

Speckle Láser y Mapas Auto-organizados para la identificación de golpes no visibles en manzanas

Lucía I. Passoni¹, Héctor Rabal²

¹ Laboratorio de Bioingeniería. Facultad de Ingeniería. Universidad Nacional de Mar del Plata. Argentina.

² Centro de Investigaciones Ópticas. CONICET-CIC

Facultad de Ingeniería. Universidad Nacional de La Plata. Argentina.

¹ lpassoni@fi.mdp.edu.ar

Resumen— En este trabajo se propone la identificación de golpes no visibles en manzanas, a partir de la segmentación de imágenes de *speckle* láser dinámico, utilizando redes neuronales no supervisadas del tipo Mapas Auto-organizados. Las imágenes a segmentar se obtienen de la adquisición y procesamiento de secuencias de *speckle* láser. Este es un fenómeno que se produce cuando un haz de luz coherente ilumina una muestra en la que se produce algún tipo de actividad, no visible, que origina un patrón variable en el tiempo. La identificación de la dinámica asociada a una región de la imagen es utilizada para su segmentación. Para ello, partiendo de una serie de experimentos, se procesa un conjunto de videos de los que se extraen características de la dinámica de la intensidad. Con este conjunto se entrena un Mapa Auto-organizado, cuyas celdas se colorean según un criterio de similitud. En la etapa de consulta del Mapa, se impactan en él patrones característicos de un nuevo video de *speckle* láser, generándose una imagen pseudo coloreada en el espacio de la muestra, a partir del color de la celda donde impacta cada patrón en el mapa. La capacidad de identificar regiones golpeadas con esta metodología ha superado la presentada por métodos que utilizan un único descriptor.

Palabras clave— *speckle* láser - golpes no visibles en manzanas - Redes Neuronales - Mapas de Kohonen.

I. INTRODUCCIÓN

En nuestro país, reconocido como productor y exportador mundial de manzanas, el desarrollo de metodologías que ayuden a mejorar los procesos de manipulación de las frutas es de suma relevancia. El daño por impacto es uno de los defectos de calidad más frecuentemente encontrados en manzanas. Las líneas de empaque presentan a menudo deficiencias en el diseño, montaje y manejo, que ocasionan importantes pérdidas de calidad.

Se denomina daño mecánico por golpe a los impactos o presiones que sin romper la epidermis deterioran la pulpa del fruto, generando un cambio de coloración progresivo. Este tipo de daño se hace perceptible unos días después de ocurrido el golpe, debido a cambios físicos en la textura del tejido y, eventualmente, a alteraciones químicas de la zona impactada, visibles en el cambio de color y sabor. El cambio de coloración depende de la variedad y de la estructura del tejido de cada fruto como el grosor de la piel, su pigmentación, entre otros [1].

La reglamentación para la exportación de frutas frescas (Decreto-Ley 9244/63) estipula las condiciones de calidad que deben reunir las manzanas destinadas a la exportación, definiendo la superficie máxima golpeada admisible, y categorizando la gravedad del daño en función de la misma.

La *Red Delicious* es una variedad sensible, que por lo general no se la relaciona con el daño mecánico por impacto, debido a que su coloración de cobertura no permite que los golpes sean claramente identificables. La forma de detectarlos, en la mayoría de los casos, es la remoción de la piel en el sector golpeado, o bien con una inspección sumamente cuidadosa (hundimiento o ablandamiento de la zona) [1].

En consecuencia es recomendable la evaluación de los golpes, especialmente debidos a daño mecánico no visibles en las frutas percederas, para comparar los efectos de diferentes procesos de la manipulación.

La detección de áreas golpeadas no visibles en manzanas, a partir de experimentos con *speckle* láser, ha sido previamente abordada utilizando un único descriptor para la segmentación del golpe [2]. El patrón de *speckle* es un patrón de interferencia originado por una luz coherente reflejada o dispersada desde distintas partes de una superficie iluminada. Si la superficie es áspera en comparación con la longitud de onda, rayos de diferentes partes de la superficie con una celda de resolución (el área mínima de imagen que resuelve el sistema óptico) viajan por diferentes caminos ópticos hasta alcanzar el plano de la imagen. La obtención de una secuencia de imágenes del objeto iluminado permite registrar patrones que caracterizan el fenómeno. Esta característica da origen a un patrón variable en el tiempo y en consecuencia la identificación de la dinámica asociada a una región de la imagen es utilizada para su segmentación.

