Congr. Int. en Ing. Electrónica. Mem. ELECTRO, Vol. 39, pp. 211-216, Oct 2017, Chihuahua, Chih. México
http://electro.itchihuahua.edu.mx/memorias_electro/MemoriaElectro2017.zip
ISSN 1405-2172

EVALUACIÓN DE ALGORITMOS PARA DETECCIÓN DE HUMO MEDIANTE VISIÓN ARTIFICIAL BAJO CRITERIOS DE DESEMPEÑO UNIFICADOS

Nieto-González J. L.; Granda-Gutiérrez E. E.; Pérez-Martínez J. A.; Flores-Fuentes A. A.
Universidad Autónoma del Estado de México
Instituto Literario No. 100, Col. Centro. Toluca, Estado de México. CP 50000
Tel.: (712) 122 04 36 ext. 148
jnietog032@alumno.uaemex.mx, eegrandag@uaemex.mx

RESUMEN.

La detección de humo en áreas abiertas mediante visión artificial elimina la dependencia del sistema detector al contacto con el humo. Sin embargo, debido a las características ópticas y el comportamiento del humo, el proceso de detección en imágenes se ha encontrado con diversos problemas. En el estado del arte se encuentran trabajos que emplean distintas características del humo y la forma en que este se mueve. En este trabajo, se presenta una comparación de tres algoritmos del estado del arte, que afrontan la detección de las características evaluadas mediante distintos enfoques; Toreyin et al, buscan características del humo en el dominio de wavelet; Vieira et al, analizan las imágenes en busca de valores de color RGB y persistencia espaciotemporal; y Zhao et al analizan las características dinámicas de las imágenes. En el presente trabajo se propone la unificación de los criterios de desempeño para evaluar los algoritmos. Estos son evaluados en función del porcentaje de detecciones correctas realizadas (sensibilidad) y el porcentaje de "no-detecciones" correctamente realizadas (especificidad).

Palabras Clave: Visión Artificial, Detección de humo, Tratamiento de imágenes

ABSTRACT.

The dependence of smoke detection systems to contact with smoke is eliminated by artificial vision. However, due to optical features and smoke behavior, many problems are found during the detection process in pictures. Different smoke features and its movement are employed in the state of the art. A comparison of three algorithms from the state of the art is presented in this work, each one facing detection of evaluated features by different approaches: Smoke features in the wavelet domain are looked by Toreyin et al; RGB color values and spatiotemporal persistence are searched through picture analysis by Vieira et al; and dynamic features of the pictures are analyzed by Zhao et al. The unification of the performance criteria to evaluate the algorithms is proposed; this is evaluated based on the percentage of correct detections performed (sensitivity) and the percentage of "non-detections" correctly performed (specificity).

Keywords: Artificial vision, Smoke detection, Image processing

1. INTRODUCCIÓN

Los sistemas para detección de incendios se basan en la identificación de fuego o humo. Frecuentemente la existencia de humo antecede a la de fuego, permitiendo realizar la detección temprana de un incendio [1].

Los dispositivos detectores de humo, basados en sensores electrónicos fotoeléctricos, de haz óptico o de muestreo por aspiración de aire, dependen de la presencia de partículas de humo en una ubicación específica para realizar una detección [2]. En áreas abiertas, tales como instalaciones industriales, sembradíos, o incluso bosques, donde la dispersión del humo en el aire es mayor, no es posible definir una ubicación adecuada para asegurar que el sensor detecte humo. Con el objetivo de superar estas desventajas, las herramientas de visión artificial son empleadas como alternativa, pues permiten la detección de características ópticas del humo sin depender de la distancia o el contacto con el humo [3].

El humo presenta distintas características potencialmente detectables en imágenes. Las herramientas de visión artificial pueden buscar características en imágenes sencillas (fotografías) o en secuencias de imágenes (videos). Las características detectables en imágenes sencillas son denominadas estáticas; el color y la textura son ejemplos de éstas. En secuencias de imágenes es posible detectar las características denominadas dinámicas que incluyen al movimiento, la dirección del movimiento y características de frecuencia como el parpadeo [4].

