

Image Feature Extraction Using Matrix Calculus Techniques: Applications in Texture Analysis and Pattern Recognition

Abstract—Feature extraction is a fundamental step in digital image processing, as it allows the transformation of high-dimensional visual information into compact and discriminative representations for pattern analysis. This paper proposes a feature extraction model based on matrix calculus and linear algebra techniques applied to digital images. The images are represented as numerical matrices, enabling the use of mathematical tools such as the Discrete Fourier Transform (DFT), the Discrete Cosine Transform (DCT), Singular Value Decomposition (SVD), Principal Component Analysis (PCA), and Globally Connected Matrices (GLCM). These methodologies allow the analysis of spectral, structural, and textural properties of the images, facilitating dimensionality reduction, redundancy elimination, and the identification of relevant patterns. The proposed methodology comprises stages of matrix representation, preprocessing, mathematical transformation, and extraction of numerical descriptors oriented toward texture analysis and pattern recognition. The results demonstrate that matrix computation techniques provide efficient representations of visual information, standing out for their mathematical interpretability, computational efficiency, and applicability to various computer vision and digital image processing problems.

Keywords—digital image processing, feature extraction, matrix computation, pattern recognition, texture analysis.

Extracción de Características de Imágenes mediante Técnicas de Cálculo Matricial: Aplicaciones en el Análisis de Texturas y Reconocimiento de Patrones

1^{er} Roger Ccama Alejo

*Departamento Académico de Ciencias Físico Matemáticas
Universidad Nacional del Altiplano
Puno, Perú
rccama@unap.edu.pe*

2^{do} Richar Marlon Mollinedo Chura

*Departamento Académico de Ciencias Físico Matemáticas
Universidad Nacional del Altiplano
Puno, Perú
rmollinedo@unap.edu.pe*

3^{er} Ruben Ticona Huayhua

*Departamento Académico de Ciencias Físico Matemáticas
Universidad Nacional del Altiplano
Puno, Perú
rticona@unap.edu.pe*

4^{to} Leonidas Vilca Callata

*Departamento Académico de Mecánica Eléctrica
Universidad Nacional del Altiplano
Puno, Perú
lvilca@unap.edu.pe*

Resumen—La extracción de características constituye una etapa fundamental en el procesamiento digital de imágenes, debido a que permite transformar información visual de alta dimensionalidad en representaciones compactas y discriminativas para el análisis de patrones. El presente trabajo propone un modelo de extracción de características basado en técnicas de cálculo matricial y álgebra lineal aplicadas a imágenes digitales. Las imágenes son representadas como matrices numéricas, lo que posibilita el uso de herramientas matemáticas como la Transformada Discreta de Fourier (DFT), la Transformada Discreta del Coseno (DCT), la Descomposición en Valores Singulares (SVD), el Análisis de Componentes Principales (PCA) y las matrices de co-ocurrencia (GLCM). Estas metodologías permiten analizar propiedades espectrales, estructurales y texturales de las imágenes, facilitando la reducción de dimensionalidad, la eliminación de redundancia y la identificación de patrones relevantes. La metodología propuesta comprende etapas de representación matricial, preprocesamiento, transformación matemática y extracción de descriptores numéricos orientados al análisis de texturas y reconocimiento de patrones. Los resultados evidencian que las técnicas de cálculo matricial proporcionan representaciones eficientes de la información visual, destacando por su interpretabilidad matemática, eficiencia computacional y aplicabilidad en diferentes problemas de visión por computador y procesamiento digital de imágenes.

Palabras Claves—análisis de texturas, cálculo matricial, extracción de características, procesamiento digital de imágenes, reconocimiento de patrones.

