

Caracterización de señales con técnicas de Inteligencia Computacional y Computación Granular

C.C. Ana Lucia DAI PRA

Universidad Nacional de Mar del Plata, Facultad de Ingeniería
Tesis del Doctorado en Ingeniería, orientación Electrónica

Directora: Lucia Isabel Passoni



RINFI es desarrollado por la Biblioteca de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata.

Tiene como objetivo recopilar, organizar, gestionar, difundir y preservar documentos digitales en Ingeniería, Ciencia y Tecnología de Materiales y Ciencias Afines.

A través del Acceso Abierto, se pretende aumentar la visibilidad y el impacto de los resultados de la investigación, asumiendo las políticas y cumpliendo con los protocolos y estándares internacionales para la interoperabilidad entre repositorios



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial-CompartirIgual 4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/).

Caracterización de señales con técnicas de Inteligencia Computacional y Computación Granular

C.C. Ana Lucia DAI PRA

Universidad Nacional de Mar del Plata, Facultad de Ingeniería
Tesis del Doctorado en Ingeniería, orientación Electrónica

Directora: Lucia Isabel Passoni

AGRADECIMIENTOS

Agradezco a los integrantes del Laboratorio de Bioingeniería por el compañerismo y el acompañamiento en mi trabajo, particularmente a mi directora, la Dra. Isabel Passoni.

Esta tesis simboliza el final de mi carrera profesional en la Universidad Nacional de Mar del Plata, en la que me desarrollé desde 1976. Agradezco a todos los que me acompañaron en la institución, en especial a mis compañeros, docentes, no docentes, investigadores y autoridades de la Facultad de Ingeniería, que fue mi segunda casa.

En recuerdo a mi esposo Jorge A Sikora, mi compañero de la vida y un apasionado de la docencia y la investigación

A mis hijos Pablo e Ignacio

INDICE

Introducción.....	6
Inteligencia Computacional.....	6
Computación granular.....	8
Procesamiento de señales.....	8
Objetivo y organización de la tesis.....	9
Referencias.....	9
Capítulo 1	11
La computación granular en el procesamiento de señales.....	11
1.1. Representaciones de Computación Granular Temporal.....	12
1.1.1 Granulación en el dominio de tiempo	12
1.1.2 Granulación espacial de fase.....	13
1.1.3 Granulación basada en densidad de la información	14
1.1.4 Granulación mediante clustering.....	14
1.1.5 Granulación basada en otros aspectos	15
1.2. Plataformas formales para la determinación de gránulos de información	16
1.3. Granularidad justificable	16
1.4 Conclusiones.....	18
1.5 Referencias	18
Capítulo 2	21
Propuesta para la caracterización de señales de <i>Speckle</i> Laser Dinámico mediante Granularidad Computacional.....	21
2.1 El fenómeno del DLS.....	21
2.2 Metodología GrC para caracterizar SSD.....	24
2.2.1 Determinación de conjuntos difusos (fuzzy sets) relativos a “intensidad”.....	25
2.2.2 Transformación a conjuntos rugosos- difusos (rough- fuzzy sets)	28
2.2.3 Formalización de la Granulación Temporal	29
2.2.5 Algoritmo FPGA	32
2.3 Metodología para procesamiento espacial	35
2.4 Conclusiones.....	36
2.5 Referencias	36
Capitulo 3	39
Análisis comparativo del descriptor granular TRFG con otros descriptores utilizados para <i>speckle</i> láser dinámico	39
3.1 Descriptores basados en análisis estadístico.....	40
3.1.1 Desviación Estándar (Standard Deviation - SD).....	40
3.1.2 Contraste Temporal (Temporal Contrast - TC).....	40

3.1.3 Autocorrelación (Full Width Half Maximum of the Autocorrelation - FWHMA).....	40
3.2 Descriptores basados en análisis de frecuencia	40
3.2.1 Energía de Banda Espectral (ESB).....	41
3.2.2 Relación Alta Baja frecuencia (High Low Ratio - HLR)	41
3.2.3 Frecuencia Media (Mean Frequency - MF)	42
3.2.4 Frecuencia de Corte (Cutoff Frequency - CF)	42
3.2.5 Entropía de Shannon (SE) del PSD.....	42
3.2.6 Entropía de la Transformada Discreta de Onditas (Discrete Wavelet Transform Entropy - DWTE)	42
3.3 Descriptores basados en el análisis de dominio de tiempo	44
3.3.1 Diferencias promedio (Averaged Differences - AD)	44
3.3.2 Diferencias Generalizadas (Generalized Differences - GD).....	44
3.3.3 Diferencias generalizadas ponderadas (Weighted Generalized Differences - WGD)	44
3.3.4 Resta promedio de intensidades consecutivas (Subtraction Average - SA).....	44
3.4 Comportamiento de los distintos descriptores.....	45
3.4.1 Descriptores estadísticos.....	45
3.4.2 Descriptores basados en análisis de frecuencia.....	45
3.4.3 Descriptores basados en el análisis de dominio de tiempo.....	46
3.4 Estudio comparativo	46
3.6 Conclusiones.....	49
3.7 Referencias	49
Capítulo 4	51
Aplicación de la técnica propuesta	51
4.1. Secado de pinturas	51
4.1.a. Secado de pinturas látex (dinámica estacionaria).....	52
4.1.b. Secado de esmaltes de secado rápido (dinámica no estacionaria)	54
4.1.c. Grosor de capas de pintura.....	56
4.2. Experiencias en muestras biológicas.....	58
4.2.a Viabilidad de semillas de maíz.....	58
4.2.b Segmentación de regiones en maíz	61
4.2.c Detección de golpes en manzanas	64
4.2.d TRFG utilizado para entrenar redes SOM	67
4.3 Ultrasonido	69
4.3.1. Ultrasonido en tumores oculares	69
4.2.2 Ecografías de pulmón	71
4.4 Otras muestras en videos.....	77
4.5 Conclusiones.....	78
4.6 Referencias	78
Conclusiones.....	82

Apéndice A.....	84
Abreviaturas utilizadas en orden alfabético.....	84
Apéndice B.....	86
Conjuntos.....	86
B.1 Conjuntos clásicos.....	86
B.2 Conjuntos difusos.....	86
B.2.1 Notaciones.....	87
B.2.2. Definiciones.....	89
B.3. Conjuntos rugosos o aproximados (rough sets).....	90
B. 4. Agrupamiento difuso FCM (<i>Fuzzy c-means</i>).....	92
B.5. Referencias.....	93
Apéndice C.....	95
Algoritmos.....	95
C.1. Algoritmo TRFG en Matlab.....	95
C.2. Algoritmo SRFG en Matlab.....	96

Introducción

Inteligencia Computacional

La Inteligencia Computacional (IC) es una rama de la Inteligencia Artificial (IA) basada en la aplicación del aprendizaje automático como un medio para resolver problemas complejos por medio de aproximación por aprendizaje de casos [1]. Muchas veces los términos IA e IC se utilizan indistintamente, aunque sus objetivos son diferentes, surgiendo desde la IC nuevos enfoques inspirados en la naturaleza que no coinciden con los principios de la IA. El enfoque clásico de la IA tiene una base simbólica, en cambio el enfoque de la IC trata de encontrar patrones inspirados en la naturaleza o biología, centrando sus esfuerzos en encontrar estrategias de adaptación y aprendizaje [2]. Básicamente las diferencias entre la IA clásica y la IC son:

- **La fuente de la representación.**

Mientras que la IA se basa en la representación del conocimiento de expertos en un cierto dominio, la IC extrae el conocimiento de datos disponibles. Sin embargo, ambas coinciden en que es el ser humano el que reconoce, interpreta o usa el conocimiento.

- **Los mecanismos para el procesamiento de la inteligencia.**

La IA utiliza métodos de razonamiento simbólico mientras que la IC está basada en métodos numéricos.

- **Las interacciones con el ambiente.**

La IA trata de ajustar el ambiente a las soluciones conocidas, representadas por bases de conocimiento, mientras que la IC utiliza diferentes metodologías, tradicionales y/o heurísticas para aprender del ambiente y crear conocimiento nuevo.

Según J. Bezdek, creador del término Inteligencia Computacional (IC), “un sistema es computacionalmente inteligente cuando solo trata con datos numéricos (bajo nivel), tiene un componente de reconocimiento de patrones y no hace uso del conocimiento en el sentido de IA y además, exhibe: adaptabilidad computacional, tolerancia a las fallas, velocidad de cambio que se adapta al comportamiento humano y tasas de error semejantes a las de un humano” [3]. En [4] Bezdek justifica su definición y la controvertida comparación con IA.

Desde la IC se comenzaron a desarrollar modelos y técnicas en el campo del aprendizaje automático o aprendizaje de máquina, tales como las redes neuronales, inspiradas en el conocimiento acerca del funcionamiento del sistema nervioso y la teoría del aprendizaje estadístico; modelos para la representación del conocimiento ambiguo y el pensamiento humano, caracterizados por la información vaga e imprecisa mediante un nuevo tipo de lógica, la lógica difusa; técnicas y algoritmos de computación evolutiva inspirados en los mecanismos de la evolución biológica (selección natural y deriva genética); técnicas inspiradas en comportamientos biológicos colectivos, como: las colonias de hormigas, los enjambres de abejas, las bandadas de pájaros, entre otros [5] [6].

La IC estudia problemas para los que los algoritmos tradicionales (estadísticos, matemáticos) no son efectivos, bien porque no es posible formularlos o porque requieren de tiempos de ejecución exponenciales. Parte de la investigación de IC está dedicada a funciones cognitivas de bajo nivel como: la percepción, el reconocimiento de objetos y patrones, el análisis de señales, el descubrimiento de estructuras de datos, control, clasificación y regresión, minería de datos. Los métodos desarrollados para este tipo de problemas incluyen los estudios supervisados y no supervisados por sistemas adaptables, y consideran también a los métodos probabilísticos y estadísticos, como las redes Bayesianas [7].

Las funciones cognoscitivas de más alto nivel que se requieren para solucionar problemas no-algoritmizables, que implican pensamiento sistemático, razonamiento, representación compleja del conocimiento, memoria episódica, planificación, comprensión del conocimiento simbólico son resueltos por la comunidad IA, que utiliza métodos basados en búsqueda, representación simbólica del conocimiento, razonamiento basado en marcos, sistemas expertos, aprendizaje de la máquina en dominios simbólicos, lógicas y métodos lingüísticos.

Todas las tareas que requieren el razonamiento basado en percepciones, tales como robótica, conducción automática de automóviles, sistemas autónomos, requieren métodos para solucionar tanto problemas de bajo como de alto nivel cognoscitivo, son motivo de reunión natural de la IA [8]

El objetivo de la IC es básicamente el desarrollo de software con el fin de resolver problemas prácticos, con capacidad para aprender y afrontar nuevas situaciones, a través de atributos del razonamiento tales como la generalización, el descubrimiento, la asociación y la abstracción, permitiendo descubrir nuevos patrones, relaciones y estructuras complejas. Factores claves que han contribuido al desarrollo de la IC son:

- Los problemas y cuestiones no resueltos por la matemática, las estadísticas y la IA tradicional.
- El rápido incremento de la potencia de las computadoras que ha favorecido la aplicación del aprendizaje de máquina, que al requerir de grandes recursos computacionales impedían progresar a grandes ideas para resolver problemas complejos del mundo real.
- La explosión de los datos, caracterizada por su volumen, variedad, cambio y ambigüedad, que ha dado origen a lo que actualmente se conoce como "big data".
- La tolerancia al conocimiento incompleto, impreciso e incierto, que facilita la obtención de soluciones aproximadas, manejables y robustas al mismo tiempo

La sociedad de IC del IEEE definió en sus inicios a la IC como redes neuronales, sistemas difusos y computación evolutiva, incluyendo inteligencia de enjambres. Sin embargo, en la bibliografía de IC son agregados diversos métodos, incluyendo problemas de la IA tradicional, siendo imposible dar una definición precisa [9]. La IEEE define a la IC como un campo en evolución, que además de los tres componentes principales, abarca paradigmas informáticos como inteligencia ambiental, vida artificial, aprendizaje cultural, redes endocrinas artificiales, razonamiento social y redes de hormonas artificiales. Y básicamente, el aprendizaje profundo que se ha convertido en el método central de la IA [10].

Más recientemente la IA generativa, un tipo de tecnología de IA que puede producir varios tipos de contenido, incluidos texto, imágenes, audio y datos sintéticos, se destaca por la simplicidad de nuevas interfaces de usuario para crear texto, gráficos y videos de alta calidad en cuestión de segundos.

Desde sus inicios, desde la IA se han estado creando herramientas para generar contenido mediante programación. Los primeros enfoques, conocidos como sistemas basados en reglas y más tarde como "sistemas expertos", utilizaron reglas explícitamente diseñadas para generar respuestas o conjuntos de datos. Las redes neuronales, que forman la base de gran parte de las aplicaciones de IC y aprendizaje automático actuales, cambiaron el problema. Diseñadas para imitar cómo funciona el cerebro humano, las redes neuronales "aprenden" las reglas para encontrar patrones en conjuntos de datos existentes. Desarrolladas en las décadas de 1950 y 1960, las primeras redes neuronales estaban limitadas por la falta de potencia computacional y pequeños conjuntos de datos. No fue hasta el advenimiento de big data a mediados de la década de 2000 y las mejoras en el hardware de la computadora que las redes neuronales se volvieron prácticas para generar contenido. El campo se aceleró cuando los investigadores encontraron una manera de hacer que las redes neuronales se ejecutaran en paralelo a través de las unidades de procesamiento de gráficos (GPU) que se

utilizaban para renderizar videojuegos. Las nuevas técnicas de aprendizaje automático desarrolladas en la última década, incluidas las redes generativas antagónicas (redes neuronales que compiten mutuamente) y los transformadores (modelos que no requieren el etiquetado de los datos), han sentado las bases para los recientes avances notables en el contenido generado por IA [11].

Computación granular

Sobre la base que para los seres humanos el conocimiento aún imperfecto puede ser muy valioso, es deseable que los computadores puedan trabajar también con tal conocimiento y no solo con el conocimiento exacto y cierto. Los medios en particular acertados que pueden manejar el conocimiento vago e incierto son los conjuntos difusos y las redes Bayesianas.

El conocimiento vago que puede proporcionar un experto humano o ser formulado intuitivamente por un sistema es formalizado con la ayuda de la lógica difusa y la teoría de conjuntos difusos. Los sistemas difusos pueden ser utilizados para realizar mecanismos de inferencia, acercándose así a métodos de razonamiento; generalmente son aplicados en la ingeniería de control porque en muchos casos la aplicación de un modelado exacto y completo del sistema es poco práctica o aún imposible. Dentro de las aplicaciones más comunes de los conjuntos difusos están, en un sentido amplio, los sistemas de control y el reconocimiento de patrones [12].

Un conjunto, como su palabra lo indica, es la agrupación de entes o elementos, que poseen una o varias características o atributos en común. Cuando la calidad de esos atributos no es precisa, surgen dudas si determinados elementos pertenecen o no a un conjunto, lo cual es común en cualquier aspecto de la vida real, requiriéndose del manejo de esos atributos en una forma más flexible de pertenencia.

El problema de la selección de atributos es uno de los campos de aplicación de la teoría de conjuntos difusos. Es importante en muchos enfoques de aprendizaje automático, en la reducción de datos de entrada para seleccionar solo aquellos atributos que son relevantes para una operación posterior, por ejemplo, clasificación o agrupación de aprendizaje automático [13].