El análisis del color es una de las herramientas básicas para la búsqueda de humo en imágenes. Algoritmos como el propuesto en [5], emplean un espacio de color RGB; se basan en que las tonalidades del humo (grises, blancos y negros), poseen una característica común: los valores de sus tres componentes se aproximan entre sí. En otros casos como el presentado en [6], se emplea el espacio de color YUV, usualmente homologado con YCbCr, el cual separa un componente de luminancia (Y) y dos de crominancia (en canal de referencia azul o Cb y canal de referencia rojo o Cr); de un modo similar, los pixeles con tonalidades semejantes al humo, poseen valores similares entre cada uno de sus componentes.

En [5]–[7] emplean un algoritmo de extracción de fondo basado en secuencias de imágenes. Inicialmente se define una matriz de fondo (*background*) que es comparada con el cuadro actual de la secuencia, de modo que los pixeles que presentan una diferencia con éste son considerados como pixeles en movimiento. Entonces, una región o grupo de pixeles en movimiento son empleadas para establecer regiones de interés.

Deldjoo et al en [8] proponen el uso de herramientas de análisis distintas al movimiento detectado de la imagen. Definen

bloques alrededor de un área de interés, de modo que si en cuadros posteriores se identifica un movimiento hacia uno de los bloques superiores se considera que el comportamiento del grupo de pixeles es similar al del humo.

Los algoritmos propuestos en [2] y [8], utilizan la transformada de wavelets para detectar características del humo en el dominio de la frecuencia. El parpadeo o fluctuaciones de los pixeles con humo en una secuencia de imágenes poseen una frecuencia menor a 3 Hz. Esto permite buscar decrementos en los coeficientes resultantes de la transformada que indiquen la presencia de este efecto.

La evaluación de la presencia de humo tradicionalmente ha sido un proceso estructurado, en el que cada etapa de análisis avanza a la siguiente al encontrar un valor característico de humo. En trabajos posteriores, los resultados de cada etapa son analizados en conjunto por una herramienta aparte; por ejemplo, en [9] y [10] emplean Adaboost como herramienta para asignar factores de peso a cada característica, permitiendo a un grupo de características, que no sea determinante, influir en la decisión final sobre la presencia de humo. Otras herramientas empleadas son las matrices de decisión difusas [8], que consisten en un conjunto de reglas lógicas que relacionan variables de entrada y salida con una función de pertenencia, de modo que permite clasificar los valores de salida en los grupos definidos a partir del conocimiento disponible sobre el humo.

En [11], se presenta una evaluación de diversos algoritmos en función de las etapas de detección, y las características que evalúan de la imágenes en busca de humo. Shrivastava et al [12] evalúan el desempeño de su algoritmo considerando la complejidad temporal como parámetro comparativo.

Aun cuando no existe un estándar para la medición del funcionamiento de las herramientas, es posible definir, de acuerdo con [13], el porcentaje de detecciones correctas, conocido como sensibilidad y el porcentaje de no detecciones correctas o especificidad. La sensibilidad indica la relación entre el total de detecciones y cuantas fueron realizadas correctamente. La especificidad es calculada de la misma manera, pero considerando los casos en los que no se detecta humo. [7], [14] y [15] utilizan también esta forma de evaluación para sus herramientas.

Considerando que actualmente no se cuenta con un estándar para la evaluación de los algoritmos de detección de humo mediante visión artificial, el presente trabajo se centra en buscar una unificación de los criterios empleados para evaluar estos algoritmos partiendo de los parámetros de exactitud propuestos en el estado del arte (sensibilidad y especificidad), que se enfocan en el resultado final del algoritmo y no en la ejecución del mismo como se plantea en [11] y [12].

A partir de los resultados de este trabajo, es posible apreciar que algunos algoritmos presentan un desempeño muy diferente ante variaciones en iluminación, o ante la modificación de la resolución de las imágenes, por lo que mediante el uso de la metodología propuesta pueden identificarse algunos otros retos a resolver en los algoritmos de visión artificial, que no han sido del todo considerados hasta el momento.

