. *Journal of Enterprise Information Management* 36 (3), 818–838.

Wang, R., Moon, S. H., Hu, X. S., Jiao, X., Reis, D., 2024. A computing-in-memory-based one-class hyperdimensional computing model for outlier detection. *IEEE Transactions on Computers*.

Xu, M., Yoon, S., Fuentes, A., Park, D. S., 2023. A comprehensive survey of image augmentation techniques for deep learning. *Pattern Recognition* 137, 109347.

Zhu, Z., Khan, M. A., Wang, S.-H., Zhang, Y.-D., 2023. Rbebt: A resnet-based ba-elm for brain tumor classification. *Comput Mater Contin* 74 (1), 101–111.