I. INTRODUCCIÓN

El procesamiento digital de imágenes se ha consolidado como una de las áreas más importantes dentro de la visión por computador y el análisis de información visual, debido a su amplia aplicación en campos como la ingeniería, medicina, biometría, teledetección y reconocimiento automático de patrones [5], [6], [8], [18], [21]. El crecimiento exponencial de datos visuales ha generado la necesidad de desarrollar métodos eficientes para representar, transformar y analizar imágenes digitales mediante modelos matemáticos y computacionales [7]. En este contexto, la extracción de características constituye una etapa fundamental, ya que permite transformar información visual de alta dimensionalidad en representaciones compactas y discriminativas. Estas representaciones facilitan tareas posteriores como clasificación, segmentación, análisis de texturas, descripción de formas y reconocimiento de patrones [1], [3], [4], [11]. Diversos estudios han demostrado que la calidad de las características extraídas influye directamente en el desempeño de sistemas de visión por computador y reconocimiento automático [2], [15]. Desde el punto de vista matemático, las imágenes digitales pueden modelarse como matrices numéricas, lo que posibilita la aplicación de herramientas de álgebra lineal y cálculo matricial para su procesamiento y análisis [7], [9], [13]. Este enfoque proporciona una base teórica sólida para representar información visual mediante transformaciones matemáticas, descomposiciones matriciales y métodos estadísticos orientados a la reducción de dimensionalidad y eliminación de redundancia [5], [10]. Entre las técnicas matriciales más utilizadas en el procesamiento digital de imágenes destacan la Transformada Discreta de Fourier (DFT), la Transformada Discreta del Coseno (DCT), la Descomposición en Valores Singulares (SVD) y el Análisis de

Componentes Principales (PCA). Estas metodologías permiten analizar propiedades espectrales, estructurales y estadísticas de las imágenes, facilitando la representación eficiente de la información visual y el reconocimiento de patrones [1], [2], [5], [11]. Asimismo, las matrices de co-ocurrencia (GLCM) permiten caracterizar propiedades texturales mediante descriptores estadísticos asociados a relaciones espaciales entre píxeles [3], [12]. La DFT ha sido ampliamente utilizada en análisis espectral y procesamiento frecuencial de imágenes debido a su capacidad para identificar componentes periódicos y estructuras repetitivas [5], [21]. Por otro lado, la DCT destaca por su eficiencia en compresión y representación compacta de información visual, siendo utilizada en diversos estándares de codificación de imágenes [21]. Asimismo, técnicas como SVD y PCA han demostrado una elevada capacidad para reducir dimensionalidad y conservar información relevante mediante aproximaciones matriciales eficientes [1], [2], [13]. El análisis de texturas y extracción de características mediante técnicas matriciales ha sido ampliamente aplicado en problemas de reconocimiento y análisis de imágenes digitales [3], [12], [15]. Asimismo, diversos estudios han demostrado que métodos basados en detección de bordes, análisis estructural y representaciones matriciales permiten identificar patrones relevantes dentro de imágenes complejas [14], [20]. Por otro lado, el avance de enfoques modernos basados en aprendizaje profundo y redes neuronales convolucionales ha impulsado nuevas estrategias para el procesamiento de información visual [16], [17], [19]. Sin embargo, las técnicas fundamentadas en cálculo matricial continúan siendo ampliamente utilizadas debido a su interpretabilidad matemática, estabilidad numérica y menor complejidad computacional, constituyendo herramientas eficientes para el análisis espectral, estructural y textural de imágenes digitales. El objetivo de este trabajo es desarrollar un modelo de extracción de características basado en técnicas de cálculo matricial y álgebra lineal para el análisis de texturas y reconocimiento de patrones en imágenes digitales. El enfoque propuesto integra metodologías como DFT, DCT, SVD, PCA y GLCM dentro de un marco unificado de procesamiento matemático orientado a la representación compacta y discriminativa de la información visual. La principal contribución de este artículo consiste en integrar diversas técnicas de cálculo matricial para el análisis espectral, estructural y textural de imágenes digitales, permitiendo obtener descriptores eficientes y matemáticamente interpretables. Los resultados obtenidos evidencian que las técnicas matriciales constituyen herramientas sólidas para la reducción de dimensionalidad, extracción de características y análisis de patrones en aplicaciones de procesamiento digital de imágenes y visión por computador.