2. METODOLOGÍA

En el presente trabajo se evalúan tres algoritmos para detección de humo mediante visión artificial, a partir de la implementación propia de cada uno. Estos algoritmos comparten algunas herramientas en su funcionamiento, o las implementan con algunas variaciones.

El primer algoritmo, propuesto por Toreyin et al [6], es utilizado por diversos autores como base de comparación para contrastar los resultados de sus propuestas, motivo por el que éste fue elegido. Este algoritmo considera cinco pasos:

1. Detección de pixeles en movimiento
2. Monitoreo de energía en coeficientes wavelet espaciales.
3. Análisis de color en canales U y V
4. Detección de parpadeo en humo mediante wavelet temporal
5. Análisis de convexidad en regiones candidatas de humo

La extracción de fondo es realizada en [5] y [6] mediante un proceso de detección de movimiento en el que para cada cuadro I_n se calcula una imagen de fondo B_n. Para el cuadro inicial I_0, el fondo B_0 es igual al mismo cuadro; posteriormente, en cada instante de tiempo n, el fondo es calculado recursivamente de la siguiente manera:

$$B_{n+1}(x,y) = \begin{cases} \alpha B_n(x,y) + (1-\alpha) I_n(x,y) & con\ movimiento \\ B_n(x,y) & \text{sin}\ movimiento \end{cases} \quad (1)$$

Dónde α representa un parámetro entre 0 y 1 que describe la influencia de cada cuadro en la imagen de fondo y (x,y) son las coordenadas de un pixel en la imagen.

Para determinar si un pixel tiene o no movimiento, la intensidad del mismo es sustraída de su valor correspondiente en el fondo; si el valor absoluto de la diferencia supera un valor de umbral τ, se considera que el pixel tiene movimiento. El valor de umbral es considerado como una constante que define la sensibilidad del algoritmo al movimiento [5].

Aplicando la transformada de wavelet al cuadro analizado, los coeficientes de detalle horizontal (HL), vertical (LH) y diagonal (HH), son empleados para obtener una imagen compuesta w_n que es dividida en bloques R_i de tamaño $K_1 \times K_2$, para posteriormente calcular la energía $e(l_1, l_2)$; si el valor de energía es menor que su correspondiente en el fondo, el bloque se mantiene como candidato con humo.

$$w_n(x,y) = |LH_n(x,y)|^2 + |HL_n(x,y)|^2 + |HH_n(x,y)|^2 \quad (2)$$

$$e(l_1, l_2) = \sum_{(x,y)\epsilon Ri} w_n(x + l_1 K_1, y + l_2 K_2) \quad (3)$$

El análisis de color es realizado en función del espacio de color YUV, donde los componentes U y V son monitoreados en busca de decrementos. Si los valores del pixel en cuestión son menores que sus valores correspondientes en el fondo, el pixel se mantiene como candidato a ser humo.

Los pixeles que tras las primeras tres pruebas se mantienen como candidatos, son monitoreados en busca de parpadeos a una frecuencia de 1 a 3 Hz (frecuencia de parpadeo característica del humo). Para esto, una señal unidimensional con la información temporal del pixel es descompuesta mediante una transformación de wavelet con un filtro de 2 etapas, con las que se obtienen las señales de banda alta d_n y de banda baja e_n. Si las señales superan un valor de umbral cierto número de veces, se determina que el pixel contiene la frecuencia adecuada.

Finalmente, se verifica la convexidad de las regiones candidatas a humo mediante la determinación y revisión de 5 líneas verticales y 5 horizontales igualmente espaciadas que intersectan la región analizada. Si a lo largo de alguna de las líneas 3 pixeles pertenecen al fondo intersectando a la región, la condición de convexidad se rompe.

En general el comportamiento del algoritmo depende de tres parámetros: el umbral τ para la detección de movimiento; el parámetro α que determina la proporción en la que un cuadro tiene influencia sobre el cálculo del fondo; y el valor umbral de frecuencia utilizado en el análisis de wavelet temporal. La complejidad temporal del algoritmo responde al orden $O(n^2)$.