Trabajos anteriores realizan la segmentación de imágenes utilizando solamente un tipo de características. Los algoritmos desarrollados para la extracción de las mismas utilizan métodos en distintos espacios: tiempo, frecuencia, tiempo-frecuencia, como así también herramientas de computación granular [3], [4].

En este trabajo se propone entrenar una red neuronal de aprendizaje no supervisado, un Mapa Auto-organizado, utilizando patrones que caractericen la evolución temporal de los píxeles del video de *speckle* láser, a partir de un conjunto de datos experimentales.

A continuación se colorean las celdas del mapa entrenado según su similitud, permitiendo pseudo colorear una imagen que representa a la muestra. Es así que al consultar el mapa con patrones que identifican a una secuencia de video, no utilizada en el proceso de entrenamiento, se genera una imagen en la que resulta posible identificar visualmente regiones según sus características dinámicas, particularmente la existencia del daño mecánico no visible en la manzana.

Los Mapas Auto-organizados han mostrado su eficiencia en una diversidad de casos asociados con el procesamiento de imágenes [5] [6].

Los resultados obtenidos con este proceso segmentan más definidamente la región del daño no visible que aquellos que utilizan un único descriptor, especialmente donde las secuencias de captura no son largas, menores a 200 imágenes.

II. EL *SPECKLE* DE INTERFEROMETRÍA LASER

El patrón de *speckle* es un patrón de interferencia originado por una luz coherente reflejada o dispersada desde distintas partes de una superficie iluminada. Las superficies de la mayoría de los materiales son extremadamente rugosos si se los observa en la escala de una longitud de onda óptica ($\lambda \sim 5 \times 10^{-7}$ m). Cuando la luz casi monocromática del láser se refleja en este tipo de superficies se genera una onda óptica que contiene diversas componentes originadas en la reflexión de elementos microscópicos diferentes de la superficie. La interferencia de las ondas desfasadas pero coherentes brinda un patrón granular de intensidad que es el llamado *speckle*.

Cuando el *speckle* es generado a partir de la luz difundida por partículas en movimiento, los “speckles” o gránulos son modulados por el movimiento de los difusores. El fenómeno de *speckle* dinámico ocurre cuando la luz del láser es dispersada por objetos que tienen algún tipo de actividad. Está presente en la observación de muestras biológicas y en algunos fenómenos no biológicos como el secado de revestimientos o pinturas [7]. Este fenómeno se origina en los cambios de fase de la luz producido por el movimiento de las partículas donde se produce la reflexión (dispersores) y a cambios en el índice de refracción, entre otros.

Para la etapa de extracción de características de las secuencias de *speckle* dinámico se propone utilizar descriptores ya presentados y discutidos en la literatura. Se consideraron adecuados para la caracterización del golpe no visible en la manzana la utilización de dos descriptores en el dominio del tiempo: el Rango Dinámico, las Diferencias Generalizadas, y de un descriptor en el dominio del tiempo – frecuencia: la Entropía de Shannon obtenida a partir de la Transformada Ondita de los patrones de *speckle* dinámico.

El llamado descriptor del Rango Dinámico se calcula con los de los valores de intensidad como la diferencia entre el valor máximo y el valor mínimo de la serie correspondiente a la ventana temporal que desea evaluarse. El potencial del mismo reside en su rapidez computacional y en la capacidad de discriminar en forma “gruesa” las regiones de diferente actividad [8].

El algoritmo de las Diferencias Generalizadas se define como:

$$GD(x, y) = \sum_k \sum_l |I_k(x, y) - I_{k+l}(x, y)|$$

k y j son los índices que incluyen todas las imágenes capturadas, (x, y) son las coordenadas de la imagen y las barras indican valor absoluto.

Este descriptor ha mostrado su bondad en la segmentación de regiones de interés en frutas [9].

Con el fin de obtener otro elemento descriptor se propone la Entropía de Shannon de la energía de los coeficientes obtenidos en el análisis multiresolución con la Transformada Ondita (T.O.). Se ha mostrado que esta técnica es útil para detectar y caracterizar fenómenos específicos en los planos de frecuencia y tiempo [10].