MARCO TEÓRICO

A. Imagen digital

Una imagen digital puede definirse como una representación bidimensional de un objeto o escena del mundo real, obtenida a partir de un proceso de digitalización. Desde el punto de vista matemático, una imagen en escala de grises puede modelarse como una función discreta $f(x,y)$, donde x e y representan

las coordenadas espaciales y el valor de f corresponde a la intensidad luminosa en cada punto [9].




Fig. 1. Coordenadas espaciales empleadas en la representación de la imagen digital [9].

Los elementos básicos de una imagen digital son los píxeles, los cuales contienen información sobre la intensidad o color en una ubicación específica. En imágenes de 8 bits, los valores de intensidad suelen estar en el rango de 0 a 255, lo que permite representar diferentes niveles de gris [5].

x

y

0	1	1	2
7	6	6	5
6	0	4	0
5	5	1	2

Fig. 2. Imagen de 16 píxeles.

B. Representación matricial de imágenes

Las imágenes digitales pueden representarse como matrices de dimensiones $N \times M$, donde cada elemento corresponde a un píxel. Esta representación facilita la aplicación de técnicas de álgebra lineal y cálculo matricial para el procesamiento de imágenes [7].




Fig. 3. Representación de una imagen en formato Matriz [7].

El modelado matricial permite aplicar operaciones como transformaciones lineales, filtrado, descomposición y análisis

espectral, las cuales son fundamentales para la extracción de características y el análisis de patrones en imágenes digitales.

C. Extracción de características

La extracción de características es un proceso fundamental en el procesamiento de imágenes, cuyo objetivo es transformar la información visual en descriptores numéricos representativos. Estos descriptores permiten reducir la dimensionalidad de los datos y facilitar tareas como clasificación, reconocimiento y análisis de patrones [11]. Entre los tipos de características más relevantes se encuentran:

- Características de textura
- Características de forma
- Características estadísticas
- Características espectrales

En particular, el análisis de texturas se basa en la identificación de patrones espaciales y variaciones locales de intensidad, los cuales contienen información relevante para la discriminación de regiones dentro de una imagen [12]. Estas propiedades resultan fundamentales en aplicaciones de visión por computador, análisis biomédico, teledetección y reconocimiento automático de patrones.

D. Técnicas de cálculo matricial

Las técnicas de cálculo matricial constituyen una base sólida para la extracción de características en imágenes digitales. Estas metodologías permiten analizar la información visual desde diferentes perspectivas matemáticas, facilitando la identificación de patrones relevantes.

1) *Transformada Discreta de Fourier (DFT)*: La Transformada Discreta de Fourier permite representar una imagen en el dominio de la frecuencia, identificando patrones periódicos asociados a estructuras repetitivas en la imagen. Esta técnica es ampliamente utilizada en el análisis de texturas y filtrado de señales [5].

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)}$$

donde:

- $f(x, y)$ representa la intensidad de la imagen,
- $F(u, v)$ representa la representación frecuencial,
- u y v corresponden a las frecuencias espaciales.

La DFT permite identificar componentes de baja y alta frecuencia, asociadas a estructuras globales y detalles finos de la imagen.

2) *Transformada Discreta del Coseno (DCT)*: La Transformada Discreta del Coseno es una técnica que permite concentrar la energía de la imagen en un número reducido de coeficientes, facilitando la compresión y el análisis eficiente de la información visual [5]. Esta propiedad hace que la DCT sea ampliamente empleada en compresión de imágenes y reducción de redundancia.

La DCT bidimensional se expresa como:

$$C(u, v) = \alpha(u)\alpha(v) \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) \cos \left[\frac{(2x+1)u\pi}{2N} \right] \cos \left[\frac{(2y+1)v\pi}{2N} \right]$$

donde:

- $C(u, v)$ representa los coeficientes transformados,
- $\alpha(u)$ y $\alpha(v)$ son factores

La DCT permite compactar la energía de la imagen en bajas frecuencias, facilitando procesos de almacenamiento y análisis eficiente.