La definición de conjuntos difusos lleva a particionar el rango de valores de un atributo mediante funciones de pertenencia cuya imagen podrá variar gradualmente de la verdad a la falsedad además de superponerse entre sí. Esas particiones conducen a lo que se denomina granularidad. Cada partición se denomina Gránulo de Información (GrI), que puede ir de lo particular a lo general [14].

El procesamiento con esos GrI es lo que se conoce como Computación Granular o Granularidad Computacional (GrC). Este tipo de procesamiento lleva a la reducción de complejidad, a la simplificación de procesos y por ende a la baja del costo computacional de procesos que pueden llegar a ser tediosos o imposibles debido al volumen de información, permitiendo diseñar prototipos rápidos y robustos.

Procesamiento de señales

Entre las aplicaciones de la computación granular, se destaca el procesamiento de señales, que conduce a: procesar señales sin consideraciones físicas, determinar patrones en las señales, lograr clasificación automática, eliminar medidas redundantes, encontrar relaciones entre los distintos tipos de señales, revelar características de interés y extraer conocimiento, entre otras alternativas. El análisis tiene por objetivo entender el contenido informativo de las señales a fin de aprovechar, mejorar, corregir o simplemente profundizar el conocimiento del fenómeno, proceso o evento que se estudia.

Para caracterizar las señales se suelen utilizar descriptores, los cuales son valores numéricos o etiquetas que se obtienen a partir de la extracción de características distintivas o atributos de la

señal representando solo algún rasgo significativo. Los descriptores se pueden usar para llevar a cabo tareas discriminatorias, predictivas o explicativas.

Objetivo y organización de la tesis

El objetivo de esta tesis es encontrar una metodología basada en GrC que permita encontrar descriptores que caractericen actividad en series de tiempo, minimizando el costo computacional. La inquietud surge del análisis de series de tiempo obtenidas en registros de experimentos realizados con rayos láser y el fenómeno que estos producen sobre objetos que presentan algún tipo de actividad, este fenómeno es conocido como *Laser Speckle* Dinámico. La hipótesis es que empleando GrC se pueden caracterizar las señales abstrayendo del motivo físico que la produce, logrando una metodología robusta y de rápido procesamiento.

La tesis está dividida en cuatro capítulos, cada uno de los cuales tiene sus propias referencias. El capítulo 1 es una revisión de la utilización de granularidad computacional para el tratamiento de series de tiempo. El capítulo 2 muestra la propuesta para la detección y caracterización de actividad en patrones de *speckle* dinámico, objetivo particular de esta tesis, tanto desde el punto de vista temporal como espacial. El capítulo 3 muestra un estudio comparativo de la metodología propuesta y otras metodologías que se han utilizado para afrontar el problema del *speckle* dinámico. El capítulo 4 presenta los resultados obtenidos con distintas muestras de *speckle* dinámico; en algunos casos se muestra la comparación con los resultados obtenidos con otros métodos. En este capítulo se aborda también la aplicación de la metodología a videos de ultrasonido para la detección de tumores y problemas pulmonares, y otros tipos de videos donde debe distinguirse actividad.

Referencias

- [1] Rudolf, Kruse et all. (2022). *Computational Intelligence - A Methodological Introduction* Third Edition. Springer Nature Suiza. 10.1007/978-3-030-42227-1.
- [2] Igulu K.T. Piah Z.P. & Asagba P.O. (2015). An Investigation into the Conceptual Controversies between Artificial Intelligence and Computational Intelligence. *Afr J. of Comp & ICTs*. 8(2). 115-120.
- [3] Bezdek J. C. (1994), What is Computational Intelligence? *Computational Intelligence Imitating Life*, ed. J. Zurada, B. Marks and C. Robinson, IEEE Press, Piscataway, 1- 12.
- [4] Bezdek J. C.(1998). Computational Intelligence Defined - by Everyone!, in *Computational Intelligence: Soft computing and Fuzzy-Neuro Integration with Applications*, eds. O. Kaynak, L. A. Zadeh, B. Turksen and I. J. Rudas, NATO ASI series F, 162, 10-37.
- [5] Pérez J. M (2010), *Inteligencia Computacional Inspirada En La Vida*. Ed: Servicio de Publicaciones de la Universidad de Málaga.
- [6] Haykin S. (2009), *Neural Networks and Learning Machines*. Pearson Prentice Hall. NJ.
- [7] Rozenberg, G., Bäck, T., Kok, J. N. (2012), *Handbook of Natural Computing*. Springer.
- [8] Engelbrecht, A. (2007), *Computational Intelligence: An Introduction*. Second Edition. John Wiley & Sons.
- [9] Duch W. (2007), What is Computational Intelligence and what could it become?, Duch W, Mandziuk J. Eds., Challenges for computational intelligence, Springer studies in *Computational intelligence* 63. 1-13.

- [10] <https://cis.ieee.org/about/what-is-ci>.
- [11] Lawton G., (2024), What is generative AI? Everything you need to know. TechTarget. <https://www.techtarget.com/searchenterpriseai/definition/generative-AI>.
- [12] Michels K., Klawonn F., Kruse R. and Nürnberger A. (2006), *Fuzzy Control: Fundamentals, Stability and Design of Fuzzy Controllers*. Springer-Verlag, Berlin/Heidelberg, Germany.
- [13] Paja W., Pancierz K., Pękala B. and Sarzyński J., (2021), Application of the Fuzzy Logic to Evaluation and Selection of Attribute Ranges in Machine Learning," *2021 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, Luxembourg, 1-6. doi: 10.1109/FUZZ45933.2021.9494515.
- [14] Zadeh L. A. (1997), Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic, *Fuzzy set syst.* 90, 111-127.

Capítulo 1

La computación granular en el procesamiento de señales

La Granularidad Computacional o *Granular Computing* (GrC) es un conjunto de conceptos y metodologías que surge a partir de la definición de conjuntos difusos. El término granularidad es nombrado en sus principios por el creador de las lógicas difusas Lotfi Zadeh, en “*Fuzzy sets*” en 1965 [1], luego fue evolucionando como él mismo lo menciona en su trabajo “*Towards a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic*” en 1997 [2]. La evolución fue compartida por varios investigadores convirtiéndose en una herramienta útil para el procesamiento de la información, siendo aplicada en gran parte al procesamiento de señales.

El objetivo de la GrC es la organización de la información en distintos niveles de conocimiento abstracto. La GrC es relativa a la definición de Gránulos de Información (GrI) y su procesamiento, incorporando tecnologías y formalismos existentes de la teoría de conjuntos. Los GrI son entidades formales que facilitan una forma de organizar y representar el conocimiento sobre los datos disponibles y las relaciones que existen entre ellos [3]. Básicamente un GrI es un subconjunto de la información con características particulares, generalmente abstractas. En el caso de datos temporales, la característica esencial es el ordenamiento de GrI en el tiempo.

Dentro del procesamiento de señales, el objetivo es la descripción de una manera semi-cualitativa señalando regiones específicas. En la mayoría de los casos, especialistas pueden interpretar señales de diagnóstico, monitoreo o comunicación, distinguiendo algunos segmentos e interpretando sus combinaciones para así evaluar el estado del sistema monitoreado. En todas estas situaciones, los fenómenos son granulados (no importa si son originalmente discretos o analógicos en su naturaleza) [4][5].

La aplicación de GrC para el análisis de señales es una técnica para explicar el comportamiento de problemas temporales que pueden ser representados como una serie de tiempo. La característica de estos modelos es la necesidad de reconocer el problema desde una visión basada en las expectativas del usuario.

La granulación como un mecanismo de abstracción de la información, permite enfocarse a rasgos esenciales e ignorar detalles irrelevantes en los datos. La calidad de tal abstracción está relacionada con la capacidad de conservar la esencia de los datos originales.

En [4], Gacek resalta las consideraciones a tener en cuenta en el análisis de señales:

- La descripción y clasificación de señales requiere de mecanismos no lineales que produzcan un conjunto de rasgos o descriptores de la señal, de modo que posean capacidades discriminatorias significativas.
- Es esperable que cualquier interpretación automatizada de señales sea fácil de usar y que los resultados de la clasificación / interpretación sean fácilmente comprensibles por un usuario humano que no necesariamente esté familiarizado con el procesamiento de señales.
- Las señales adquiridas son afectadas por ruido y pueden requerir de técnicas de filtrado avanzadas.
- La interpretación de las señales puede requerir de técnicas orientadas al conocimiento.

En el diseño de sistemas centrados en el usuario, es decir, donde se requiere que la respuesta sea comprensible por un usuario que no conoce de la tecnología de procesamiento de señales, se hace crucial desarrollar una comunicación eficiente de doble dirección con el usuario/experto.

La comunicación ayuda en la transferencia del conocimiento de dominio de un experto y de este modo, el diseño del sistema se hace más eficiente. Los resultados obtenidos por el sistema se ofrecen al usuario de un modo explícito y transparente.

Por lo tanto, es importante explotar un formalismo que esté cerca del modo en que la gente percibe, describe y comunica sus conclusiones. Es evidente que los datos y resultados numéricos por sí solos no son ni fácilmente ni naturalmente percibidos e interpretados por la gente. En cambio, los gránulos de la información (entidades de elementos que vienen con una semántica bien definida), elegidos adecuadamente dentro de un contexto, pueden ser considerados y manejados fácilmente. Los GrI pueden formarse en varios niveles de abstracción y de este modo el nivel más conveniente de detalle puede ser conducente al modelo más conveniente del fenómeno subyacente [5], además, la abstracción conveniente de un nivel de granularidad ayuda a reducir la alta complejidad computacional.

Un acercamiento intuitivo a la granulación de series de tiempo es definir ‘ventanas de observación’ y evaluar gránulos representativos dentro de cada ventana de la serie de tiempo. Esto puede ser formalizado como una representación de la serie de tiempo en intervalos definidos para caracterizar GrI individuales. La elección de la representación es el proceso fundamental para obtener buenos resultados.

1.1. Representaciones de Computación Granular Temporal

Diferentes representaciones de granulación son empleadas en el tratamiento de series de tiempo. En [6], Bargiela y Pedrycz proponen tres tipos distintos de representaciones como esquemas generales de granulación: granulación en el dominio de tiempo, granulación espacial de fase y densidad de la información basada en granulación. Pero puede ser necesario definir otros tipos de representación que mejor se ajusten a problemas particulares. Distintas técnicas de *clustering* también son consideradas en la definición de GrI.

1.1.1 Granulación en el dominio de tiempo

La granulación en el dominio de tiempo requiere de la definición de ventanas de observación, como en los métodos tradicionales de tratamiento de series de tiempo, y de la evaluación de una representación granular apropiada dentro de cada segmento de la serie de tiempo. Lo interesante de esta formalización proviene de fundamentos teóricos pero mantiene algunas dificultades de los métodos tradicionales, como ser sensibles al tamaño de la ventana de observación.

Considerando la segmentación de la señal en intervalos fijos, las Fig.s 1.1 a) a d) ilustran una simple granulación en el dominio de tiempo de dos series. Tales granulaciones pueden ser vistas como un mapeo de los datos originales $X = \{x_1, x_2, \dots, x_N\}$ en un conjunto de intervalos $I = \{I_1, I_2, \dots, I_G\}$ donde N es el número de elementos en la serie de tiempo y G es el número de gránulos.

En las Fig. 1.1 a) a d), tal como lo plantea Bargiela y Pedrycz en [6], cada gránulo es descrito por la gama de valores involucrados en un intervalo fijo, siendo el gránulo representado por *min x* y *max y*. La desventaja fundamental de este método es que es extremadamente sensible al tamaño del intervalo elegido. Si la ventana de observación está bien alineada con los límites de cambios significativos (Fig. 1.1 a) y 1.1 b)) será una buena abstracción de los datos originales, pero lo más probable es que la ventana incluya datos pertenecientes a distintos grupos generando gránulos grandes o poco representativos como en la Fig. 1.1 c) y d).

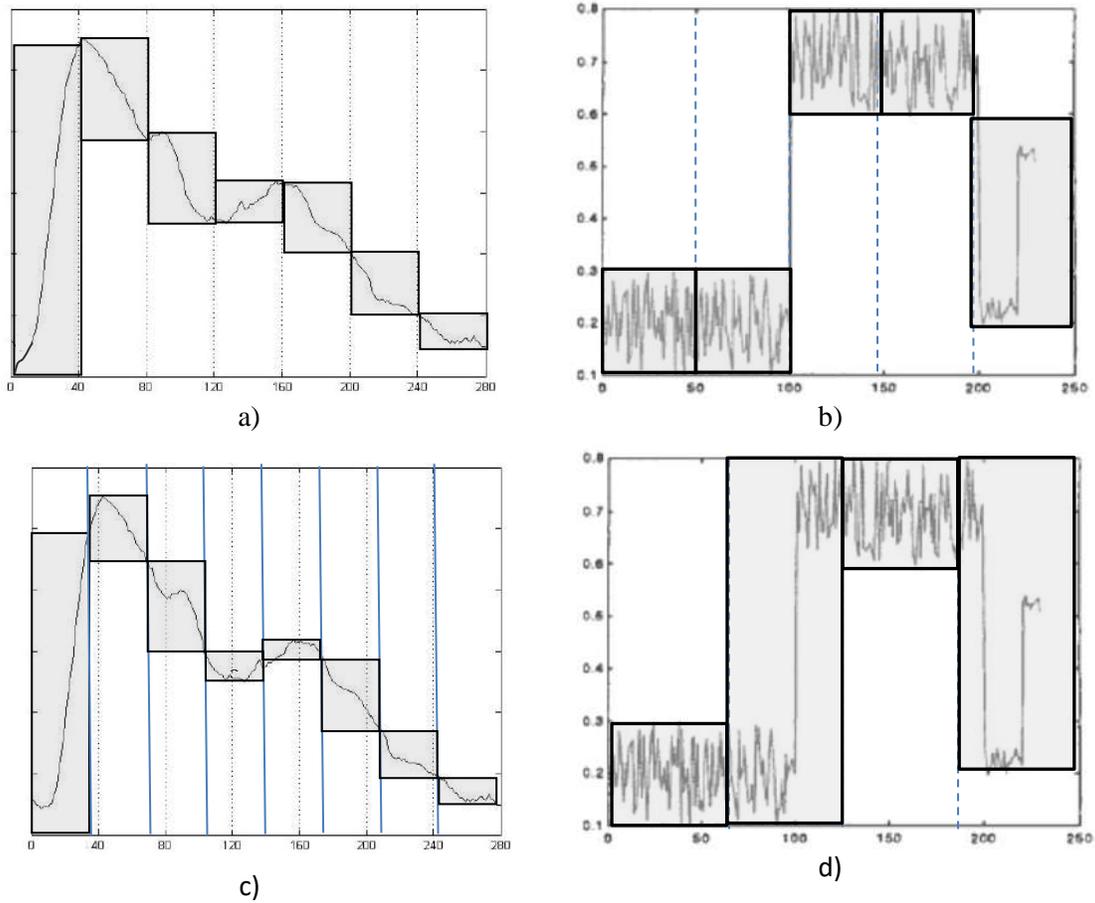


Fig 1.1. Gránulos definidos por $\min x$ y \max y de la señal en un intervalo fijo. a) y b) Gránulos indicando cambios significativos. c) y d) Gránulos poco representativos. (señal base en b) y d) extraída de [6])

En [7] Das et al. proponen un refinamiento de este método, que intenta encontrar patrones en una serie de tiempo para establecer reglas que definan el comportamiento, particularmente para el caso de series multivariadas. El método está basado en establecer intervalos, deslizarlos a través de toda la serie y luego aplicar clusterización para establecer similitudes. Este método puede ser muy costoso si la serie de tiempo es muy cambiante, siendo poco práctico para problemas de la vida real.