El segundo algoritmo, propuesto por Viera et al. [5] fue seleccionado por su metodología para el análisis de color en RGB, adaptable a distintos tipos de humo. Este algoritmo parte del mismo proceso de detección de movimiento. Los pixeles de las regiones con movimiento detectadas son analizados en busca de colores correspondientes a humo utilizando el espacio de color RGB.

Los pixeles de humo son clasificados de acuerdo con una base de entrenamiento. A partir de un grupo de imágenes de humo, las combinaciones de valores RGB son almacenadas; si un pixel con movimiento aparece en la base, el pixel se mantiene como un candidato a presencia de humo.

Este paso implica a la vez una desventaja para el algoritmo, pues como describen en [5], está entrenado para un tipo específico de humo, y emplearlo en distintos casos requiere de un entrenamiento distinto.

Los pixeles que cumplen las condiciones anteriores son agrupados en regiones, con lo que la imagen es segmentada en clústeres de pixeles candidatos a presencia de humo. Cada clúster es diferenciado de los demás, y aquellos de menor tamaño son discriminados para la siguiente etapa de análisis.

Como último paso en el algoritmo, la persistencia espaciotemporal es verificada, esto es, se monitorea la permanencia de una región durante 30 cuadros consecutivos, las regiones que cumplen con esta permanencia son etiquetadas como con humo. Aquellas regiones que aún no han cumplido con esta condición se mantienen como candidatos. El comportamiento de esta herramienta depende solamente del parámetro de umbral τ, para la detección del movimiento, y su complejidad responde al orden $O(n^2)$.

Finalmente, el algoritmo propuesto por Zhao et al. en [16], fue seleccionado por la combinación de etapas para detección de características dinámicas con la herramienta AdaBoost, que se presenta de manera recurrente en el estado del arte. El algoritmo parte de una etapa de detección de movimiento mediante la estimación de un fondo utilizando filtrado Kalman. Partiendo del valor de la intensidad de cada pixel ($s(x,y)$), se calcula el valor estimado del fondo $S_{bg}(x,y,t_i)$ y el valor de variación, mediante:

$$S_{bg}(t_i) = S_p(t_i) + K(t_i) \cdot \left[z(t_i) - H(t_i) \cdot S_p(t_i)\right] \qquad (4)$$

Dónde H es la matriz de medición, K es la matriz de ganancia de Kalman, y S_p, es el término de predicción calculado como el producto del valor del fondo en un tiempo t_{i-1} por una matriz A denominada matriz del sistema.

De manera similar a los algoritmos anteriores, los pixeles con movimiento son determinados obteniendo la diferencia del valor del pixel actual y su correspondiente en el fondo; si esta diferencia supera un valor de umbral definido como valor constante. Con base en ello, se define una matriz de mapa binario con los pixeles en movimiento como 1 y los estáticos como 0.

Empleando la transformada de wavelet, la energía de alta frecuencia es calculada para bloques de tamaño $M \times M$. En los casos en los que la diferencia de energía supera a la de los cuadros anteriores, el bloque es considerado como con presencia de humo.

Como manera de diferenciar el humo de objetos similares en las imágenes, como niebla, el algoritmo analiza la dirección de movimiento de los bloques candidatos. Para cada bloque k, en un tiempo t, son calculadas las coordenadas del centroide de movimiento $C_x(t,k)$ y $C_y(t,k)$, de acuerdo con las ecuaciones descritas en [16]. El ángulo de dirección es calculado por la función trigonométrica inversa del coseno, para así determinar si el bloque se comporta como humo, con el movimiento vertical característico o no.

La textura dinámica de las regiones candidatas a humo es revisada mediante el cálculo de un Patrón de Movimiento Local Binario (LBMP), que, para cada cuadro de la imagen, a partir de ventanas de búsqueda de 5×5 pixeles calcula el valor de patrón binario local de un punto central P_0 en la ventana y de un punto P_x distinto al centro. La diferencia mínima de los patrones locales en la ventana es considerada como el patrón LBMP; posteriormente, y de acuerdo con su ubicación, la textura dinámica es definida como:

$$TexturaDinamica = \sum_{i,j,k} \delta(LBMP(i,j,k), i) \qquad (5)$$

Donde δ es la distribución delta de Kronecker, definida como

$$\delta(i,j) = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (6)$$

Por último, el algoritmo Adaboost es empleado para que, a partir de los valores obtenidos, se determine que si un conjunto de estos valores iguala o supera un rango de éxito de 0.5, será impulsado como un clasificador fuerte que defina la existencia de humo.