III. MAPAS AUTO-ORGANIZADOS

El Mapa Auto-Organizado (*Self Organization Map*, SOM) es un algoritmo de redes neuronales basado en aprendizaje no supervisado propuesto por Teuvo Kohonen [11]. En la arquitectura original del modelo Kohonen cada una de las neuronas de entrada se conecta a las celdas de salida, existiendo cierta influencia entre las neuronas vecinas de esta capa. La actualización de los pesos internos de la red durante el proceso de aprendizaje va a depender precisamente de esta interacción lateral.

En el proceso de aprendizaje, partiendo de un estado interno inicial del mapa, se presentan secuencialmente los patrones de entrenamiento. Con la presentación de cada patrón se activa la celda que más se asemeja al mismo (BMU), calculando alguna medida de similitud (ej.: distancia euclidiana). El cambio del estado interno del mapa (aprendizaje) se realiza cuando se modifica el vector de pesos asociado con la celda ganadora y los de las celdas “cercanas” o “vecinas”. El concepto de vecindario es dinámico, va evolucionando (reduciéndose) con el número de iteraciones. De esta manera se consigue que el estado interno de la celda activada y el de sus “vecinas” sea más parecido al patrón de entrada.

Los mapas tienen dos factores de calidad que califican su eficacia:

- Error de cuantificación: promedio de las distancias entre los vectores datos y su BMU.
- Error topográfico: porcentaje de vectores datos para los cuales la primera y la segunda BMU son celdas no adyacentes.

Una vez que el mapa está adecuadamente entrenado se propone utilizar la asignación de un color para cada celda del mapa. Se lo colorea con una paleta de color generada a partir de la proyección de los datos de entrenamiento. En consecuencia las celdas del mapa se colorean según su similitud. La codificación de color será tal que las celdas cercanas (según su distancia euclidiana) tendrán colores similares y aquellas lejanas según este criterio tendrán colores bien diferenciados.

IV. EXPERIMENTO

Con el fin de coleccionar secuencias de *speckle* láser para el entrenamiento del SOM se procedió a golpear de manera controlada manzanas del tipo *Red delicious*

(originalmente en buen estado) con una esfera de acero (diámetro=21.9 mm y peso=133.6g) desde una altura de 20 cm. El daño producido de este modo no podía apreciarse por inspección visual. En todos los casos se utilizó la misma configuración del arreglo óptico con un láser de baja potencia de He-Ne (5mW, $\lambda=633$ nm) para la iluminación de la muestra. Para el registro, sucesivas imágenes fueron adquiridas utilizando una cámara CCD, posteriormente digitalizadas para su almacenamiento en memoria del ordenador personal. La frecuencia de adquisición de las imágenes es de 4 Hz, registrándose en estos experimentos secuencias de 100 imágenes, considerándose que durante el intervalo de adquisición el fenómeno es estacionario, por lo tanto es pertinente la extracción de características en la ventana temporal.

Para iluminar la región de interés de la muestra, zona del golpe, se utilizó un haz divergente del láser. Con el fin de lograr una buena definición de los *speckles*, el diafragma de la cámara CCD fue establecido en un valor alto (típicamente $f=50$ mm, $f/\#=16$), lográndose que el tamaño medio del grano de *speckle* cubra varios píxeles. El láser fue ajustado de forma de mantener constante la intensidad media durante todo el proceso de medición. Este arreglo se hizo para mejorar la relación entre la luz detectada difundida por el interior con respecto a la difundida en la superficie, dado que el fenómeno que se quiere detectar (el golpe) es un daño no superficial, pues la cáscara no está lastimada. Se consideró que la sensibilidad de los indicadores de actividad logrados con este experimento fueron adecuados para los propósitos del mismo.