3) *Descomposición en Valores Singulares (SVD)*: La Descomposición en Valores Singulares descompone una matriz en componentes ortogonales, permitiendo identificar las estructuras más importantes de la imagen. Esta técnica es útil para la reducción de dimensionalidad y eliminación de ruido [5]. Esta metodología es utilizada en reducción de dimensionalidad, compresión y eliminación de ruido.

La SVD de una matriz A se define como:

$$A = U\Sigma V^T$$

donde:

- U y V representan matrices ortogonales,
- Σ contiene los valores singulares de la matriz.

La SVD permite aproximar una imagen utilizando únicamente los valores singulares más significativos, reduciendo la complejidad computacional sin perder información relevante.

4) *Análisis de Componentes Principales (PCA)*: El Análisis de Componentes Principales es un método estadístico que proyecta los datos en direcciones de máxima varianza, generando representaciones compactas y discriminativas. Esta técnica es ampliamente utilizada en tareas de reconocimiento de patrones [11]. Esta técnica es ampliamente utilizada en reconocimiento de patrones y reducción de dimensionalidad.

La transformación PCA puede expresarse como:

$$Y = W^T(X - \mu)$$

donde:

- X representa los datos originales,
- μ corresponde al vector media,
- W contiene los vectores propios,
- Y representa los datos transformados.

El PCA permite eliminar redundancia y conservar únicamente las características más representativas de la información visual.

5) *Matrices de co-ocurrencia (GLCM)*: Las matrices de co-ocurrencia permiten analizar la relación espacial entre píxeles en una imagen. A partir de estas matrices, se pueden obtener descriptores estadísticos como contraste, homogeneidad, energía y entropía, los cuales son fundamentales en el análisis de texturas [12]. A partir de estas matrices pueden obtenerse descriptores estadísticos utilizados en análisis de texturas.

Entre los descriptores más importantes destacan:

- Contraste
- Homogeneidad
- Energía
- Entropía

Estos parámetros permiten caracterizar propiedades texturales presentes en diferentes regiones de una imagen, facilitando procesos de clasificación y reconocimiento de patrones.

II. METODOLOGÍA

La metodología adoptada en este estudio sigue un enfoque analítico y matemático, orientado a la extracción de características en imágenes digitales mediante técnicas de cálculo matricial y álgebra lineal. El proceso metodológico permite transformar información visual de alta dimensionalidad en representaciones numéricas compactas y discriminativas para el análisis de texturas y reconocimiento de patrones. La metodología se estructura en cinco etapas principales: adquisición de imágenes, representación matricial, preprocesamiento, aplicación de transformaciones matemáticas y extracción de características.

A. Adquisición de imágenes

Para el desarrollo experimental se utilizaron imágenes digitales en escala de grises, imágenes naturales y imágenes de textura. Las imágenes presentan diferentes patrones espaciales, niveles de intensidad y variaciones texturales, permitiendo evaluar el comportamiento de las técnicas matriciales en diversos escenarios.

Las imágenes fueron normalizadas a dimensiones homogéneas con el objetivo de garantizar consistencia en el procesamiento y análisis matemático.

B. Representación matricial

Cada imagen digital fue modelada como una matriz numérica bidimensional, donde cada elemento representa la intensidad luminosa de un píxel. Esta representación constituye la base matemática para la aplicación de técnicas de álgebra lineal y transformaciones matriciales. La representación matricial de una imagen se expresa como:

Una imagen se modela como:

$$I(x, y) \in \mathbb{R}^{M \times N}$$

donde:

- M representa el número de filas,
- N representa el número de columnas,
- $I(x, y)$ corresponde al valor de intensidad del píxel.

El modelado matricial permitió aplicar operaciones de transformación, reducción de dimensionalidad y análisis espectral sobre la información visual.

C. Preprocesamiento de imágenes

En esta etapa se aplicaron técnicas de preprocesamiento orientadas a mejorar la calidad de las imágenes y reducir el efecto del ruido. Las operaciones realizadas incluyeron:

- Conversión a escala de grises
- Normalización de intensidad
- Filtrado para reducción de ruido
- Ajuste de contraste

El preprocesamiento permitió homogenizar las condiciones visuales de las imágenes, facilitando las etapas posteriores de extracción de características y análisis matemático.