1.1.2 Granulación espacial de fase

Otro acercamiento es la granulación espacial de fase. La ‘forma’ de la sub-secuencia está definida por un rango de ángulos de gradiente entre el primer punto y todos los demás de la secuencia, como se muestra en la Fig. 1.2. Esto reduce el número de indicadores de la secuencia, pero la complejidad es similar a la de la granulación en el dominio de tiempo.

La granulación espacial de fase puede ser formalizada como un mapeo de los conjuntos de datos originales $X = \{x_1, x_2, \dots, x_N\}$ que componen la serie de tiempo en un conjunto de cajas $B = \{B_1, B_2, \dots, B_G\}$, donde N es el número de elementos en la serie de tiempo y G es el número de

gránulos, siendo cada gránulo definido en un intervalo por $\min x$, $\max x$ y el ángulo formado por el primer punto en el intervalo y el rango de gradientes al resto de los puntos en el intervalo $grads(x)$.

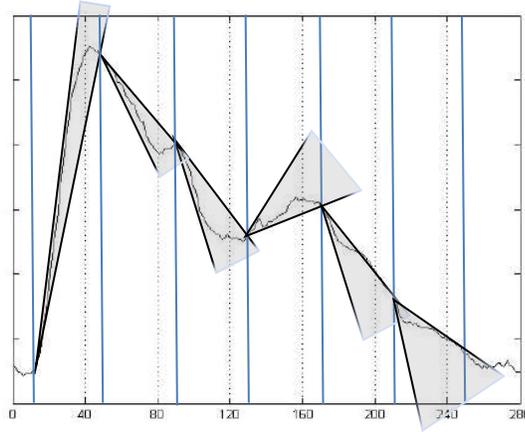


Fig. 1. 2. Ángulos dados por un punto inicial y el rango de gradientes al resto de los puntos dentro de un intervalo

1.1.3 Granulación basada en densidad de la información

En la definición de gránulos valorados por intervalos surge como el compromiso entre dos requerimientos conflictivos:

- i) El intervalo debería "abrazar" tantos elementos x_j como sea posible, definiendo la cobertura/cardinalidad ($card$), con $\chi_I(x_k) = \{1 \text{ si } x_k \in I, 0 \text{ en otro caso}\}$

$$card(I) = \sum_{x \in X} \chi_I(x_k), \text{ con } I = [a, b] \quad (1)$$

- ii) El intervalo debería ser sumamente específico. Esto traduce en el requisito de una longitud mínima del intervalo, definiendo la especificidad/ancho del intervalo (tam).

$$tam(long([a, b])) \quad (2)$$

El radio entre cardinalidad y especificidad $card/tam$, se adapta simultáneamente a la maximización de $card$ y a la minimización de tam . La optimización del radio se puede expresar como la maximización de la 'densidad de gránulos información', que debe distinguirse del concepto de 'densidad de datos' que es típicamente representado como una proporción de $card$ de un conjunto sobre el volumen del espacio que contiene a este conjunto.

1.1.4 Granulación mediante clustering

Aunque un *cluster* puede ser visto como un GrI, hay características que determinan el *cluster* y lo diferencian de un GrI. Necesariamente la clusterización está asociada a un método que debe determinar centros de cluster, a través de una función y un umbral de similaridad, mientras que el gránulo no requiere de ninguna de esas características. Ding et al. hacen una intrínseca conexión entre computación granular y análisis de *clusterización* [8], planteando las limitaciones de los métodos convencionales de clusterización ante datos dinámicos y complejos, donde se presenta falta de fiabilidad, inexactitud, e incoherencia, y mostrando que la granularidad es una herramienta que se adapta a ese tipo de información.

Tak-chung Fu [9] hace una revisión de las técnicas de minería de datos (data mining) para descubrir información oculta o conocimiento desde series temporales, mostrando que el descubrimiento de patrones es la tarea más común para ese propósito y el *clustering* es el método más habitual para encontrarlos. Otras tareas de extracción de datos de series temporales incluyen la clasificación, la minería de reglas (encontrar reglas que rijan las asociaciones y objetos causales entre conjuntos de ítems) y la *sumarización* (métodos que asignan los datos a conjuntos con descripciones asociadas, permitiendo extraer o derivar datos representativos de una base de datos y analizar conceptos).

Moller-Levet et al. [10] adoptan el algoritmo *fuzzy c-means* (FCM) [11] para series de tiempo cortas y agrupación de series de tiempo con puntos de muestreo no uniformemente espaciados. Proponen medir la similitud de series temporales cortas basadas en formas, dadas por el cambio relativo de amplitud y la información temporal.

Bargiela y Pedrycz [12] discuten la noción de datos granulares, desarrollan la granulación de información recursiva y acceden a la característica de los GrI a través de un agrupamiento de FCM, utilizando la *clusterización* como un medio para determinar el tamaño y especificidad de GrI.

1.1.5 Granulación basada en otros aspectos

Otra alternativa es, en lugar de valuar intervalos uniformes, particionar la serie de tiempo en intervalos caracterizados por rasgos determinados de los puntos que los integran sin importar su tamaño, de esta manera se desprecian pequeñas variaciones y los intervalos pueden ser cuantificados o evaluados por su tamaño o distribución.

- En la Fig. 1.3 a) se analiza el mismo gráfico de la Fig. 1.1 a), granulando la señal por el signo predominante de su diferencial, lo cual podría ser de utilidad para problemas particulares.
- En la Fig. 1.3 b) se analiza el mismo gráfico de la Fig. 1.1 c), granulando la señal por el rango de valores de la serie, lo cual, igual que en el caso anterior, podría ser de utilidad para problemas particulares.

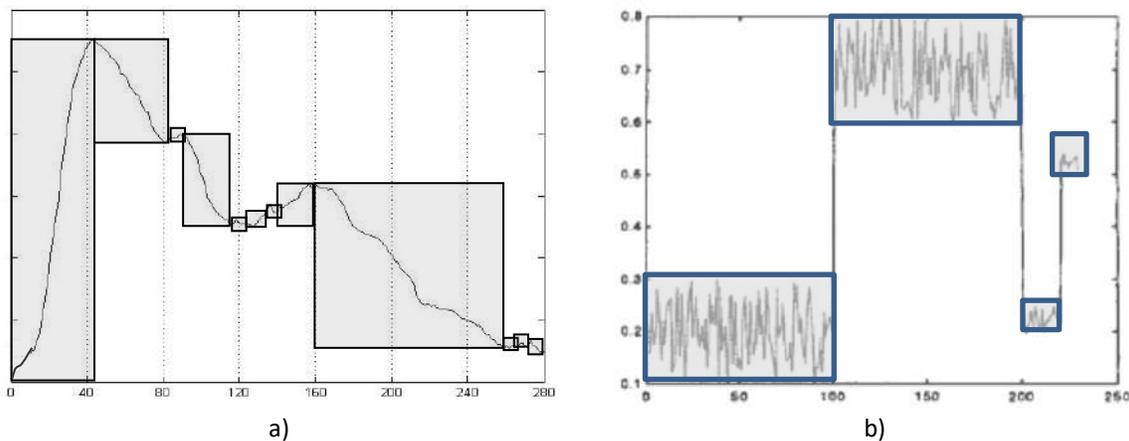


Fig. 1.3. a) Gránulos por signo de la diferencial, b) Gránulos por rango de valores

En ambos casos la distribución y tamaño de los gránulos pueden brindar información útil a la descripción de la señal, pero el criterio de granulación es dependiente del problema.

En [13][14][15][16][17] pueden verse distintos casos particulares de la utilización de granularidad en series de tiempo.

1.2. Plataformas formales para la determinación de gránulos de información

Gacek en [3] y [5] propone distintas plataformas formales para la definición de GrI, que en el caso de series de tiempo están vinculados a intervalos que reúnen distintas características:

- *Conjuntos tradicionales*: un elemento pertenece a un único conjunto [13].
- *Conjuntos difusos (fuzzy sets)*: ofrece una buena generalización por admitir pertenencias parciales y superpuestas [1].
- *Basados en probabilidades*: definidos por funciones de probabilidad o densidad probabilística, relativo a experimentación y ocurrencia de elementos [19].
- *Conjuntos rugosos (rough sets)*: enfatiza en la descripción de un concepto en término de la indiscernibilidad de sus atributos [20].
- *Conjuntos sombreados (shadowed sets)*: distingue entre elementos pertenecientes a un concepto, no pertenecientes y no totalmente reconocidos [21].
- *Conjuntos probabilísticos*: funciones de densidad probabilística sobre la pertenencia de elementos a un conjunto (de cualquier tipo).

Asimismo, un GrI puede involucrar varios formalismos, por ejemplo:

- *Probabilidades difusas*: conjuntos difusos y probabilísticos. Probabilidades cuyos valores son cuantificados en términos de conceptos difusos [22].
- *Conjuntos difusos rugosos y conjuntos rugosos difusos*: la relación de indiscernibilidad está formada por conceptos difusos o el conjunto difuso es descrito en términos de indiscernibilidad.

La granularidad temporal generalmente está asociada a conjuntos difusos y rugosos, lo cual crea una nueva complejidad que es la definición adecuada de esos conjuntos. La ventaja es que permiten niveles más altos de abstracción, con la consiguiente innovación de las metodologías aplicadas.

En la caracterización de señales mediante granularidad, un requisito previo a la realización de un procesamiento detallado, es la elección de la característica o atributo elegido para la granulación, que puede ser una abstracción o concepto particular que no necesariamente coincida con las características utilizadas habitualmente en el procesamiento de señales. Ello afectará a la eficiencia de los algoritmos, en particular influirá en la calidad de los clasificadores obtenidos construidos sobre la base de los GrI [3].

1.3. Granularidad justificable

En la búsqueda de una metodología de uso general para la granulación de series de tiempo se define el principio de granularidad justificable. Este principio se refiere a una forma coherente de diseñar GrI en presencia de evidencia experimental (ya sea de carácter numérico o granular) [13]; suele ser analizado desde el estudio de intervalos para elaborar alguna generalización [3][23].

Considerando los datos (evidencia experimental) como un conjunto de datos numéricos $D = \{x_1, x_2, \dots, x_N\}$, la definición de cada GrI es concerniente con la formación de un gránulo con información significativa, cumpliendo los dos requerimientos principales de:

- *Evidencia experimental*: La evidencia experimental en un GrI debe ser lo más alta posible. Se cuantifica por el número de datos que forman parte de un gránulo, puede ser relativo a una función de densidad probabilística o a cardinalidad

- *Significado semántico*: Debe ser tan específico como sea posible, con una semántica bien articulada (significado) diferenciable de otros GrI.

Al considerar la granularidad justificable, el diseño se asocia con un problema de optimización bien definido con los requisitos de evidencia experimental y especificidad, debido a que ambos requisitos suelen ser contrapuestos, ya que cuando más específico sea el concepto utilizado para definir un GrI menos cantidad de datos abarcará.

Gacek y Pedrycz en [23] y Pedrycz y Homenda en [13] proponen métodos para obtener gránulos temporales en una plataforma de conjuntos difusos para lograr una granularidad justificable. Plantean que un valor representativo en un intervalo numérico puede ser la media de los valores, para así determinar los extremos superior e inferior del conjunto difuso.

En [23], Gacek y Pedrycz proponen para la granular las series de tiempo, dividir la serie en ventanas del mismo tamaño y definir un conjunto difuso A para el espacio de amplitud en cada ventana. Para ello elige la mediana p de los puntos comprendidos como centro de una función de pertenencia triangular, o trapezoidal para los casos en que la mediana esté entre dos valores p y r . Las zonas creciente y decreciente las definen mediante rectas pendientes desde el núcleo (core) de la función de pertenencia al valor nulo, de modo de maximizar la suma de las pertenencias de los puntos que quedan involucrados, optimizando los valores a y b que determinan el soporte ($supp$) del conjunto difuso.

El valor a , se obtiene en el subintervalo k , maximizando la relación entre la evidencia experimental $\sum_k \mu_A(x_k)$, y la especificidad $|p - a|$. Fig. 1.4. Similarmente se obtiene el valor de b para el subintervalo l .

$$\max_a \left(\frac{\sum_k \mu_A(x_k)}{|p - a|} \right) \quad y \quad \max_b \left(\frac{\sum_l \mu_A(x_l)}{|r - b|} \right) \quad (3)$$

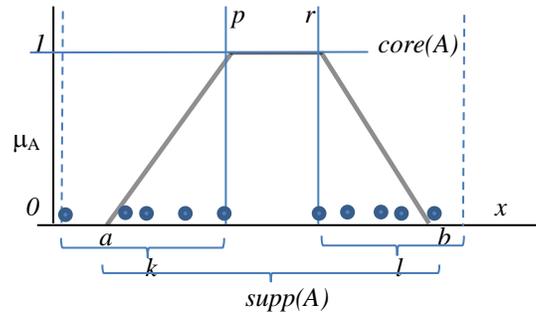


Fig 1.4. Optimización de una función de pertenencia

Similarmente Pedrycz y Homenda en [13], a partir del conjunto de datos D , evalúa la evidencia experimental de un GrI en un intervalo, cuantificando los datos dentro de sus límites. Determina la mediana del intervalo, y define los extremos a y b del primer intervalo Ω , para lo cual toma en consideración por un lado los elementos a la derecha de $med(D)$ y por otro lado los elementos a la izquierda de $med(D)$, $card\{x_k \in D / med(D) < x_k \leq b\}$ y $card\{x_k \in D / a \leq x_k < med(D)\}$

Luego define dos funciones, $f1$ y $f2$ para aplicar el Principio de Pareto o algún índice de maximización a $V(a)$ y $V(b)$, siendo:

$$\begin{aligned} V(b) &= f1(card\{x_k \in D / med(D) < x_k \leq b\}) * f2(|med(D) - b|) \\ V(a) &= f1(card\{x_k \in D / a \leq x_k < med(D)\}) * f2(|med(D) - a|) \end{aligned} \quad (4)$$

Define una función creciente $f1(u) = u$ como indicador de cardinalidad y una función $f2(u)=exp(-au)$ como indicador de especificidad. Y obtiene b_{opt} , maximizando $V(b)$ y a_{opt} maximizando $V(a)$. Si el valor de α es 0, el extremo del intervalo será el mayor o menor valor de D , si el valor de α es grande se obtendrán intervalos más específicos. Modificando $f1$ y $f2$ obtiene distintos tipos de optimización.

Otra propuesta que realiza Pedrycz y Homenda en [13], es utilizar un agrupamiento FCM (*Fuzzy C-means*) para determinar los centros de conjuntos difusos. Ambos casos generaran conjuntos dependientes del tamaño de las ventanas consideradas.

En [24], [25], [26] se utilizan otros procedimientos para para cumplir con el principio de granularidad justificable.