Fig. 1. Arreglo óptico

Se registraron secuencias en diferentes etapas del experimento: antes del golpe, inmediatamente después, media hora después, el día después, manteniendo siempre las mismas condiciones del arreglo óptico, generándose una secuencia de imágenes, como se indica en la Fig. 2. A partir de la misma se generaron series temporales (una por cada píxel) y se calculó un vector de características por cada una de ellas, generándose patrones de entrenamiento para un SOM con tres componentes: Rango, Diferencias Generalizadas y Entropía de Shannon de la Transformada Ondita. Con estos patrones se entrenó el SOM, cuyas dimensiones se fijaron a partir de un algoritmo de crecimiento que pesa los errores de cuantificación y topográficos [12] y su entrenamiento se detuvo cuando estos parámetros de calidad presentaron comportamientos estacionarios.




Fig. 2. Arreglo de imágenes de *speckle* láser

Dado que las secuencias de imágenes tenían una dimensión de 200 x 200 píxeles, la época de patrones de entrenamiento se armó con cuatro conjuntos (antes del golpe, inmediatamente después, media hora después, un día después) de 40.000 vectores de tres dimensiones (Rango, Entropía de Shannon de la Transformada Ondita (T.O.) y Diferencias Generalizadas) por cada uno.

Los parámetros de inicialización del mapa se fijaron como una estructura de grilla 2D, tipo de celda hexagonal con forma de vecindario *gaussiana*, dimensión 25 x 25. Los patrones de entrenamiento fueron normalizados en un rango entre 0 y 1, y la inicialización del mapa se realizó utilizando una transformación lineal de los datos de entrenamiento.

V. RESULTADOS

Los errores obtenidos en el entrenamiento del SOM fueron los siguientes: de cuantificación 0.034 y el error topográfico resultó nulo.

Para visualizar el resultado del entrenamiento se utilizó la matriz de distancia unificada (*U-matrix*) [13], una representación de las distancias entre celdas del mapa. En esta representación fue posible detectar dos grupos o *clusters*, como se aprecia en la Fig. 3. Al impactar patrones conocidos en el mapa se etiquetaron los *clusters* como pertenecientes a regiones del golpe y a regiones no golpeadas de la manzana. En consecuencia se infiere que los descriptores utilizados son adecuados para “descubrir” la existencia del golpe.

Posteriormente se logró otra visualización del estado interno del SOM. Asignándose colores a las celdas en función de su similitud (Fig. 4 izquierda), se logra una gama particular que identifica la zona del golpe (ángulo inferior izquierdo: tonos amarillo-naranja, que coincide la región de impacto del área golpeada en la *U-matrix*).




Fig 3. Representación 3D de la matriz de distancia.




Fig 4 Izquierda: Mapa coloreado según la similitud de sus celdas. Región de impacto de patrones del golpe vértice inferior izquierdo (amarillo). Derecha: Imagen de la muestra donde se distingue claramente la zona del golpe coloreada en amarillo.

En la etapa de consulta del SOM se coloreó la imagen con las dimensiones de la muestra, utilizando el tono de la celda del mapa donde impacta el patrón que caracteriza a cada píxel.

En la Fig. 5a, b y c se observan las imágenes formadas por cada uno de los descriptores de la secuencia, se percibe que la segmentación de la región del golpe no es tan clara como en la Fig. 4 derecha, en la que se muestra la imagen pseudo coloreada por el SOM (el golpe coincide con la mancha amarilla). Como evidencia del desempeño del SOM en la Fig. 6 se muestran otras imágenes resultado, en las que la existencia de manchas amarillas “descubre” golpes en la muestra como en la Fig. 6 izquierda. En la Fig. 6 derecha, que corresponde a un día después del experimento, no se descubre esta región, dado que el efecto factible de ser evaluado con esta técnica ha desaparecido, no obstante el cambio de coloración en la manzana aún no se había producido.


VI. CONCLUSIONES

En este trabajo se propone una metodología para la detección de golpes en manzanas, en la etapa en que aún no son visibles.

Partiendo del conocimiento de que el daño mecánico del fruto genera alteraciones en la estructura del tejido, se presenta a la técnica de *speckle* láser dinámico para la segmentación de las mismas.

Como aporte original en este trabajo se propone el uso de redes neuronales no supervisadas para la segmentación automática de muestras golpeadas, brindando una imagen pseudo coloreada de inmediata interpretación para un operador entrenado.