El algoritmo requiere una serie de muestras de entrenamiento; se implementa a partir de 4 pasos principales, en los que se inicializa el peso de la muestra $W(i)$ como 1 entre el número total de muestras positivas para una muestra negativa y viceversa. Posteriormente, se calcula un predictor que iterativamente es calculado de acuerdo con el proceso descrito en [16]; si el peso calculado para el clasificador multiplicado por el valor de la característica normalizado, es mayor al umbral de 0.5, se considera que el cuadro contiene humo. Al igual que el algoritmo anterior, el comportamiento de esta herramienta depende del parámetro de umbral τ, para la detección del movimiento, sin embargo la complejidad del algoritmo tiende a una función $O(n)$

2.1. Calculo de sensibilidad y especificidad

Para medir los parámetros de exactitud planteados, es necesario realizar una clasificación y conteo de los cuadros analizados en 2 categorías principales: Imágenes con humo (S) e imágenes sin humo (N). Los videos son revisados para definir la pertenencia de los cuadros a partir del tiempo en el que aparece o no humo, esto es, si el humo aparece a partir de un tiempo t, los cuadros anteriores a ese punto son clasificados como sin humo, posterior a eso, y si no hay desaparición del humo, los cuadros son clasificados como con humo. La Figura 1 muestra el diagrama de flujo para este proceso.

En cada algoritmo, implementado y evaluado en el programa MATLAB® se utilizó la función *imwrite* mediante la cual todos los cuadros en los que detectó humo son almacenados en un directorio específico para los resultados del algoritmo. Los cuadros detectados que fueron almacenados en este directorio contienen un indicador de presencia de humo. Con base en esto, se realizó un conteo de las imágenes detectadas con el indicador de presencia de humo, y la relación de estos con el total de cuadros con humo es igual a la sensibilidad.

De forma similar, el número de cuadros que no fueron detectados en relación con el total de cuadros clasificados como sin humo, es igual a la especificidad del algoritmo.

La Figura 2 muestra el diagrama de flujo del procedimiento de evaluación propuesto para los algoritmos. Cada que una detección es realizada por un algoritmo, se actualiza un conteo de imágenes por cada etiqueta; con base en esto se determinan los valores de sensibilidad y especificidad.