1.4 Conclusiones

Las personas naturalmente tienen capacidad para construir gránulos de la información, manipularlos y llegar a conclusiones adecuadas en distintos aspectos. Desde la perspectiva de la GrC se pueden describir algunas series de tiempo en una manera semi-cualitativa, señalando regiones específicas de tales señales. Los especialistas pueden interpretar, por ejemplo, señales diagnósticas biomédicas, distinguiendo algunos segmentos de tales señales e interpretando las combinaciones de esos segmentos. También pueden interpretar visualmente las lecturas temporales de sensores y evaluar el estado de un sistema monitoreado. La GrC, desde el punto de vista de la IC, trata de hacer uso de la capacidad humana de granular naturalmente la información.

Aunque la GrC ofrece la capacidad de traducir convenientemente un problema a la lengua de GrI, no está libre de limitaciones. La GrC posee ventajas claves manifestadas con respeto a la eficiente representación, transparencia e interpretabilidad del conocimiento; pero hay algunas limitaciones relativas a la falta de habilidades efectivas y a la naturaleza perceptiva de la construcción de gránulos.

Hasta el momento no se ha logrado una metodología general para la definición de GrI, ya que son dependientes de contexto, tanto desde el punto de vista de la estructura de los datos como desde el punto de vista del usuario.

1.5 Referencias

- [1] Zadeh L. A. (1965). Fuzzy sets. *Inform. Control* 8 338–353.
- [2] Zadeh L. A. (1970). Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic, *Fuzzy set syst.* 90 111-127.
- [3] Pedrycz W., Homenda W., Jastrzebska A. and Yu F. (2020). Information Granules and Granular Models: Selected Design Investigations, *2020 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, Glasgow, UK, 1-8, doi: 10.1109/FUZZ48607.2020.9177696.
- [4] Gacek A. (2013). Granular modelling of signals: A framework of Granular Computing. *Inf Sci* 221 1–11.
- [5] Gacek A. Signal processing and time series description: A Perspective of Computational Intelligence and Granular Computing. *Appl Soft Comput* 27 (2015) 590–601.
- [6] Bargiela, A., Pedrycz, W. (2003). Granulation of temporal data: A global view on time series. In, *IEEE Proc. 22nd International Conference of the North American Fuzzy Information Processing Society*, IEEE Press, New York 191-196.

- [7] Das, G. et al. (1998). Rule Discovery from Time Series. In proceedings of the *4th Conference on Knowledge Discovery and Data Mining*. 16-22.
- [8] Shifei D., Mingjing D., Hong Z. (2015). Survey on granularity clustering. *Cogn Neurodyn* 9 561–572.
- [9] Tak-chung F. (2011). A review on time series data mining. *Eng Appl Artif Intell* 24 164–181.
- [10] Moller-Levet C.S., Klawonn F., Cho K.H., Wolkenhauer O. (2003). Fuzzy clustering of short time-series and unevenly distributed sampling points. In: *Proceedings of the Fifth International Symposium on Intelligent Data Analysis* 330–340.
- [11] Bezdek J. C. (1981). Pattern Recognition with Fuzzy Objective Function Algorithms. Kluwer Academic Publishers Norwell, MA, USA.
- [12] Bargiela A., Pedrycz W. (2003). Recursive information granulation: aggregation and interpretation issues. *IEEE Trans Syst Man Cybern.* 33 (1) 96–112.
- [13] Pedrycz W., Homendad W. (2013). Building the fundamentals of granular computing: A principle of justifiable granularity. *Appl Soft Comput.* 13 (10) 4209-4218.
- [14] Min T., Yuanjian Z., Jianfeng X., and Yu L. (2015). Analysis and Modeling of Time Series Based on Granular Computing. *International Journal of Future Computer and Communication* 4 (2) 93-97.
- [15] Pedrycz W. (2002). Temporal granulation and its application to signal analysis, *In. Sci* 143 47-71.
- [16] Ruijun D., Pedrycz W. (2008). A granular time series approach to long-term forecasting and trend forecasting, *A: Stat Mech Appl* 387 (13) 3253–3270.
- [17] Pedrycz W., Wei L., Xiaodong L., Wei W., Lizhong W. (2014). Human-centric analysis and interpretation of time series: a perspective of granular computing. *Soft Comput.* 18 2397–2411.
- [18] Wei L. et al. (2014). The modeling of time series based on fuzzy information granules. *Expert Syst Appl* 41 3799–3808
- [19] George J. K. (2002). Basic Issues of Computing with Granular Probabilities . Data Mining, Rough Sets and Granular Computing. Ed: Tsau Young Lin, Yiyu Y. Yao, Lotfi A. Zadeh.. *Studies in fuzziness and soft computing* 95 339-349. Springer-Verlag Berlin Heidelberg.
- [20] Pawlak Z., Skowron A. (2007). Rudiments of rough sets, *Inf Sci*, 177 3–27
- [21] Pedrycz W. (2005). Granular Computing with Shadowed Sets. *International Workshop on Rough Sets, Fuzzy Sets, Data Mining, and Granular-Soft Computing. RSFDGrC 2005*. Lecture Notes in Artificial Intelligence 3641. Edited by J. G. Carbonell and J. Siekmann. Subseries of Lecture Notes in Computer Science. 23-32
- [22] Hirota K. (1977). Concepts of Probabilistic Sets. *Fuzzy Set Syst* 5 (1) 1361- 1366.
- [23] Gacek A., and Pedrycz W. (2006). A Granular Description of ECG Signals. *IEEE Trans Biomed Eng* 53 (10) 1972-1982.
- [24] Wang D, Liu Y, Yu Z. (2023). Synergistic Mechanism of Designing Information Granules with the Use of the Principle of Justifiable Granularity. *Mathematics* 11 (7) 1750. <https://doi.org/10.3390/math11071750>

- [25] Wang D., Hao L., Pedrycz W, Wenyan S., Hongxing L. (2022). Design Gaussian information granule based on the principle of justifiable granularity: A multi-dimensional perspective. *Expert Syst Appl* 197 116763
- [26] Kosheleva O. and Kreinovich V. (2018). Measures of Specificity Used in the Principle of Justifiable Granularity: A Theoretical Explanation of Empirically Optimal Selections, *2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)* 1-7, Rio de Janeiro, Brazil, , doi: 10.1109/FUZZ-IEEE.2018.8491648.

Capítulo 2

Propuesta para la caracterización de señales de *Speckle* Laser Dinámico mediante Granularidad Computacional

Como se vio en el Capítulo 1, hay distintas formas de percibir la granularidad de una señal, es una metodología totalmente dependiente del contexto y de la característica a destacar en la señal.

En esta tesis, la motivación de aplicar Granularidad Computacional (GrC) para la descripción de señales surge del estudio de lo que se conoce como *Speckle* Laser Dinámico (*Dynamic Laser Speckle* – DLS) y de la visión de su comportamiento desde la perspectiva de la IC.

En este capítulo se desarrolla:

En la sección 2.1 se da una simple descripción del fenómeno del DLS y la característica y obtención de las señales correspondientes.

En la sección 2.2 se explica la metodología temporal propuesta para la caracterización de las señales obtenidas del DLS, tipos de GrC a procesar y algoritmo aplicado.

En la sección 2.3 se muestra una propuesta para la aplicación de GrC espacial a un único patrón de DLS.

2.1 El fenómeno del DLS

El DLS es un fenómeno que ocurre cuando un rayo de luz coherente (láser) ilumina un objeto con una superficie que es rugosa en comparación con la longitud de onda, generando un patrón granular o “*speckle*”. Cuando el objeto iluminado presenta algún tipo de actividad, generalmente imperceptible al ojo humano, las pequeñas partículas superficiales se mueven y el *speckle* varía en el tiempo.

En la década de 1970, el DLS se convirtió en un tema de investigación. En particular, se estableció una conexión entre las fluctuaciones del patrón de *speckle* y el movimiento de los centros de dispersión en los organismos vivos, por ejemplo, el movimiento de los glóbulos rojos. En la década de 1980, este efecto se utilizó en una técnica fotográfica conocida como fotografía *speckle* desarrollada para estudiar el flujo sanguíneo en la retina. Aunque el método funcionó, la necesidad de procesar las fotografías antes de que se pudiera acceder a la información resultó ser un problema importante. Recién en la década de 1990, los nuevos métodos digitales permitieron el desarrollo de una versión en tiempo real del método, convirtiéndose en un método poderoso para registrar ciertos tipos de dinámicas [1].

El fenómeno actualmente puede ser capturado con cámaras CCD para que su comportamiento pueda ser analizado. Esta particularidad permite identificar algunos procesos químicos/biológicos sin realizar procedimientos invasivos. Las imágenes obtenidas en la secuencia se conocen como “Patrones de *Speckle*” (PS) y el estado de un mismo píxel a través de los PS genera las “Señales de *Speckle* Dinámico” (SSD). La Fig 2.1 muestra el setup óptico.

Detalles de la dinámica del *speckle* con teorías y aplicaciones pueden ser vistas en [2], donde se presenta por primera vez la computación granular.

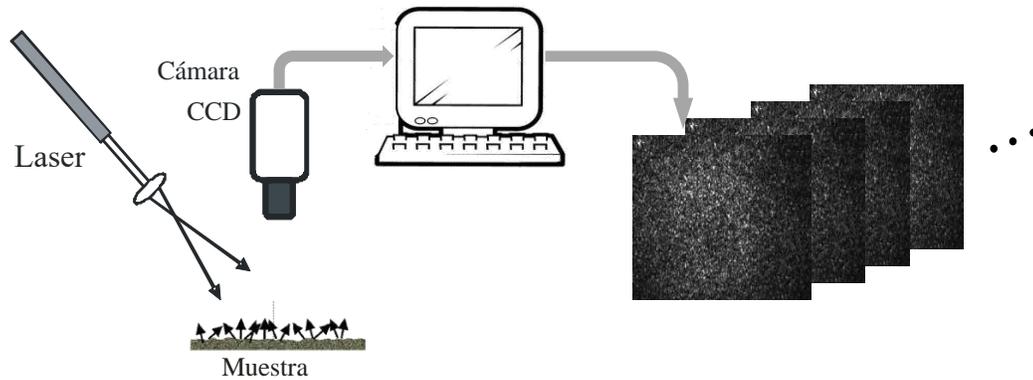


Fig. 2. 1. Setup óptico

Cuando los PS obtenidos se consideran relativamente homogéneos, como por ejemplo los obtenidos al evaluar una superficie pintada en forma pareja, para analizar la actividad, se crea un nuevo patrón denominado *Time History Speckle Pattern* (THSP), presentado por Arizaga et al. en [3]. El objetivo del THSP es mostrar la evolución de los PS y reducir la cantidad de SSD a procesar.

Para generar un THSP, se selecciona una determinada columna de píxeles de cada uno de los PS (ej: la ubicada en el centro de cada uno de ellos) y se compone un nuevo patrón colocando cada una de esas columnas en orden contiguo, siguiendo el orden temporal de la adquisición. Se obtiene así un patrón cuyo tamaño será cantidad de filas del PS original por la cantidad de PS obtenidos (Fig. 2.2).

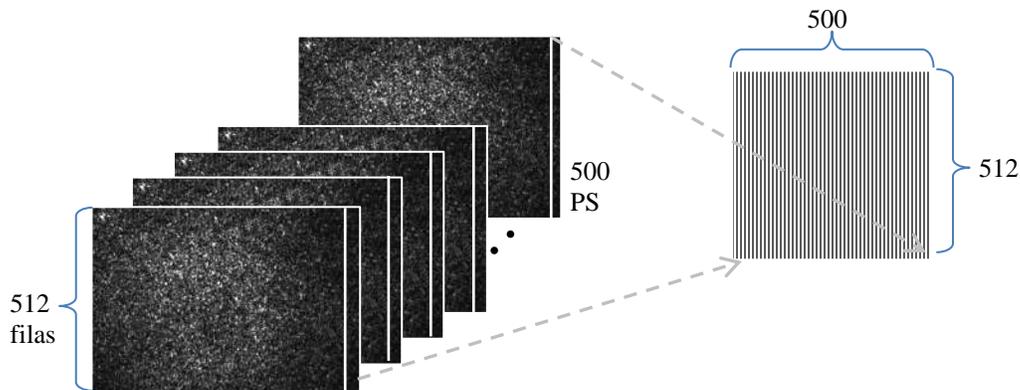
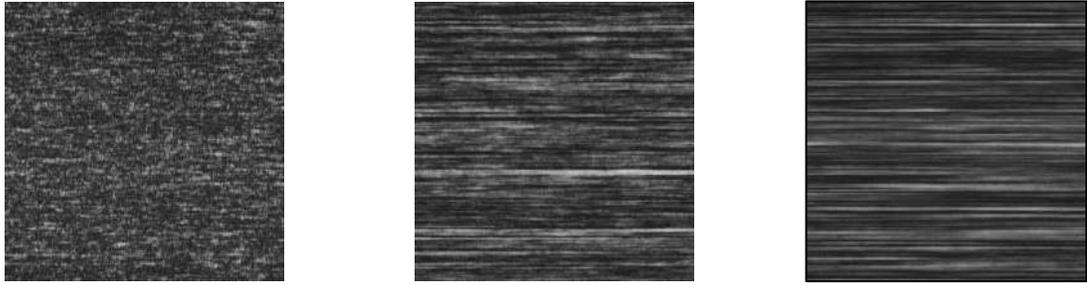


Fig. 2. 2 Formación de un THSP de 512x500 píxeles

Estos THSP visualmente dan una idea de la actividad en la muestra, la Fig. 2.3 muestra tres THSP correspondientes a distintos estadios de una superficie pintada que se va secando. Aunque los PS serán visualmente muy semejantes entre sí, esta forma de presentarlos permite visualizar cómo la actividad de cada píxel va disminuyendo, mostrando una tendencia a líneas más continuas.

Los valores de intensidad de cada fila del THSP constituyen una SSD que representa los cambios de intensidad de un píxel en el tiempo. Para obtener un descriptor de actividad, se pueden utilizar distintos métodos para procesamiento de señales, que serán descritos en el Capítulo 3. En el caso de los THSP, luego de obtener un descriptor individual para cada SSD, deberán ser promediados para obtener un resultado que indique la actividad estimada para la muestra.



a) THSP con variación temporal alta b) THSP con variación temporal media c) THSP con variación temporal baja

Fig. 2. 3 THSP con distinta variación temporal

En el caso de que la actividad se modifique durante el tiempo de captura de los PS, como en el caso de la Fig 2.4, resultante de una superficie pintada con un esmalte de secado rápido, el THSP mostrará una textura cambiante. En ese caso, deberían obtenerse descriptores en lapsos más cortos de tiempo, acá es de importancia que la metodología empleada muestre resultados satisfactorios en SSD cortas. Los métodos tradicionales para obtener descriptores en una señal suelen requerir de una gran cantidad de PS para mostrar los resultados esperados.

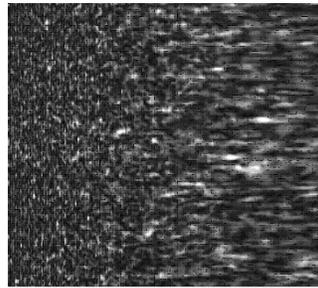


Fig. 2. 4 THSP variando en el tiempo (esmalte de secado rápido)

Cuando los PS no correspondan a una superficie homogénea, sino a una muestra en la que se presenten distintos tipos de actividad y el objetivo sea obtener una imagen que muestre una segmentación de regiones con distinto grado de actividad, habrá que analizar cada uno de los píxeles de los PS individualmente y luego recomponer una imagen (“imagen de actividad”) donde cada píxel corresponda al descriptor resultante (Fig. 2.5).