D. Aplicación de técnicas de cálculo matricial

Una vez preprocesadas las imágenes, se aplicaron diferentes técnicas de cálculo matricial y análisis matemático con el objetivo de obtener descriptores representativos de la información visual. Se aplicaron:

• Transformada Discreta de Fourier (DFT)

La DFT fue utilizada para transformar las imágenes al dominio de la frecuencia, permitiendo identificar patrones periódicos y componentes frecuenciales asociados a estructuras texturales.

• Transformada Discreta del Coseno (DCT)

La DCT fue aplicada para obtener representaciones compactas de la información visual mediante la concentración de energía en coeficientes de baja frecuencia. La DCT permitió reducir redundancia y facilitar el análisis eficiente de las imágenes.

• Descomposición en Valores Singulares (SVD)

La SVD fue empleada para descomponer las imágenes en componentes ortogonales y conservar únicamente los valores singulares más representativos. Esta técnica permitió reducir la dimensionalidad de los datos y eliminar información redundante sin afectar significativamente las estructuras principales de la imagen.

• Análisis de Componentes Principales (PCA)

El PCA fue utilizado para proyectar los datos en direcciones de máxima varianza y generar representaciones discriminativas de menor dimensión. El análisis permitió identificar las componentes principales asociadas a las características más relevantes de la información visual.

• Matrices de co-ocurrencia (GLCM)

Las matrices de co-ocurrencia fueron utilizadas para analizar relaciones espaciales entre píxeles y extraer descriptores texturales estadísticos. A partir de la GLCM se calcularon parámetros como:

- Contraste
- Homogeneidad
- Energía
- Entropía

Estos descriptores permitieron caracterizar patrones texturales presentes en diferentes regiones de las imágenes.

E. Extracción de características

Las características obtenidas mediante las técnicas matriciales fueron organizadas en vectores numéricos representativos de la información visual. Estos vectores permitieron describir propiedades espectrales, estructurales y texturales de las imágenes, facilitando procesos posteriores de análisis y reconocimiento de patrones.

La extracción de características permitió reducir la dimensionalidad de los datos manteniendo la información relevante para la discriminación de patrones visuales.

III. RESULTADOS

Las técnicas de cálculo matricial aplicadas en este estudio permitieron obtener representaciones eficientes y discriminativas de la información visual presente en imágenes digitales. Los resultados obtenidos evidencian que las transformaciones matemáticas utilizadas facilitan el análisis espectral, estructural y textural de las imágenes mediante descriptores numéricos compactos.

Etapa 1: Imagen original

Imagen digital en escala de grises utilizada como entrada para el proceso de extracción de características: Características: Dimensión: 512 x 512 píxeles Profundidad: 8 bits Rango de intensidad:[0,255]



Imagen en escala de grises
512 x 512 píxeles

Fig. 4. Imagen original.

Etapa 2: Representación matricial

Etapa 2: Representación matricial

124	126	128	...	118	120
125	127	129	...	119	121
127	129	131	...	121	123
⋮	⋮	⋮	⋱	⋮	⋮
115	117	119	...	111	113
116	118	120	...	112	114

Matriz de intensidades (512 x 512)
Valores en el rango [0, 255]

Fig. 5. Representación matricial de la Imagen original.

Etapa 3: Preprocesamiento de la imagen original

La representación matricial de las imágenes permitió aplicar técnicas de cálculo matricial para la extracción de características. Como se muestra en la Fig. 6, la imagen es transformada en una matriz de valores numéricos, lo que posibilita el análisis mediante herramientas como la Transformada Discreta

de Fourier, la Transformada Discreta del Coseno, la Descomposición en Valores Singulares y el Análisis de Componentes Principales.




Fig. 6. Preprocesamiento de la imagen.

Los resultados obtenidos evidenciaron una adecuada separación entre componentes de baja y alta frecuencia. Las componentes de baja frecuencia concentraron la mayor parte de la energía de la imagen, asociándose a estructuras globales y regiones homogéneas, mientras que las altas frecuencias representaron bordes, detalles finos y variaciones abruptas de intensidad. El análisis espectral permitió identificar propiedades texturales relevantes y reducir el efecto del ruido mediante filtrado frecuencial.