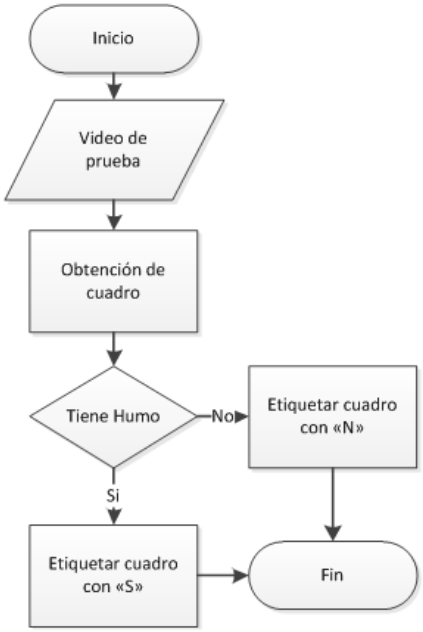

Fig. 1. Diagrama de flujo de la clasificación de los cuadros con y sin humo

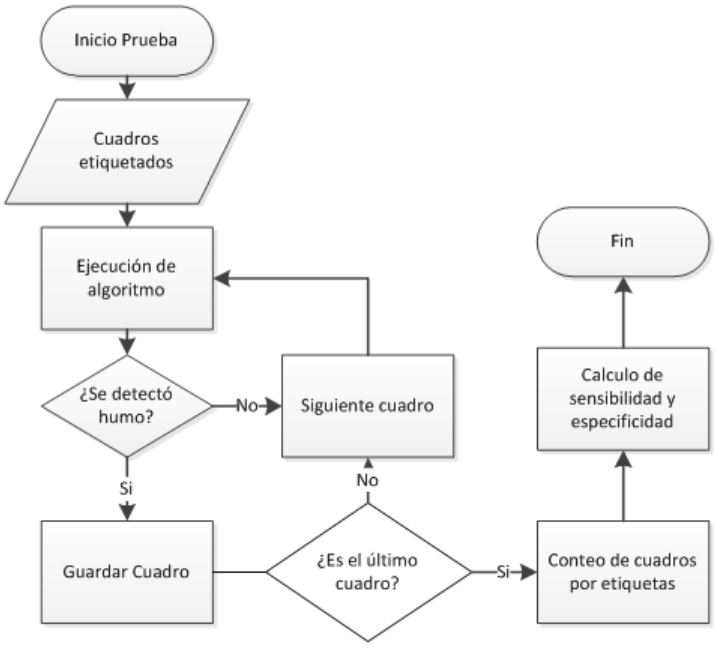

Fig. 2. Diagrama de flujo de la metodología empleada para evaluar los algoritmos

Para evaluar los parámetros de exactitud en los algoritmos evaluados, se emplearon los videos de prueba descritos en la Tabla 1, cuyas muestras representativas se presentan en la Figura 3.

Tabla 1 Especificaciones de los videos de prueba

Video	Duración (mm:ss)	Ancho (pixeles)	Alto (pixeles)	Cuadros por segundo
Video 1 (Humo de día)	01:00	320	240	15
Video 2 (Sin humo de noche)	00:15	320	240	10
Video 3 (Humo de día)	01:00	1920	1080	29
Video 4 (Sin humo de día)	00:19	1280	720	30

Los videos 1 y 2 fueron obtenidos del banco de prueba de la universidad de Bilkent (consultado en la dirección http://signal.ee.bilkent.edu.tr/VisiFire/); el video 1 fue elegido por la cercanía del humo a detectar en condiciones de iluminación diurna mientras que el video 2 fue elegido por su condición de iluminación nocturna. El resto de videos fueron obtenidos por medios propios; el video 3 fue elegido por su condición de iluminación diurna con mayor distancia al humo y el video 4 por no presentar humo bajo condiciones de cielo nublado. Cada video presenta distintas condiciones de iluminación o de resolución.

Fig. 3. Muestras representativas de los videos de prueba. De arriba abajo: Video 1, 2, 3 y 4.

3. RESULTADOS EXPERIMENTALES

A partir de los videos descritos, se obtuvieron un total de 2640 imágenes con humo (900 del video 1 y 1740 del video 3); así mismo, se obtuvieron 736 cuadros sin humo (160 del video 2 y 576 del video 4).

La Figura 4 muestra la gráfica con las comparaciones de sensibilidad de los tres algoritmos en cada uno de los casos de prueba.

En cuanto al segundo parámetro de la exactitud de los algoritmos, la especificidad, evaluada a partir de los videos sin humo (Video 2 y Video 4), los porcentajes resultantes se muestran en la Figura 5.

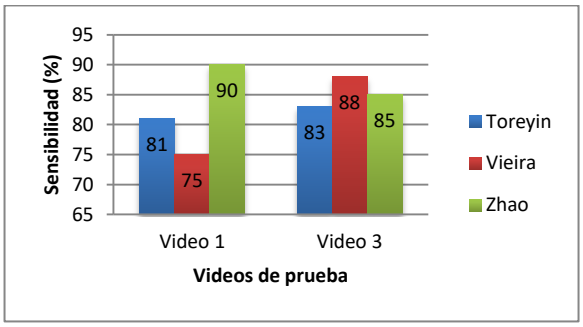

Fig. 1. Gráfica comparativa de sensibilidad para los tres algoritmos en videos con humo