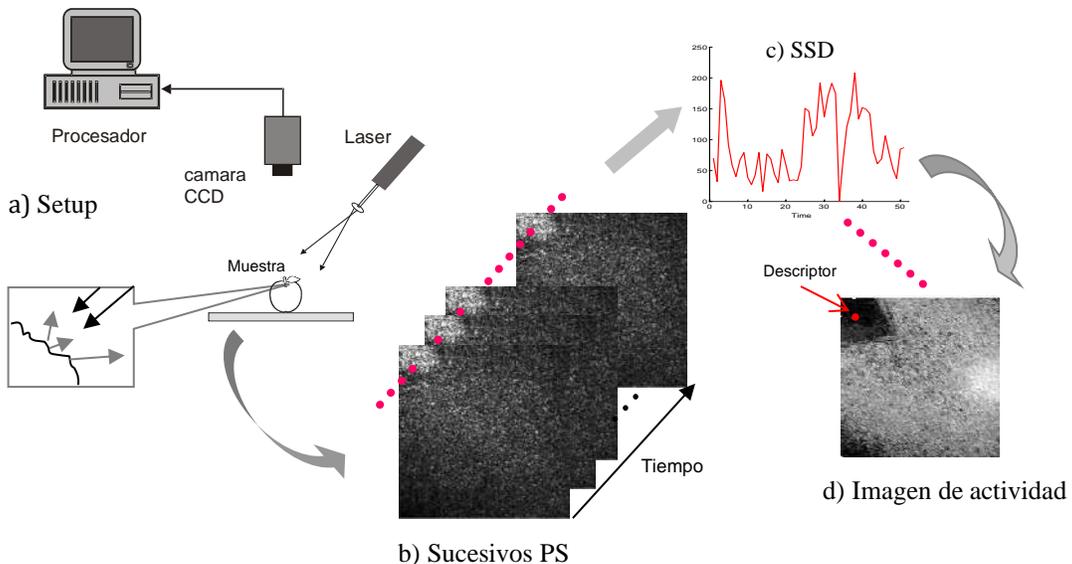


Fig. 2. 5 Generación de una imagen de Actividad

2.2 Metodología GrC para caracterizar SSD

La idea principal de esta nueva metodología es procesar las SSD, abstrayéndose de la justificación física que subyace al fenómeno de *speckle* y prescindiendo de las metodologías tradicionales de procesamiento de señales, intentando representar la actividad desde el punto de vista de la percepción humana (o computación granular), procurando efectuar un procesamiento rápido y eficiente.

La aplicación de GrC al fenómeno *speckle* surge desde la visión natural de cómo se percibe el fenómeno. Al observar una secuencia de PS como un video, puede observarse como una imagen de televisión fuera de sintonía con puntos brillosos que cambian permanentemente de intensidad; se ha comprobado que un cambio más rápido de intensidad está asociado a una actividad más alta en el objeto en observación.

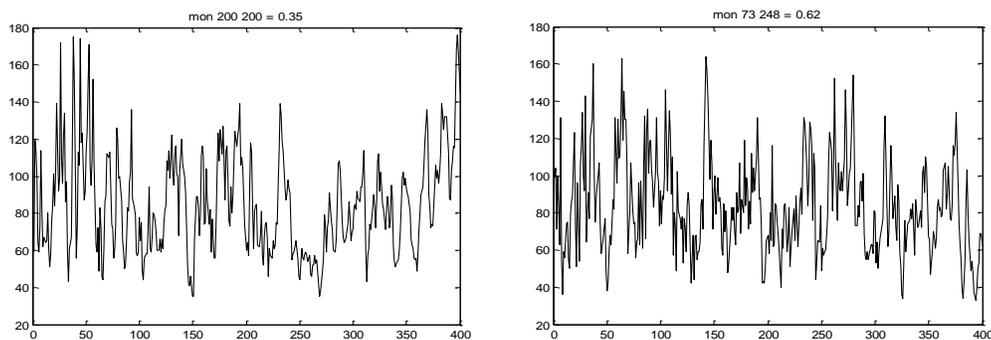


Fig. 2.6 SSD de una misma muestra con distinta actividad

Las SSD aparentan tener un comportamiento aleatorio difícil de caracterizar; poder cuantificar esa actividad sería un descriptor útil en una gran variedad de casos. La Fig.2.6 muestra dos SSD arbitrarias, identificadas mediante GrC con valores de 0,35 y 0,62 respectivamente en [0,1]. Aunque muchos descriptores basados en procesamiento de señales han sido desarrollados para caracterizar las SSD [1], no todos ellos han sido adecuados para todas las muestras y no hay aún un criterio definido sobre cuál podría ser la mejor opción.

El hecho de procesar señales no estacionarias lleva a cálculos tediosos que no necesariamente por ser cuidadosos y detallistas muestran un resultado claro. El poder simplificar la señal reduciendo la complejidad podría mejorar los resultados, a tales efectos se suelen utilizar filtros para atenuar las variaciones, sin embargo, en ciertas ocasiones estos filtros pueden distorsionar la esencia de la señal. En el caso particular de las SSD no está claro aún cual sería el detalle para destacar o atenuar para elegir un filtro adecuado.

Si se pudiese fijar la vista en un solo píxel de un video de PS, lo que observaría es un cambio de intensidad del píxel, sin poder evaluar el valor exacto de intensidad, ni el tiempo que permanece en la misma. A lo sumo se podría decir, si se pudiese observar en cámara lenta, ‘está brillante’, ‘está oscuro’, ‘está más o menos’, ‘cambia rápido’ o ‘permanece casi igual’. Con este criterio y desde el punto de vista de la GrC, surge la idea de considerar como GrI secuencias de valores de intensidad ‘semejantes’ y utilizar la cuantificación de esos gránulos como un descriptor de actividad.

Los conjuntos difusos se consideran adecuados para determinar valores de intensidad semejantes, ya que son conceptos vagos con límites indefinidos. Con el objetivo de aplicar GrC a cada señal, se busca definir conceptos difusos relativos a los valores de intensidad para determinar los GrI correspondientes.

2.2.1 Determinación de conjuntos difusos (fuzzy sets) relativos a "intensidad"

Los conjuntos difusos se caracterizan a diferencia de los conjuntos clásicos porque sus elementos pueden tener valores de pertenencia intermedios entre verdadero y falso, es decir permiten establecer relaciones más naturales en la definición de un concepto subjetivo, como por ejemplo el brillo en una imagen de intensidad

Formalmente Zadeh, en [4], es quien establece la definición de conjuntos difusos y propone en [5] el concepto de granularidad. Basicamente, un conjunto difuso está definido dentro de un universo U determinado y el valor de verdad de la pertenencia de un elemento $i \in U$ a un conjunto difuso A , está dado por una función $\mu_A(i)$ con imagen en $[0,1]$.

Siendo U los valores de intensidad, $U = \{i / i \in [0,255]\}$, un PS puede ser visto como una matriz, con valores $\in U$. Una secuencia de PS puede ser vista como una hipermatriz de tres dimensiones (x, y, z) , con x e y dados por el tamaño del PS, siendo z la cantidad de PSs obtenidos en una muestra. Cada SSD tiene longitud z y corresponde a una posición (x,y) , Un THSP corresponde a una hipermatriz (x, j, z) , $j < y$.

Desde la teoría de GrC formalizada por Pedrycz en [6] y Pedrycz y Homendad en [7], la determinación de los GrI debe ser realizada considerando el principio de granulación justificada, dada por una adecuada cobertura y especificidad. Es decir, que el concepto que va a definir cada gránulo debe cubrir la mayor cantidad de datos posibles, pero a la vez especificar claramente a qué se refieren. Siendo la plataforma formal elegida para la determinación de GrI, los conjuntos difusos relativos al brillo del píxel, para la variable *intensidad*, una *buena cobertura* debe requerir de pocos conjuntos, pero lo *suficientemente específicos*.

A partir de métodos heurísticos, se establecen entonces tres conjuntos difusos, buscando rangos de cobertura representativos en función de la intensidad de una muestra en particular. Los conceptos considerados para la definición de los conjuntos difusos relativos a intensidad son *claro*, *mediano* y *oscuro*.

A los efectos de establecer una adecuada definición de los conjuntos difusos, se considera que los conceptos elegidos deben ser igualmente distinguibles. La definición de un conjunto difuso está asociada a una función de pertenencia $\mu(i)$ que establece, para rangos de valores en U , un grado de pertenencia total o parcial, que puede superponerse con el de otros conjuntos definidos en el mismo U . Es necesario entonces definir las funciones $\mu_{claro}(i)$, $\mu_{mediano}(i)$ y $\mu_{oscuro}(i)$. Se parte de funciones de pertenencia trapezoidales, por ser las más simples de procesar. Luego de diversas pruebas para obtener la mejor distribución en U de los tres conjuntos planteados, se observó que, en general, los resultados más satisfactorios se producían cuando aplicando las funciones de pertenencia a cada uno de los elementos $i = PS(x,y)$, la suma de los $\mu_c(i)$ para cada conjunto $c = \{claro, mediano, oscuro\}$ era similar (Eq.1).

$$\sum_{i \in PS} \mu_{claro}(i) \approx \sum_{i \in PS} \mu_{mediano}(i) \approx \sum_{i \in PS} \mu_{oscuro}(i) \quad (1)$$

Dada la característica observada y con el objetivo de encontrar en forma automática los parámetros de las $\mu_c(i)$ que definan los distintos conceptos c , se construye un histograma de intensidades de un PS, con frecuencias $h(i)$ con $i=0$ a 255 y se establecen 5 regiones R_j tal que:

$$R_j \approx \sum_{i=0}^{255} \frac{h(i)}{5}, \quad j = 1, \dots, 5 \quad (2)$$

Determinándose 4 valores i que delimitan 5 regiones en $[0,255]$ que serán utilizadas como parámetros de las funciones $\mu_c(i)$. Las regiones R_1 , R_3 y R_5 determinan valores $\mu_c(i) = 1$ para cada conjunto. Las regiones R_2 y R_4 corresponden a las regiones solapadas *claro - mediano* y *mediano - oscuro* respectivamente, en estos casos los valores de los $\mu_c(i)$ son distribuidos linealmente para cumplir con la Eq.(1).

Resultados similares podían ser obtenidos aplicando FCM (ver apéndice B), pero en comparación este proceso es más lento, requiere de parámetros de superposición y da como resultados puntos centrales para cada concepto que deberían ser extendidos a intervalos.

La Fig. 2.7 representa el objetivo buscado para una señal arbitraria a partir de los parámetros de las $\mu_c(i)$ obtenidas con la Eq. (2). Se comprobó además, que para los PS de una misma muestra, el histograma es bastante similar, por lo tanto, para determinar la distribución de los conjuntos difusos se estableció que era suficiente analizar un único PS de la secuencia.

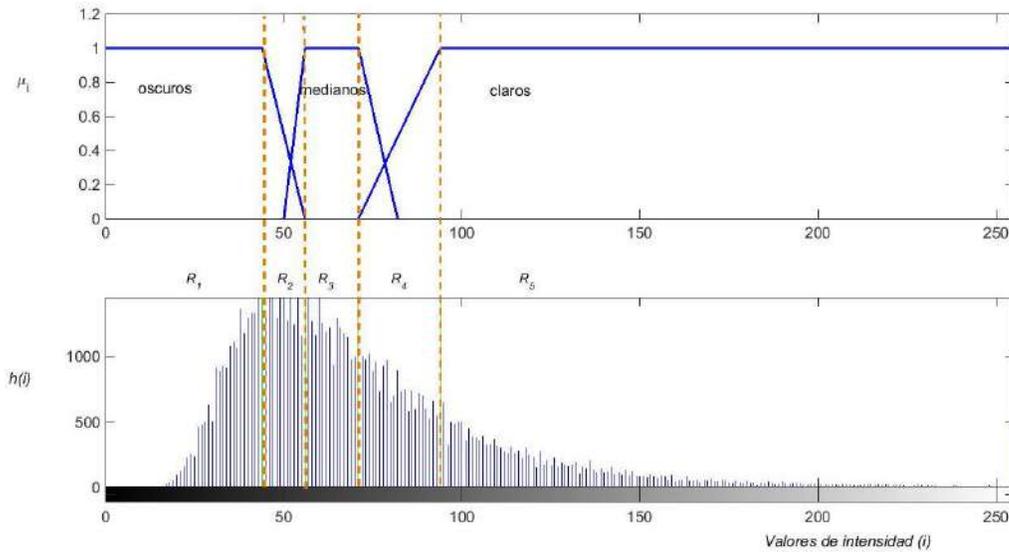


Fig. 2.7 Determinación de conjuntos difusos a partir de histograma de intensidades

El método de granulación elegido consiste en transformar cada SSD en un conjunto de gránulos que permita un nuevo y más simple análisis de la señal. Cada gránulo es definido como una sucesión continua de valores pertenecientes al soporte (*supp*) de un mismo concepto o conjunto difuso, siendo:

$$supp c (x) = \{x \in U, \mu_c(x) > 0\} \quad (3)$$

Cada gránulo puede superponerse total o parcialmente con otro gránulo perteneciente a otro conjunto, como puede observarse en la Fig. 2.8. La característica de la GrC permite desentenderse de la precisión numérica que en una SSD es muy variable, condicionando la efectividad de algunos métodos de procesamiento de señales, Siendo a la vez posible realizar una granulación tipo 2 que permita analizar cada gránulo.

Como el objetivo del análisis de los PS es determinar el grado de actividad en cada SSD, se define como valor del descriptor de actividad a un valor Q_T que representa la cuantificación relativa de gránulos en un tiempo T , siendo Gr_c el conjunto de gránulos pertenecientes a un concepto c .

$$Q_T = \left(\sum_T Gr_{claros} + \sum_T Gr_{medianos} + \sum_T Gr_{oscuros} \right) / T \quad (4)$$

En la señal ejemplificada en la Fig. 2.8, se pueden identificar 4 gránulos claros, 10 medianos y 8 oscuros, resultando un total de 22 gránulos. De acuerdo a la Eq. (4), considerando 51 puntos, el índice de actividad $Q_T = (4+8+10)/51 = 0.43$.

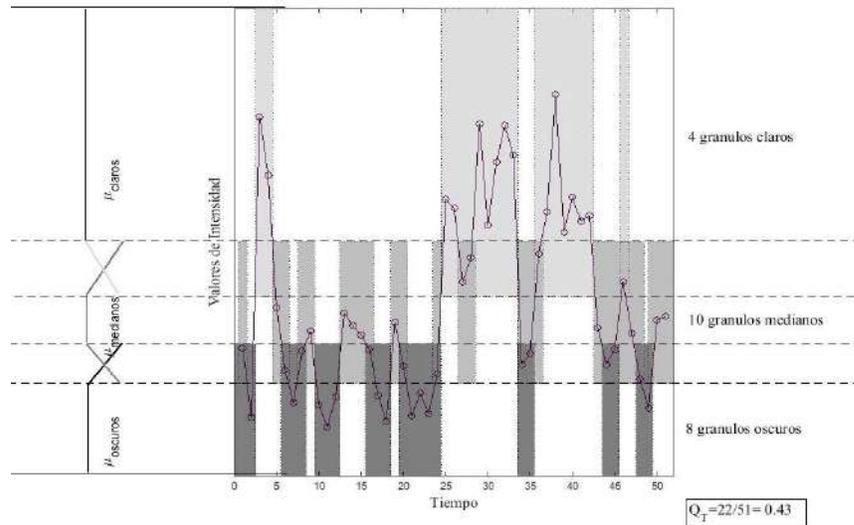


Fig.2.8 Granulación de una señal arbitraria

Esta granulación actúa como un filtro al ignorar las pequeñas variaciones, marca las variaciones significativas de amplitud al cortarse las secuencias y las variaciones medias se mantienen en secuencias de conjuntos adyacentes. La Fig. 2.9 muestra resultados obtenidos con distintas señales, estudio publicado en [8]. La Fig. 2.10 muestra una SSD procesada en forma continua, es decir evaluándose en cada instante; en este caso los valores permanecen relativamente uniformes debido a que se promedian en cada instante para el total de las instancias, en señales largas es conveniente evaluar los gránulos utilizando ventanas deslizantes de menor tamaño.