Etapa 4.1: Transformada Discreta de Fourier (DFT)




Fig. 7. Transformada Discreta de Fourier (DFT).

Resultados mediante Transformada Discreta del Coseno (DCT) La Transformada Discreta del Coseno permitió obtener representaciones compactas de las imágenes mediante la concentración de energía en un número reducido de coeficientes.

Etapa 4.2: Transformada Discreta del Coseno (DCT)




Fig. 8. Transformada Discreta del Coseno (DCT)

Los resultados mostraron que la mayor parte de la información visual se concentró en coeficientes de baja frecuencia, permitiendo representar las imágenes con menor redundancia y alta eficiencia computacional. La DCT facilitó procesos de compresión y representación eficiente de la información visual,

conservando las características principales de las imágenes con una reducción significativa de dimensionalidad.

Resultados mediante Descomposición en Valores Singulares (SVD)

La aplicación de la Descomposición en Valores Singulares permitió descomponer las imágenes en componentes ortogonales y conservar únicamente los valores singulares más representativos.




Fig. 9. Descomposición en Valores Singulares (SVD)

Los resultados evidenciaron que una aproximación utilizando únicamente los valores singulares dominantes permitió reconstruir las estructuras principales de las imágenes conservando información relevante y reduciendo significativamente la complejidad de los datos. Asimismo, la SVD permitió disminuir el efecto del ruido y eliminar información redundante sin afectar considerablemente la calidad visual de las imágenes reconstruidas.

Resultados mediante Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales permitió proyectar la información visual en direcciones de máxima varianza, generando representaciones compactas y discriminativas.




Fig. 10. Análisis de Componentes Principales (PCA)

Los resultados obtenidos mostraron que las primeras componentes principales concentraron la mayor parte de la variabilidad de los datos, permitiendo reducir dimensionalidad y conservar las características más relevantes de las imágenes. La reducción de dimensionalidad facilitó el análisis de patrones y disminuyó el costo computacional asociado al procesamiento de imágenes de alta resolución.

Resultados mediante matrices de co-ocurrencia (GLCM)

Las matrices de co-ocurrencia permitieron obtener descriptores estadísticos asociados a propiedades texturales de las imágenes. Los parámetros calculados incluyeron:

- Contraste
- Homogeneidad
- Energía

Entropía




Fig. 11. matrices de co-ocurrencia (GLCM)

Los resultados evidenciaron que estos descriptores permitieron diferenciar regiones texturales con distintos niveles de variación espacial e intensidad luminosa. El contraste mostró sensibilidad a cambios abruptos de intensidad, mientras que la homogeneidad permitió identificar regiones uniformes y patrones repetitivos. La energía y la entropía facilitaron la caracterización estadística de las texturas, contribuyendo al reconocimiento de patrones y análisis estructural de las imágenes.

Análisis general de resultados

Los resultados experimentales demostraron que las técnicas de cálculo matricial permiten representar información visual mediante descriptores compactos y matemáticamente interpretables. Cada metodología analizada aportó propiedades específicas para el análisis de imágenes digitales:


- La DFT permitió analizar propiedades frecuenciales y estructuras periódicas.
- La DCT facilitó la compactación de energía y reducción de redundancia.
- La SVD permitió reducir dimensionalidad y reconstruir imágenes preservando información relevante.
- El PCA identificó componentes discriminativas asociadas a máxima varianza.
- La GLCM permitió caracterizar propiedades texturales mediante descriptores estadísticos.

En conjunto, estas técnicas proporcionaron herramientas eficientes para el procesamiento digital de imágenes, destacando por su interpretabilidad matemática, eficiencia computacional y aplicabilidad en problemas de análisis de texturas y reconocimiento de patrones.


Etapa 5: Vector de características extraídas

La etapa de extracción de características permitió transformar la información visual de las imágenes digitales en descriptores numéricos compactos y discriminativos mediante técnicas de cálculo matricial. A partir de las transformaciones aplicadas, se obtuvieron vectores de características asociados a propiedades espectrales, estructurales y texturales de las imágenes.