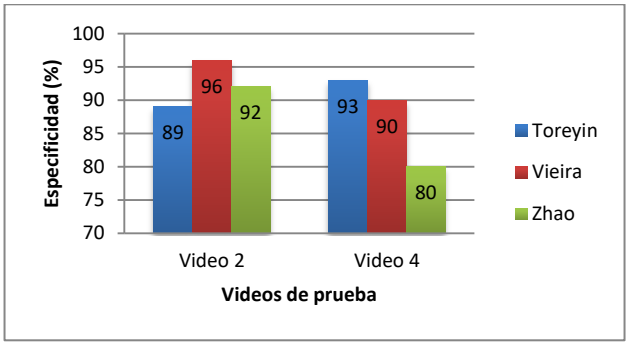

Fig. 2. Gráfica comparativa de especificidad para los algoritmos en videos sin humo

La sensibilidad de los algoritmos evaluados encuentra su valor más bajo en la ejecución del algoritmo de Vieira et al [5]. Debido a que la herramienta empleada para análisis de color en el espacio RGB requiere de un entrenamiento específico para el tipo de humo y las condiciones de iluminación en la captura de la imagen. Con la referencia del trabajo propuesto en [5], el algoritmo está calibrado para trabajar con humo en tonos blancos y grises claros, en un video con una columna de humo más definida (Video 3), el funcionamiento del algoritmo alcanza un 88% de sensibilidad, al adecuarse las tonalidades al vector de combinaciones RGB de entrenamiento. Por el mismo motivo, el algoritmo cuenta con valores de especificidad altos, pues el rango de combinaciones de entrenamiento RGB es distinto a las combinaciones presentes en los videos de prueba.

El algoritmo de Zhao et al [16], presenta los valores de sensibilidad más altos, del 85 y 90%, mostrando una mejor

adaptación de la detección a cambios en la resolución y eliminando la dependencia a un conjunto de combinaciones de valores RGB. Por otro lado, en el video 4, el algoritmo obtuvo el menor porcentaje de especificidad, esto puede deberse a la necesidad de ajustar diversos valores de umbral en las distintas etapas; esto es, los valores obtenidos como características bajas debido a los umbrales pueden ser impulsadas por el algoritmo Adaboost.

Adicionalmente, los resultados del algoritmo pueden variar a partir del conjunto de entrenamiento del algoritmo Adaboost.

El algoritmo de Toreyin et al [6], obtuvo valores de sensibilidad de 81% en el Video 1 y de 83% en el Video 3, lo que muestra que mantiene un funcionamiento similar bajo diferentes resoluciones y velocidades de video. Del lado de la especificidad, los valores de 89% en el video 2 y 93% en el video 4, permiten ver que el algoritmo no mantiene su funcionamiento ante condiciones de iluminación diferentes (noche y día).

4. CONCLUSIONES

En general, el comportamiento de los algoritmos se ve influenciado por los valores de umbral, que son configurados como constantes. Al ejecutar las pruebas bajo distintas condiciones de iluminación, los algoritmos presentan distintos resultados.

Otro caso similar son los conjuntos de entrenamiento utilizados para los algoritmos. La amplia gama de tonos que puede tomar el humo en las imágenes implica que el número de posibles combinaciones de las intensidades RGB de los pixeles es muy alto (para este ejercicio se trabajaron más de 2600 combinaciones solo para tonos blancos y grises claros). Bajo distintas condiciones de iluminación es necesario emplear un entrenamiento distinto.

El algoritmo de Vieira et al [5] trabaja mejor con humo de tonos claros bajo condiciones de luz diurna. El algoritmo de Toreyin mantiene un comportamiento similar con columnas de humo de distintos tonos, sin embargo su desempeño se ve afectado en condiciones de luz nocturna. Puede ser implementado en condiciones de luz diurna para diferentes tipos de humo.

El algoritmo de Zhao et al [16], debido a las características dinámicas que detecta, trabaja mejor que los otros algoritmos cuando el movimiento está afectado por factores externos como el aire; en el Video 1 es posible observar que la condición de convexidad del algoritmo de Toreyin es rota en distintas ocasiones por movimientos irregulares del humo, resultando en no detecciones incorrectas; mientras que el algoritmo de Zhao, es tolerante a estas condiciones.