Esta técnica mejora resultados obtenidos con descriptores únicos, previamente publicados, especialmente en casos donde las secuencias capturadas no son grandes, es decir menores a 150 imágenes.



a) Entropía de Shannon (T.O.) b) Rango de la secuencia c) Diferencias Generalizadas

Fig 5: Tres descriptores de la misma muestra cuyo pseudo-coloreado con SOM se muestra en la Fig. 4 Derecha.




Fig. 6. Evaluación de nuevas muestras. Izquierda: Descubrimiento de un golpe. Derecha: muestra sin golpe identificable

En consecuencia, al disponer del SOM entrenado con casos conocidos, es posible procesar nuevas secuencias adquiridas bajo condiciones similares y realizar la detección de eventuales golpes no visibles que derivan *a posteriori* en cambios de textura y color en la manzana.

Esta metodología se considera adaptable a procesos de evaluación de calidad de nuevos empaques o formas de transporte de frutas. Si bien el proceso de adquisición de la secuencia de *speckle* láser debe ser llevado a cabo en una ventana temporal no mayor a media hora del daño mecánico, el procesamiento de la información puede realizarse fuera de línea.

A partir de la experimentación de estas técnicas se postula que este proceso es factible de implementarse en otras aplicaciones de interés para el agro, como por ejemplo la evaluación de la viabilidad en semillas de maíz.

REFERENCIAS

- [1] A. Segatori, S. Di Masi, and T. Gomila, "Daño mecánico por golpe en manzanas," *Informe proyecto Nacional N° 52-535 .INTA Estación Experimental del Alto Valle del Río Negro*, 2005.
- [2] M. Pajuelo, G. Baldwin, H. Rabal, N. Cap, R. Arizaga, and M. Trivi, "Bio-speckle assessment of bruising in fruits," *Optics and Lasers in Engineering*, vol. 40, pp. 13-24, 2003/8// 2003.
- [3] H. J. Rabal and R. A. Braga, *Dynamic Laser Speckle and Applications*, 1 ed. vol. 1. Boca Raton: CRC, 2008.
- [4] E. Blotta, V. Ballarín, and H. Rabal, "Decomposition of biospeckle signals through granulometric size distribution," *Opt. Lett.*, vol. 34, pp. 1201-03, 2009.
- [5] O. Kohonen, M. Hauta-Kasari, J. Parkkinen, and T. Jaaskelainen, "Co-occurrence matrix and self-organizing map-based query from spectral image database," in *ICO20: Illumination, Radiation, and Color Technologies 2006*, p. 603305 Doi 10.1117/12.668059
- [6] S. Battiato, F. Rundo, and F. Stanco, "Self Organizing Motor Maps for Color-Mapped Image Re-Indexing," *IEEE Transactions on Image Processing*, vol. 16, pp. 2905-2915, 2007.
- [7] J. Amalvy, C. A. Lasquibar, R. Arizaga, H. Rabal, and M. Trivi, "Application of dynamic speckle interferometry to the drying of coatings," *Progress in Organic Coatings*, vol. 42, pp. 89-99, 2001.
- [8] L. I. Passoni, A. Scandurra, H. Rabal, R. Arizaga, and M. Trivi, "Nuevos descriptores en speckle dinámico: resultados preliminares," presented at the 88^o Reunión Nacional de la Asociación Física Argentina. AFA Bariloche-Argentina, 2003.
- [9] P. A. Faccia, O. R. Pardini, J. I. Amalvy, N. Cap, E. E. Grumel, R. Arizaga, and M. Trivi, "Differentiation of the drying time of paints by dynamic speckle interferometry," *Progress in Organic Coatings*, vol. 64, pp. 350-355, 2009.
- [10] L. I. Passoni, A. L. Dai Pra, H. Rabal, M. Trivi, and R. Arizaga, "Dynamic Speckle Processing using Wavelets based Entropy," *Optics Communications*, vol. 246, pp. 219-228, 2004.
- [11] T. Kohonen, *Self-Organizing Maps*, 3^o ed. vol. 30. Heidelberg, New York: Springer, 2001.
- [12] A. Forti and G. L. Foresti, "Growing hierarchical tree SOM: an unsupervised neural network with dynamic topology," *Neural Networks*, vol. 19, pp. 1568-80, 2006.
- [13] J. Vesanto, "SOM-Based Data Visualization Methods," *Intelligent Data Analysis*, vol. 3, pp. 111-26, 1999.