La Transformada Discreta de Fourier (DFT) permitió extraer componentes frecuenciales relacionadas con patrones periódicos y variaciones espaciales presentes en la imagen. Por otro lado, la Transformada Discreta del Coseno (DCT) permitió concentrar la energía de la información visual en coeficientes de baja frecuencia, generando representaciones compactas con menor redundancia.



Asimismo, la Descomposición en Valores Singulares (SVD) permitió identificar componentes dominantes de la información visual mediante valores singulares representativos, facilitando la reducción de dimensionalidad y eliminación de información redundante. El Análisis de Componentes Principales (PCA) permitió proyectar los datos en direcciones de máxima varianza, obteniendo características discriminativas asociadas a las estructuras más relevantes de las imágenes.



En el análisis textural, las matrices de co-ocurrencia (GLCM) permitieron obtener descriptores estadísticos como contraste, homogeneidad, energía y entropía, los cuales facilitaron la caracterización de patrones espaciales y relaciones entre píxeles. Estos descriptores permitieron diferenciar regiones con distintas propiedades texturales y estructurales.



Las características extraídas fueron organizadas en vectores numéricos representativos de la información visual, permitiendo reducir la dimensionalidad de los datos y facilitar procesos posteriores de análisis y reconocimiento de patrones. Los resultados obtenidos evidencian que las técnicas matriciales proporcionan representaciones eficientes, matemáticamente interpretables y computacionalmente adecuadas para el procesamiento digital de imágenes.

La Figura anterior muestra el proceso de construcción del vector final de características utilizado para el reconocimiento de patrones. En la parte izquierda se presentan los descriptores texturales obtenidos mediante la matriz de co-ocurrencia (GLCM), incluyendo parámetros estadísticos como contraste,

homogeneidad, energía y entropía. Estos valores representan propiedades espaciales y texturales presentes en la imagen digital. Posteriormente, dichos descriptores son integrados con las características obtenidas mediante técnicas matriciales como DFT, DCT, SVD y PCA, formando un vector concatenado de dimensión 410. En la gráfica del lado derecho, el eje horizontal representa el índice de las características extraídas, mientras que el eje vertical corresponde al valor numérico de cada descriptor. La variación observada en la señal refleja la diversidad de información espectral, estructural y textural contenida en la imagen. Este vector final constituye una representación matemática compacta y discriminativa de la información visual, utilizada en procesos de análisis y reconocimiento de patrones.

El vector final de características obtenido mediante técnicas matriciales puede utilizarse como entrada para sistemas de reconocimiento de patrones y clasificación de imágenes. Cada vector representa matemáticamente propiedades espectrales, estructurales y texturales de la imagen digital, permitiendo comparar similitudes y diferencias entre diferentes clases de patrones visuales.

IV. DISCUSIÓN

Los resultados obtenidos evidencian que las técnicas de cálculo matricial permiten representar información visual mediante descriptores compactos y matemáticamente interpretables, facilitando el análisis de patrones y texturas en imágenes digitales. La Transformada Discreta de Fourier (DFT) permitió identificar componentes frecuenciales y estructuras periódicas, mientras que la Transformada Discreta del Coseno (DCT) facilitó la compactación de energía y reducción de redundancia.

Asimismo, la Descomposición en Valores Singulares (SVD) y el Análisis de Componentes Principales (PCA) demostraron ser eficientes en la reducción de dimensionalidad, conservando las características más representativas de la información visual y disminuyendo la complejidad computacional. Por otro lado, las matrices de co-ocurrencia (GLCM) permitieron caracterizar propiedades texturales mediante descriptores estadísticos como contraste, homogeneidad, energía y entropía.

En conjunto, las técnicas matriciales presentaron ventajas importantes relacionadas con interpretabilidad matemática, estabilidad numérica y eficiencia computacional. No obstante, algunas metodologías pueden verse afectadas por ruido, variaciones de iluminación y pérdida parcial de información durante procesos de reducción dimensional. Los resultados obtenidos confirman la utilidad de las técnicas de cálculo matricial en aplicaciones de procesamiento digital de imágenes y reconocimiento de patrones.