Mediante la metodología propuesta se han podido identificar parámetros de desempeño que no solamente permiten decir si el algoritmo es capaz de detectar o no el humo, sino que se puede calificar el desempeño de los mismo de una manera unificada, abriendo la posibilidad de detectar otras problemáticas en los algoritmos, y por lo tanto nuevos retos a resolver en la identificación de humo mediante visión artificial como son los cambios en la iluminación o la optimización de la resolución de las imágenes.

5. REFERENCIAS

[1] D. Martín-Borregón Domènech, “Sistema de detección de incendios forestales utilizando técnicas de procesado de imagen,” Universidad Politecnica de Cataluña, 2012.

[2] D. T. Gottuck y J. Dinaburg, “Fire Detection in Warehouse Facilities,” Hughes Associates, Inc., Baltimore, 2012.

[3] J. P. Dukuzumuremyi, B. Zou, y D. Hanyurwimfura, “A Novel Algorithm for Fire / Smoke Detection based on Computer- Vision,” Int. J. Hybrid Inf. Technol., vol. 7, no. 3, pp. 143–154, 2014.

[4] S. Luo, C. Yan, K. Wu, y J. Zheng, “Smoke detection based on condensed image,” Fire Saf. J., vol. 75, no. August, pp. 23–35, 2015.

[5] D. A. G. Vieira, A. L. Santos, H. C. Yehia, A. C. Lisboa, y C. A. M. Nascimento, “Smoke Detection in Environmental Regions by Means of Computer Vision,” Comb. Intell. Methods Appl. - Proc. 3rd Int. Work., pp. 135–151, 2012.

[6] B. U. Töreyin, Y. Dedeoglu, y A. E. Çetin, “Wavelet Based Real-time Smoke Detection in Video,” Proc. Eur. Signal Process. Conf., p. 4, 2005.

[7] R. D. Labati, A. Genovese, V. Piuri, y F. Scotti, “Wildfire Smoke Detection using Computational Intelligence Techniques Enhanced with Synthetic Smoke Plume Generation,” IEEE Trans. Sys, pp. 1–11, 2013.

[8] Y. Deldjoo, F. Nazary, y A. M. Fotouhi, “A Novel Fuzzy-Based Smoke Detection System Using Dynamic and Static Smoke Features,” 23rd Iran. Conf. Electr. Eng., pp. 729–733, 2015.

[9] H. Kim, D. Ryu, and J. Park, “Smoke Detection Using GMM and Adaboost,” Int. J. Comput. Commun. Eng., vol. 3, no. 2, pp. 123–126, 2014.

[10] L. Shuai, W. Bo, D. Ranran, Z. Zhiqiang, y L. Sun, “A novel smoke detection algorithm based on Fast Self-tuning background subtraction,” 28th Chinese Control Decis. Conf., pp. 3539–3543, 2016.

[11] A. E. Çetin, K. Dimitropoulos, B. Gouverneur, N. Grammalidis, O. Günay, Y. H. Habiboglu, B. U. Toreyin y S. Verstockt, “Video fire detection – Review,” Digit. Signal Process., vol. 23, pp. 1827–1843, 2013.

[12] M. Shrivastava y P. Matlani, “A smoke detection algorithm based on k-means segmentation,” Int. Conf. Audio, Languaje Image Process., pp. 301–305, 2016.

[13] B. Ko, J. Park, y J. Nam, “Spatiotemporal bag-of-features for early wild fi re smoke detection ☆,” Image Vis. Comput., vol. 31, no. 10, pp. 786–795, 2013.

[14] K. Dimitropoulos, P. Barmpoutis, y N. Grammalidis, “Higher Order Linear Dynamical Systems for Smoke Detection in Video Surveillance Applications,” IEEE Trans. Circuits Syst. Video Technol., vol. 8215, pp. 1–13, 2016.

[15] D. A. Agrawal y P. Mishra, “Smoke Detection using Local Binary Pattern,” Int. J. Curr. Eng. Technol., vol. 4, no. 6, pp. 4052–4056, 2014.

[16] Y. Zhao, Z. Zhou, y M. Xu, “Forest Fire Smoke Video Detection Using Spatiotemporal and Dynamic Texture Features,” J. Electr. Comput. Eng., vol. 2015, pp. 1–7, 2015.