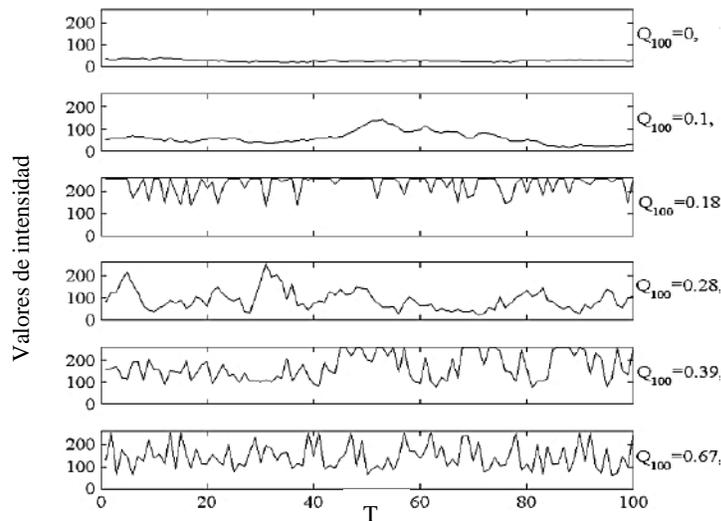


Fig. 2.9 Grado de actividad Q_T en distintas señales

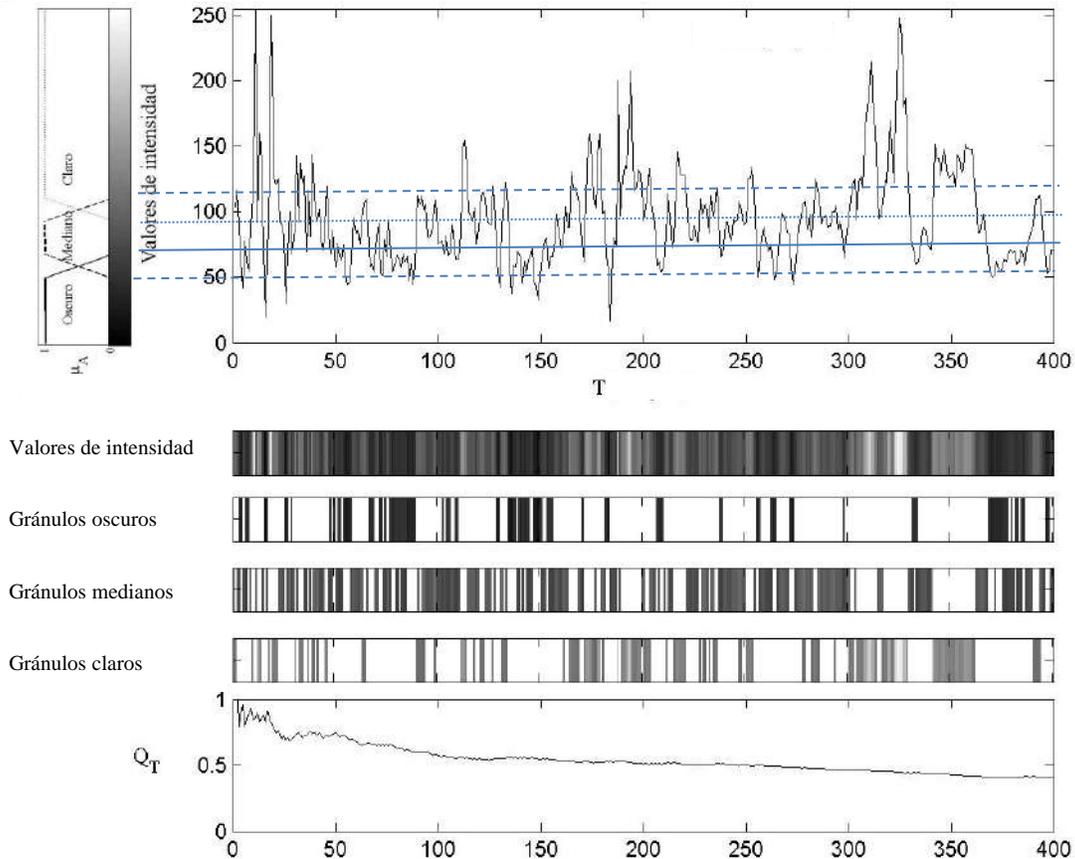


Fig 2.10. Obtención de una curva continua con Q_T evaluado en cada tiempo T

Inicialmente se realizan pruebas con PS a partir de muestras donde hay un resultado conocido, evaluándose también los resultados utilizando mayor cantidad de conjuntos difusos. En todos los casos se tiene en cuenta una distribución que permita que todos los conceptos sean igualmente distinguibles. Los mejores resultados son los obtenidos con los tres conjuntos previstos. La evolución del procedimiento, denominado TFG (*Temporal Fuzzy Granularity*) fue presentada en diversos congresos [9][10][11][12][13]

La transformación de la SSD en un conjunto de GrI permite analizar la señal desde una nueva perspectiva. La característica y distribución de los distintos gránulos, así como la evaluación individual de cada gránulo, como el tamaño, el peso de los grados de pertenencia, entre otras posibilidades, permitiría extraer distintos tipos de información, dando lugar a lo que se podría considerar granulación tipo 2. En [8] se presenta un ejemplo en el que se evalúa el peso medio de los gránulos y no solo su cantidad, es decir que cada gránulo está asociado al promedio de los valores de pertenencia de los puntos que lo componen. Esto puede ser de utilidad en algunos casos donde se desea destacar el comportamiento de sectores de actividad con más detalle. El ejemplo es mostrado en el Capítulo 4.

2.2.2 Transformación a conjuntos rugosos- difusos (rough- fuzzy sets)

Como consecuencia de la aplicación de GrC en distintas áreas de investigación, se crearon distintos tipos de conjuntos que permiten hacer más efectiva la GrC, entre ellos aparecen

principalmente los conjuntos rugosos (*rough sets*), propuestos por Pawlak [13][15] como una alternativa o un complemento al uso de los conjuntos difusos.

Los conjuntos difusos y los conjuntos rugosos conducen al concepto general de granulación con muchos usos potenciales [16][17][18][19]. Los conjuntos rugosos tratan con la indiscernibilidad de objetos en relación con sus atributos y los conjuntos difusos tratan con la imprecisión de expresiones en las cuales los objetos son considerados.

En la evolución y análisis del proceso de granulación de las SSD, surge la posibilidad de analizar el uso de conjuntos *rugosos-difusos*, para disminuir la complejidad de cumplir con la Eq. (1), en la determinación de los valores de $\mu_c(i)$ en las regiones de superposición ($\mu_c(i) < 1$). De esta manera se podría establecer una pertenencia binaria, pero con conjuntos superpuestos. Aunque ello limita algunos tipos de análisis, no cambia la eficiencia para el caso del análisis de actividad en PS y además hace posible la programación de dispositivos FPGA para procesar PS en tiempo real. Los resultados de la aplicación con FPGA, fueron presentados en [20][21], publicados en [22] y el algoritmo es descripto en el Apéndice B.

Un conjunto difuso es un conjunto cuyos elementos pueden pertenecer parcialmente a un conjunto y simultáneamente a otro; esto permite definir conceptos vagos, con límites imprecisos. Un conjunto rugoso es una aproximación de un concepto por un par de conceptos exactos. Los conjuntos rugosos están basados en el hecho que un objeto no siempre puede ser definido en forma exacta dentro de una categoría sobre la base del valor de sus atributos, entonces divide entre los objetos que son ciertamente definidos dentro de un concepto y los objetos que son posiblemente definidos dentro del concepto [13].

Si el atributo que caracteriza al objeto es difuso, pero es clasificado como un conjunto rugoso el conjunto es un conjunto rugoso-difuso (*rough-fuzzy sets*) Si la relación por la cual los elementos del conjunto son indiscernibles de otros elementos por sus atributos es difusa, entonces el conjunto es difuso-rugoso (*fuzzy-rough set*), ello implicaría la existencia de distintos atributos [23].

2.2.3 Formalización de la Granulación Temporal

El método a aplicar para detectar actividad en SSD se denominó *Temporal Rough Fuzzy Granularity* (TRFG), a diferencia de TFG como fue denominado inicialmente. Aunque este método fue creado para detectar actividad en muestras de PS, como se muestra en el Capítulo 4, puede tener distintas aplicaciones.

Formalmente un conjunto rugoso es expresado como: Dado un sistema de información $S = (U, A)$, con U conjunto Universal que define todos los objetos a considerar, A conjunto que define todos los posibles atributos de los objetos considerados en U , se pueden definir subconjuntos $X \subseteq U$ and $B \subseteq A$ y clases de equivalencia $[x]_B$ las cuales definen una relación en la cual los elementos en X son indiscernibles de otros elementos por los atributos en B . Un conjunto rugoso es entonces definido por dos conjuntos $\{x \in U: [x]_B \subseteq X\}$ y $\{x \in U: [x]_B \cap X \neq \emptyset\}$ los cuales son denominados como *B-aproximación inferior (B-lower approximation)* y *B-aproximación superior (B-upper approximation)* de X en B , denotados como $\underline{B}X$ y $\overline{B}X$ respectivamente. Los objetos en $\underline{B}X$ son ciertamente miembros de B y los objetos en $\overline{B}X$ son posiblemente miembros de B , como lo expresa Pawlak en [13].

Siendo $U = [0, 255]$, A el atributo difuso “intensidad” e $I \subseteq U$ los valores de intensidad correspondientes a una PS determinada; se consideran tres ($k=3$) conceptos difusos F_k para el atributo A , $F_k = \{\text{claros medios y oscuros}\}$. Los conceptos F_k no tienen intervalos definidos dentro del conjunto I , son rangos de valores subjetivos, sin límites claros y naturalmente superpuestos; los valores extremos podrían ser claramente distinguidos como *claros* y *oscuros*, pero la gama de grises

intermedia es difícil de caracterizar y dependerá de características de la imagen tales como el brillo (define gama de grises) y el contraste (variación de intensidades).

Considerando conjuntos difuso-rugosos, y las regiones definidas por la Eq.(1), se establecen las regiones 1,3 y 5 como aproximaciones inferiores $F_k I = \{i \in U: [i]_{F_k} \subseteq I\}$ (valores claramente pertenecientes a los conceptos definidos), las regiones 2 y 4 corresponden a regiones límites (valores que no son totalmente ciertos para ningún concepto), correspondiendo las regiones 1+2 a oscuros, 2+3+4 a medios y 4+5 a claros, a las aproximaciones superiores (valores que podrían pertenecer a los conceptos definidos) $\overline{F_k} I = \{i \in U: [i]_{F_k} \cap I \neq \emptyset\}$.

Para granular una $SSD_{(x,y)}$ de longitud n , cada gránulo de información estará dado por sucesiones de valores con igual clase de equivalencia $[i]_{F_k}$, (aproximaciones superiores). Un gránulo finaliza cuando el siguiente valor de la serie pertenece a una clase de equivalencia distinta. La definición de los gránulos se realiza simultáneamente para las tres clases de equivalencia ya que los gránulos pueden estar total o parcialmente superpuestos, Fig.2.11.

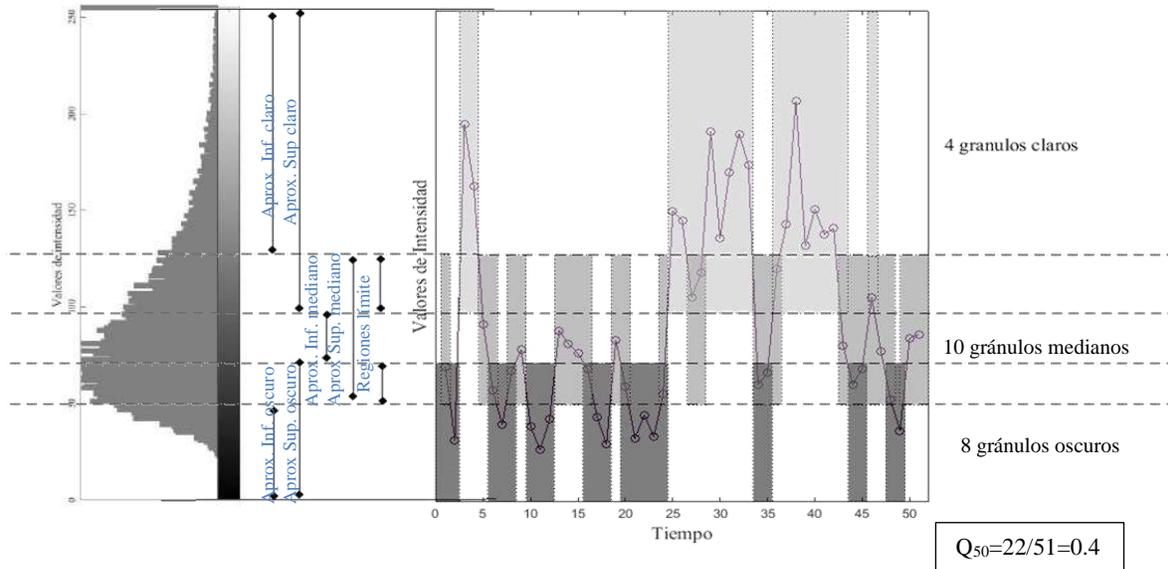


Fig. 2.11 Proceso general con conjuntos rugosos - difusos

Siendo I los valores de intensidad de una PS de $ir \times ic$ y n la cantidad de PSs, para cada $SSD_{(x,y)}$ en cada instante j , la finalización de cada granulo k es verificado y almacenado en una matriz Gr de $ir \times ic \times k$, donde 1 (*verdadero*) indica el fin de un gránulo k y 0 (*falso*) indica la continuidad del gránulo o cambio de clase de equivalencia (comienzo de un nuevo gránulo).

$$Gr_j(x, y, k) = \begin{cases} 1 & \text{si } [SSD_{(x,y)}(j-1)] \in F_k \text{ y } [SSD_{(x,y)}(j)] \notin F_k \\ 0 & \text{en otro caso} \end{cases} \quad (5)$$

Una matriz Q_T de $ir * ic$ acumula la cantidad de gránulos Gr de cada SSD en (x,y) , es decir la cantidad de gránulos que finalizan en cada instante j . Un valor relativo puede ser computado para T instancias de PSs, Eq. (6).

$$Q_T(x, y) = \left(\sum_{j=2}^T \sum_{k=1}^3 Gr_j(x, y, k) \right) / T \quad (6)$$

La actividad Q_T puede ser calculada en un periodo fijo, como se muestra en la Fig. 2.5 o en tiempo real, evaluando cada nuevo valor en relación al estado de los gránulos en el tiempo previo $j-1$, Fig. 2.10.