V. CONCLUSIONES

Los resultados obtenidos evidencian que las técnicas de cálculo matricial permiten representar información visual mediante descriptores compactos y eficientes para el análisis de imágenes digitales. La Transformada Discreta de Fourier (DFT) permitió identificar componentes frecuenciales y patrones periódicos presentes en las imágenes, mientras que la

Transformada Discreta del Coseno (DCT) facilitó la compactación de energía y reducción de redundancia en la representación visual. Asimismo, la Descomposición en Valores Singulares (SVD) y el Análisis de Componentes Principales (PCA) demostraron ser eficientes en la reducción de dimensionalidad, conservando las características más representativas de la información visual y disminuyendo la complejidad computacional. Por otro lado, las matrices de co-ocurrencia (GLCM) permitieron caracterizar propiedades texturales mediante descriptores estadísticos como contraste, homogeneidad, energía y entropía. En conjunto, los resultados muestran que las técnicas matriciales proporcionan representaciones matemáticamente interpretables, eficientes y aplicables en tareas de análisis de texturas y reconocimiento de patrones en imágenes digitales.

REFERENCIAS

- [1] [1] I. T. Jolliffe and J. Cadima, "Principal component analysis: a review and recent developments," *Philosophical Transactions of the Royal Society A*, vol. 374, no. 2065, pp. 1–16, 2016.
- [2] M. Turk and A. Pentland, "Eigenfaces for recognition," *Journal of Cognitive Neuroscience*, vol. 3, no. 1, pp. 71–86, 1991.
- [3] R. M. Haralick, "Statistical and structural approaches to texture," *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786–804, 1979.
- [4] D. Zhang and G. Lu, "Review of shape representation and description techniques," *Pattern Recognition*, vol. 37, no. 1, pp. 1–19, 2004.
- [5] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 4th ed. Pearson, 2018.
- [6] R. Rodríguez, *Procesamiento digital de imágenes*. México: Alfaomega, 2013.
- [7] A. Rodríguez and H. Sossa, *Visión por computadora*. México: Alfaomega, 2012.
- [8] J. Leyva, M. Mejía, and R. Arce, *Procesamiento digital de imágenes*. México: Alfaomega, 2002.
- [9] N. Efford, *Digital Image Processing: A Practical Introduction*. Harlow, UK: Addison-Wesley, 2000.
- [10] E. Esqueda, *Procesamiento digital de imágenes usando MATLAB*. México: Alfaomega, 2002.
- [11] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York: Springer, 2006.
- [12] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural features for image classification," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 3, no. 6, pp. 610–621, 1973.
- [13] A. K. Jain, *Fundamentals of Digital Image Processing*. Englewood Cliffs, NJ: Prentice Hall, 1989.
- [14] M. A. Mobarhan et al., "A license plate detection algorithm using edge features," *Engineering Applications*, vol. 166, pp. 1–8, 2011.
- [15] M. Seul, L. O’Gorman, and M. J. Sammon, *Practical Algorithms for Image Analysis*. Cambridge: Cambridge University Press, 2000.
- [16] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [17] J. Singh and B. Bhushan, "Real-time Indian license plate detection using deep neural networks and optical character recognition," in *Proc. Int. Conf. Computing, Communication and Intelligent Systems*, 2020, pp. 347–352.
- [18] S. E. Umbaugh, *Computer Imaging: Digital Image Analysis and Processing*. Boca Raton, FL: CRC Press, 2005.
- [19] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception architecture for computer vision," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 2818–2826.
- [20] Y. Yuan, W. Zou, Y. Zhao, X. Wang, X. Hu, and N. Komodakis, "A robust and efficient approach to license plate detection," *IEEE Transactions on Image Processing*, vol. 26, no. 3, pp. 1102–1114, 2017.
- [21] W. K. Pratt, *Digital Image Processing*. New York: Wiley-Interscience, 2001.