Los valores de la matriz Q_T normalizados al rango de los valores de intensidad [0,255] permiten reconstruir una imagen en la que se podrá distinguir el nivel de actividad de cada píxel sin reducción de resolución espacial, como puede suceder en otros métodos. Esto convierte el algoritmo en una metodología robusta al no ser sensible ni a pequeños cambios en la señal ni a precisión en la definición de los parámetros. Una leve variación de los parámetros modifica las regiones límites en las cuales se acomodan los gránulos, pero por lo general no produce cambios significativos en los resultados. El algoritmo es mostrado en el Apéndice C.

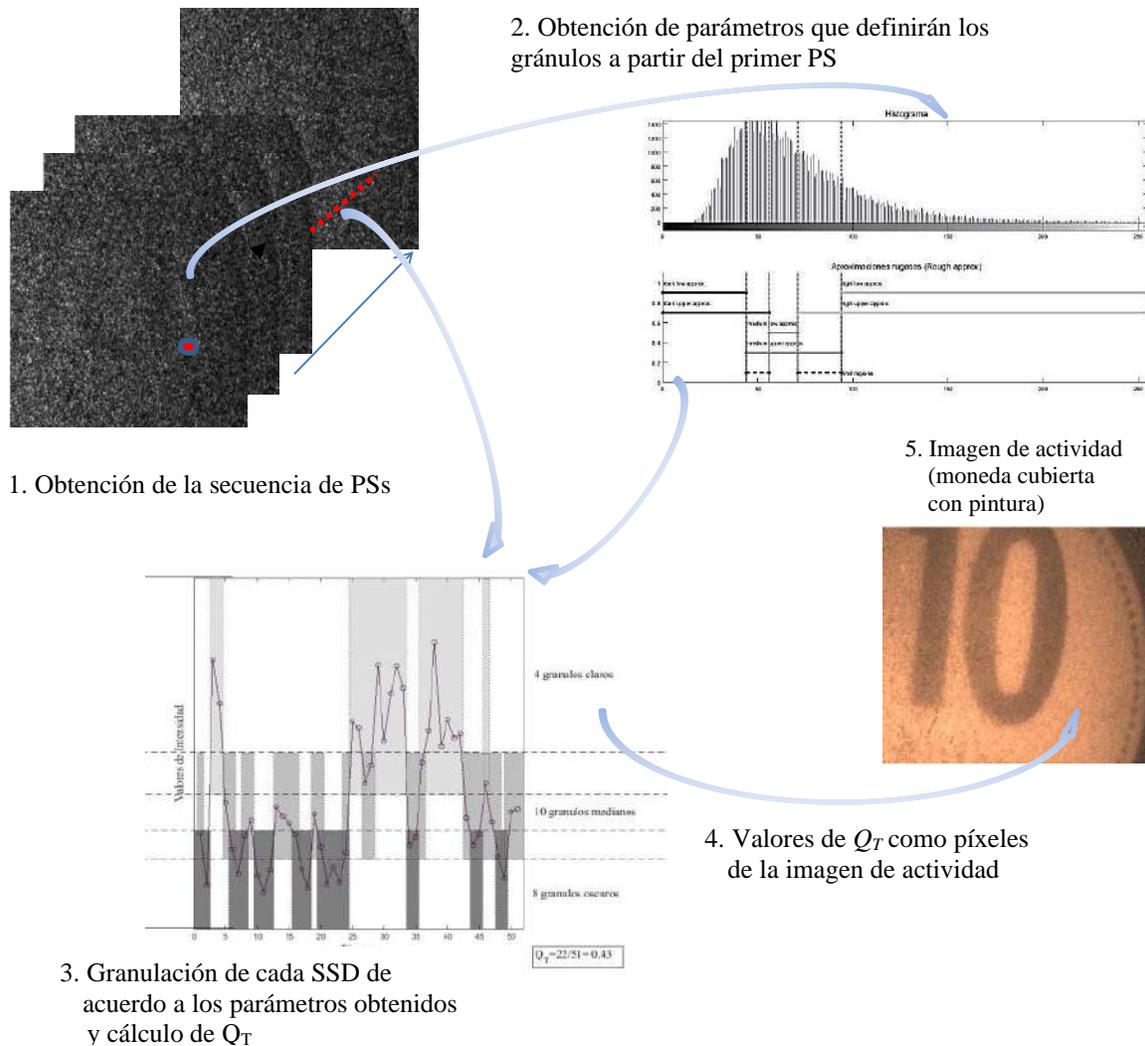


Fig. 2.12 Representación del método TRFG

2.2.5 Algoritmo FPGA

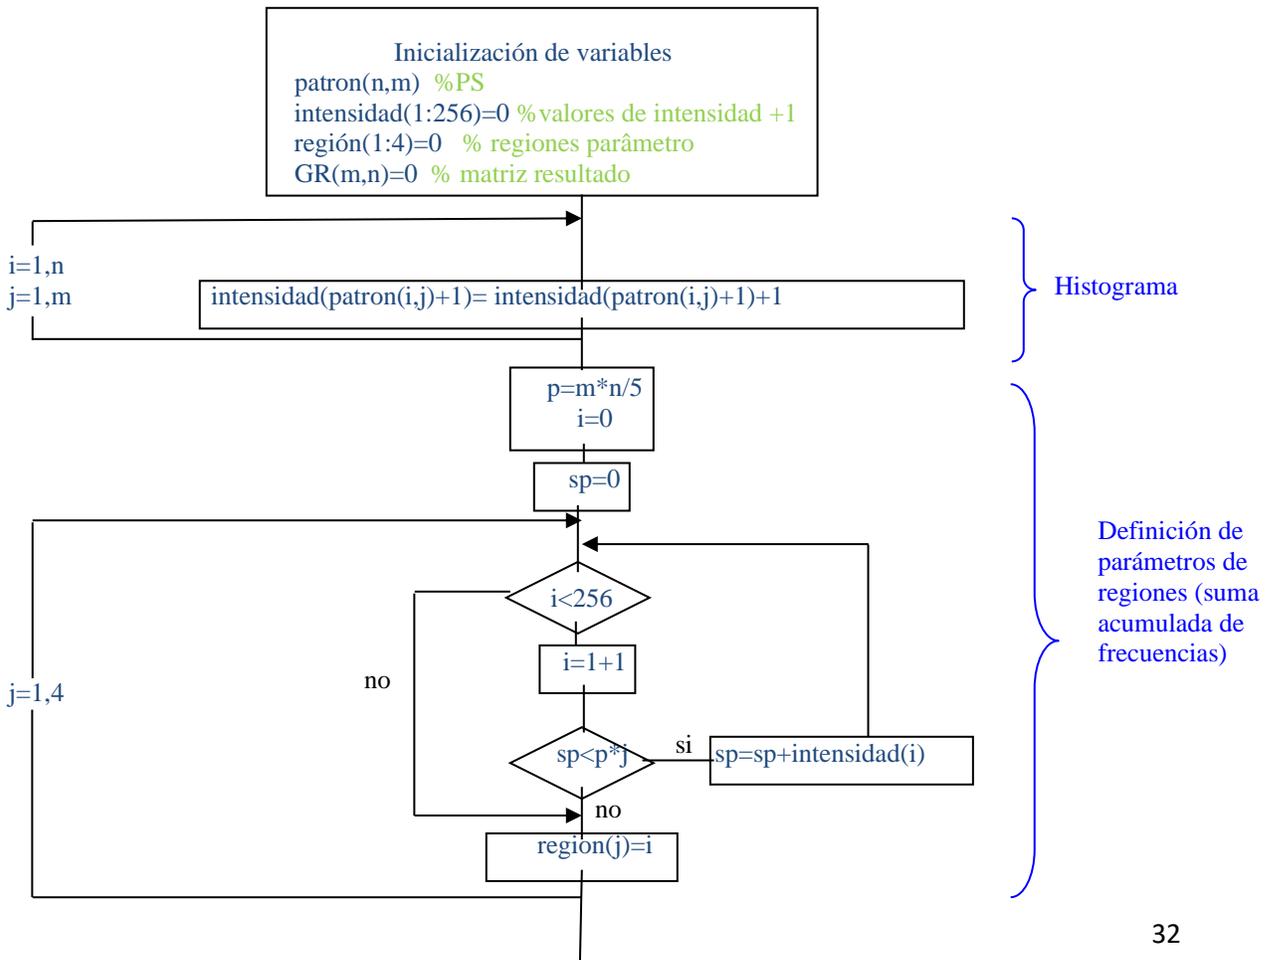
Como se vio en la sección 2.2.1, a partir de la transformación de la metodología de granulación difusa TFG a granulación rugosa-difusa TRFG, el algoritmo es simplificado sin perder eficiencia. En la Fig.2.13 se muestra el diagrama de flujo básico.

El bajo costo computacional de este algoritmo lo hace adecuado para ser diseñado con tecnologías FPGA (*Field Programmable Gate Array*) [20][21][22], haciendo posible procesos en tiempo real, tomando la información directamente de la cámara (Fig. 2.14).

El análisis de la actividad de *speckle* en tiempo real, permitiría el desarrollo de importantes aplicaciones prácticas de interés tecnológico, comercial y biológico, pudiendo procesar alrededor de mil imágenes de *speckle* de 512 x 512 fps con períodos mínimos de reloj y latencias.

En este caso, el valor de Q_T para cada píxel es calculado en forma continua, es decir que se calcula cada vez que un nuevo PS es enviado desde la cámara, teniendo en cuenta el estado de los gránulos acumulados en el instante previo, como fue mostrado en la Fig. 2.10.

En el diseño para FPGA hay un módulo para cada etapa del proceso. Es decir, un primer módulo para establecer el histograma de intensidad; el segundo para calcular las 5 regiones con una distribución equilibrada de píxeles en cada región; el tercero para calcular la cantidad de gránulos y los índices de actividad Q_T .



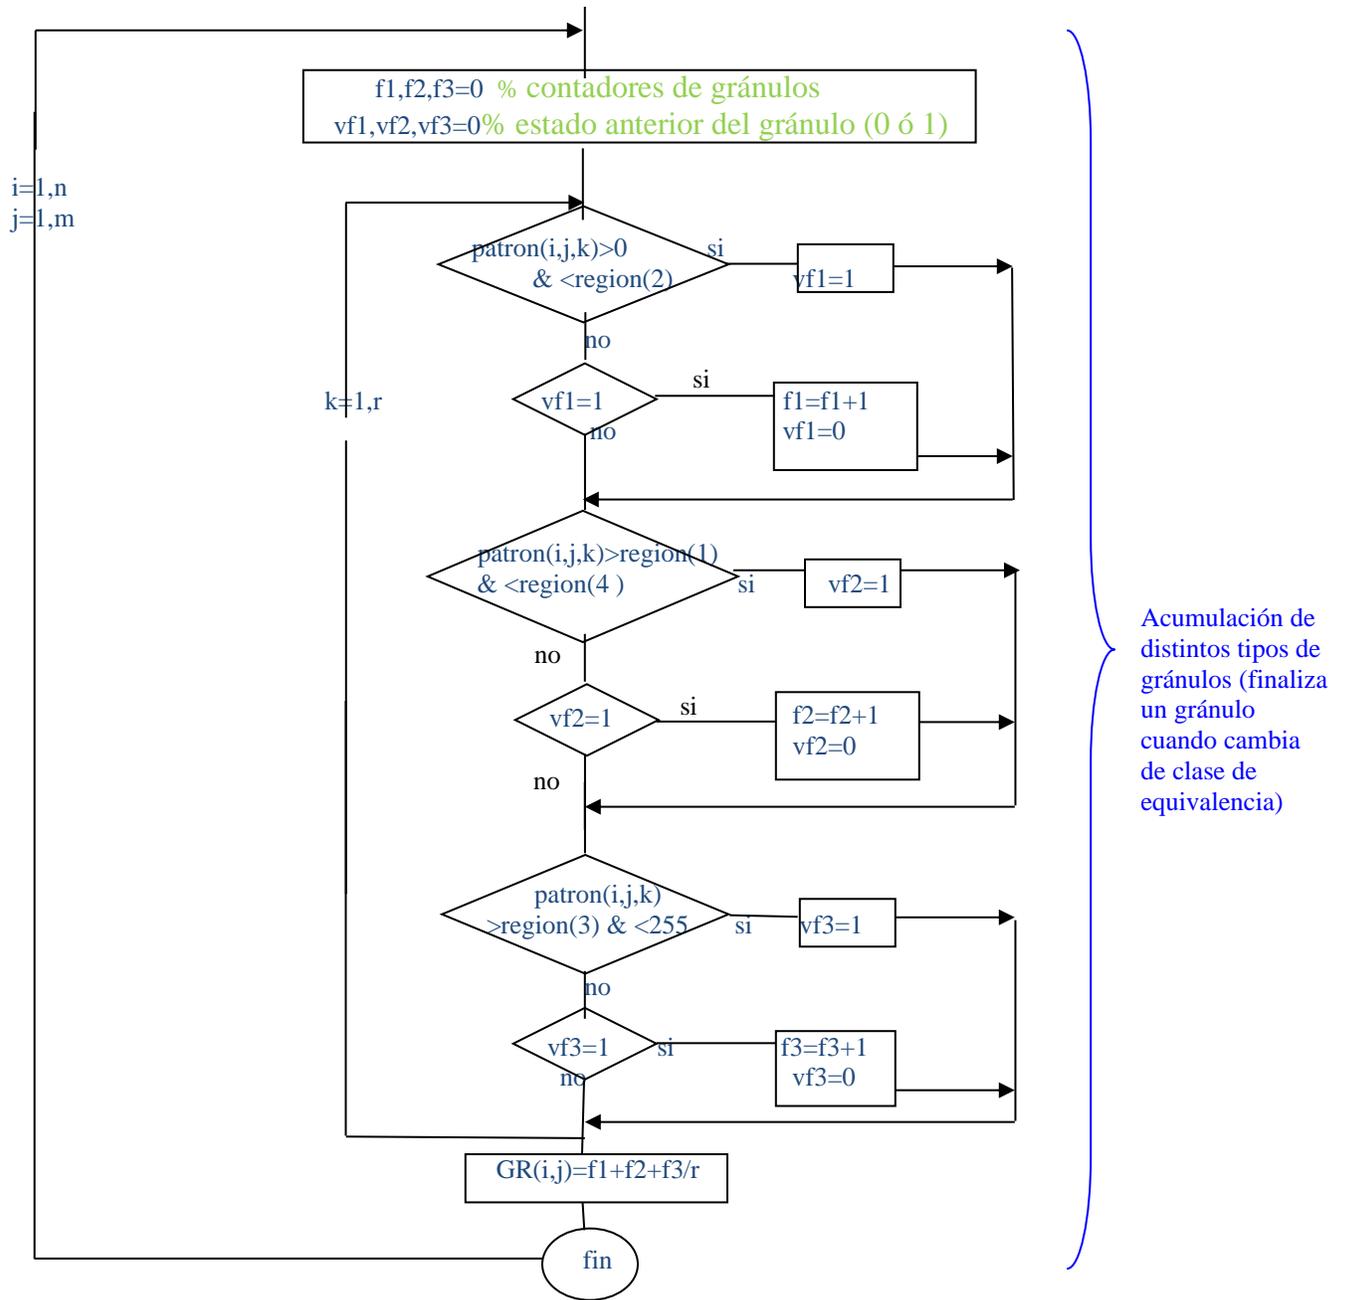


Fig. 2.13 Diagrama de flujo de bajo nivel del TRFG

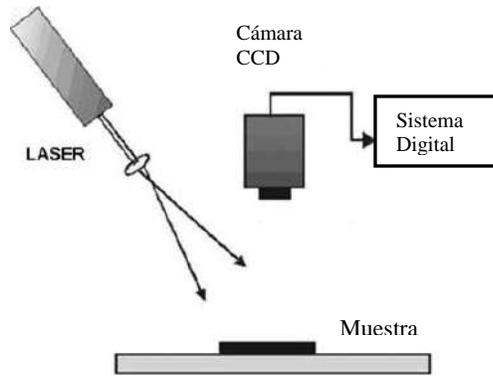


Fig.2.14 Configuración óptica para un sistema digital

Las entradas del circuito son proporcionadas por un controlador de cámara que impulsa: una señal de inicio para un nuevo cálculo, una señal de escala de grises de 8 bits con los valores de intensidad de un solo píxel a la vez, una identificación del píxel y una señal para el número de cuadro. La salida son los valores Q_T para cada píxel.

Considerando:

- N_p : cantidad de píxeles en un PS, de $N_r \times N_c$ filas por columnas
- N_f : cantidad de PSs a capturar
- Z : cantidad de conceptos difusos

La memoria requerida estará dada por:

- Contadores de gránulos (C_{mem}): Se necesitan $N_p = N_r \times N_c$ contadores de gránulos para supervisar la actividad de cada píxel. Esto implica un requisito de memoria, en bits, de:

$$C_{mem} = N_p \times L,$$

donde L representa el tamaño de la celda de registro. Siendo la cantidad máxima de instancias $N_f = 2^b$, se requieren $b + 1$ bits para L . Aunque b bits son suficientes para contar desde 0 hasta $2^b - 1$, podrían estar involucrados dos gránulos en cada paso de conteo (por superposición de gránulos), por lo que se considera un bit más.

- Configuración del histograma (H_{mem}): considerando valores de intensidad en $[0, 255]$, se necesitan 256 registros de memoria binaria para almacenar cantidades en $[0, N_p]$. El requisito de memoria en bits se da como:

$$H_{mem} = 256 \times \log_2 N_p.$$

- Memoria de regiones (F_{mem}): en cada nueva instancia la intensidad del píxel es expresada en regiones. Para el diseño de los circuitos se consideran las 5 regiones definidas en la eq. (2) son utilizadas para codificar cada valor de la SSD con 3 bits, cada uno de los cuales corresponde a un tipo de gránulo como se muestra en la tabla 2.1.

Tabla 2.1 Codificación de regiones

Regiones	código	Clases de equivalencia
R1	001	<i>oscuro</i>
R2	011	$\overline{\text{oscuro}} \cap \overline{\text{medio}}$
R3	010	<i>medio</i>
R4	110	$\overline{\text{medio}} \cap \overline{\text{claro}}$
R5	100	<i>claro</i>

Las memorias se deben incrementar cuando el valor de un mismo píxel en la instancia anterior es distinto, ello requiere de la siguiente cantidad de memoria

$$Fmem = Np \times Z$$

Para obtener el máximo rendimiento, el acceso a la memoria externa debe reducirse tanto como sea posible. La Tabla 2.2 muestra los requisitos de memoria para diferentes configuraciones de PS. Existen dispositivos lógicos programables listos para usar con estas cantidades de memoria en el chip.

Tabla 2.2 Requerimientos de memoria en bits para diferentes setups

<i>Np</i>	<i>Nf</i>	<i>Z</i>	<i>Cmem</i>	<i>Fmem</i>	<i>Hmem</i>	<i>Total</i>
512*512	128	3	2,097,152	786,432	4,608	2,888,192
512*512	64	3	1,835,008	786,432	4,608	2,626,048
400*400	128	3	1,280,000	480,000	4,426	1,764,426
400*400	64	3	1,120,000	480,000	4,426	1,604,426
350*350	128	3	980,000	367,500	4,328	1,351,828
350*350	64	3	857,500	367,500	4,328	1,229,328

2.3 Metodología para procesamiento espacial

En la granulación espacial, los píxeles individuales de una imagen se organizan en entidades más grandes y se procesan como tales. En el caso de los PS, se analiza una ventana deslizante de $m \times l$, que dará valor al píxel superior izquierdo correspondiente.

El método, denominado *Spatial Rough-fuzzy Granularity* (SRFG), utiliza los mismos principios que el TRFG. Una vez determinadas las clases de equivalencia $[i]_{F_k}$, se evalúa la pertenencia de cada píxel de la ventana, determinando una ventana binaria para cada clase de equivalencia Eq. (7). Se considera que un gránulo está dado por valores igual a 1 contiguos y el valor de cuantificación $Q_S(x,y)$ que determinará la imagen de actividad, será la suma de la cantidad de gránulos total, Eq. (8). La Fig. 2.15 ejemplifica el procedimiento para una ventana en particular. El algoritmo es mostrado en el Apéndice C.

El valor de $Q_S(x,y)$ será mayor cuando los píxeles de la ventana pertenezcan a las regiones de límite (el píxel pertenece a más de un concepto difuso). Esta característica podría interpretarse como correspondiente al desenfoque de las regiones en movimiento. Resultados mostrados en Capítulo 4.

$$Gr(x, y, k) = \begin{cases} 1 & \text{si } [PS(x + i, y + j)] \in F_k \\ 0 & \text{si } [PS(x + i, y + j)] \notin F_k \end{cases} \quad \forall i \in [0, m - 1] \text{ y } j \in [0, l - 1] \quad (7)$$

$$Q_S(x, y) = \left(\sum_{k=1}^3 rot(Gr(x, y, k)) \right) \quad (8)$$

donde $rot(Gr)$ indica componentes conectados en la matriz binaria Gr

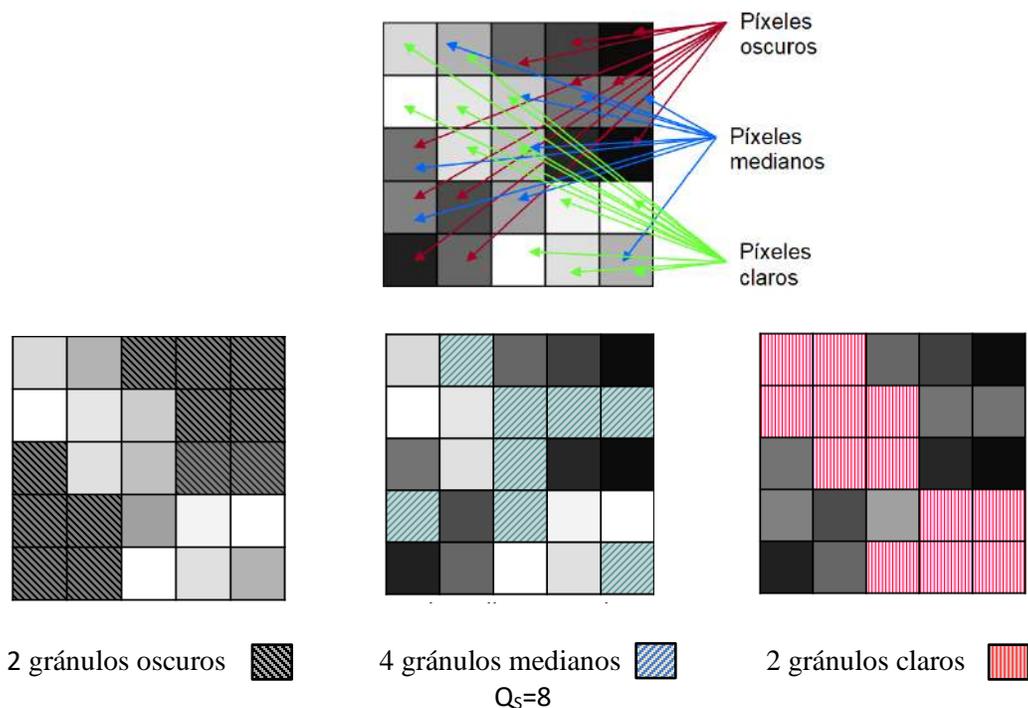


Fig. 2.15 Representación de la SRFG

Se estudió la posibilidad de combinar SRFG con TRFG para crear un método temporoespacial, pero sus resultados no han superado al TRFG a pesar de tener un alto costo computacional.

2.4 Conclusiones

La metodología propuesta nace de una idea de implementación a partir de la visión natural del fenómeno sin considerar ningún conocimiento al tema subyacente. El proceso resulta ser muy simple comparado con los métodos utilizados hasta el momento aplicando tecnologías de procesamiento de señales. En la evolución de la metodología el proceso se fue simplificando aún más, estudiándose la posibilidad de diseñar un sistema digital que permita analizar PS en tiempo real.

En el capítulo siguiente se compara TRFG con distintas técnicas y métodos de procesamiento de señales con señales simuladas para evaluar su respuesta.

El procesamiento espacial de PS podría permitir analizar actividad con un solo PS. Ello ha sido útil como un método complementario al TRFG como se verá en el capítulo 4. El SFRG aunque utiliza una única imagen tiene un procesamiento más lento.

2.5 Referencias

- [1] Briers D., Duncan D., Hirst E., Kirkpatrick J., Larsson M., Steenbergen W., Stromberg T., and Thompson O., (2013). Laser speckle contrast imaging: theoretical and practical limitations. *J Biomed Opt* 18 (6) 066018.
- [2] Dai Pra A. L. and Passoni L.I. (2009). Granular Computing In Thsp: Fuzzy Granular Analysis, in: Hector J. Rabal H.J., Braga R.A. *Dynamic Láser Speckle and Applications*. (169-180). CRC Press. Boca Raton, USA. ISBN 978-1-4200-6015-7.

- [3] Arizaga R., Trivi M., Rabal H J. (1999). Speckle time evolution characterization by co occurrence matrix analysis. *Opt Laser Technol*, 31, 163-169.
- [4] Zadeh L.A. (1965). Fuzzy sets. *Inform. Control*, 8, 338–353.
- [5] Zadeh L. A. (1970). Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic, *Fuzzy set syst.* 90, 111-127.
- [6] Pedrycz W. (Ed.) (2001). Granular computing: An emerging Paradigm, *Studies in fuzziness and soft computing* 70. Physica-Verlag, Germany,
- [7] Pedrycz W., Homendad W. (2013). Building the fundamentals of granular computing: A principle of justifiable granularity. *Applied Soft Computing*. 13 (10) 4209-4218
- [8] Dai Pra, A.L., Passoni L.I., Rabal H., (2009). Evaluation of láser dynamic speckle signals applying granular computing. *Signal Process.* 89, 266-274
- [9] Dai Pra, A.L., Passoni, I.L., Rabal, H. (2006) .Fuzzy Temporal Granularity for activity measure in Dynamic Speckle Phenomenon. *XV Conference on Nonequilibrium Statistical Mechanics and Nonlinear Physics -Medyfinol* Poster. Mar del Plata. 4-8 diciembre 2006
- [10] Dai Pra A.L., Passoni I.L., Maldonado E., (2007). Granularidad Difusa para la Segmentacion de Topografías Utilizando Speckle Dinamico. *Simposio Argentino de Tecnologia - AST 2007 (36 JAIIO)*. Mar Del Plata - Buenos Aires. 27-31 Agosto de 2007.
- [11] Dai Pra A.L., Passoni L.I., Rabal H. (2008). Conjuntos Difusos Aplicados al Análisis de Secuencias de Imágenes de Speckle Láser. XIV. *Congreso Latino Ibero Americano de Investigación de Operaciones*. Cartagena de Indias, 9 al 12 de Setiembre de 2008. ISBN: 978 958 825283-4. 123.
- [12] Dai Pra A.L., Passoni L.I., Rabal H. (2009). Temporal Granular Computing in Dynamic Speckle Signal Processing. *XIII Reunión de Trabajo en Procesamiento de la Información y Control. RPIC 2009*. Rosario. 16 al 18 setiembre 2009. ISBN 950-665-340-2.
- [13] Passoni L.I., Dai Pra A.L., Rabal H. (2010). Signal Processing with Fuzzy Sets. Conferencia invitada. *ALIO (Association of Latin-Iberoamerican Operational Research Societies) /INFORMS (Institute for Operations Research and the Management Sciences)* Joint International Meeting. 6-9 de Junio 2010. Universidad de Buenos Aires- Argentina.
- [14] Pawlak Z. (1982). Rough sets. *Int J Comput Inf Sci* 11 341-356.
- [15] Pawlak Z., Skowron A. (2007). Rudiments of rough sets, *Inform Sciences*, 177 3–27.
- [16] Pal, S. K. (2012). Granular Mining and Rough-Fuzzy Pattern Recognition: A Way to Natural Computation. *IEEE Intelligent Informatics Bulletin* 13 3-13.
- [17] Maji P., Pal S. K. (2012). Rough-fuzzy pattern recognition. *Applications in bioinformatics and medical imaging* 7. John Wiley & Sons, NY.
- [18] Greco S., Matarazzo B., Słowiński, R. (2009). A summary and update of “Granular Computing and Data Mining for Ordered. Data: the Dominance-based Rough Set Approach”. In: Meyers R.A. *Encyclopedia of Complexity and Systems Science*, Springer, New York, 4283-4305.
- [19] Jensen R., Shen Q. (2002). Fuzzy-rough sets for descriptive dimensionality reduction, *Fuzzy Systems. FUZZ-IEEE'02. Proceedings of the 2002 IEEE International Conference on* 1 29-34.

- [20] Ferrara F., Cozzolino E., Todorovich E., Vazquez M., Bioul G., Dai Pra A.L. (2013). Un Sistema Digital para Procesar Señales Speckle en Tiempo Real. *IV Congreso de Microelectrónica Aplicada (uEA 2013)*. 25, 26 y 27 de Septiembre de 2013. Bahía Blanca, Argentina
- [21] Todorovich E., Vazquez M., Cozzolino E., Ferrara F., Bioul G., Dai Pra A.L., Passoni L.I. (2011) Speckle Signal Processing through FPGA. *UEA 2011(II Congreso de Microelectrónica Aplicada)* 7, 8 y 9 de Septiembre La Plata.
- [22] Todorovich E., Dai Pra A.L., Passoni L.I. (2016). Vázquez M., Cozzolino E., Ferrara F., Bioul G. Real-time speckle image processing, *Journal of Real-Time Image Processing* 11(3) 535-545
- [23] De Cock M., Cornelis C., and Kerre E.E. (2007). Fuzzy Rough Sets: The Forgotten Step. *IEEE Transactions On Fuzzy Systems* 15 (1)
- [24] Dai Pra, A.L., Passoni, L.I. (2015). Rough-Fuzzy Granularity in the Study of Optical Phenomena. *Workshop Fuzzy Logic in Artificial Intelligence, IJCAI 2015*, Buenos Aires, Julio 2015. CEUR Workshop Proceedings 1424

Capítulo 3

Análisis comparativo del descriptor granular TRFG con otros descriptores utilizados para *speckle* láser dinámico

La caracterización de los PS, añadido al hecho de que la dinámica interna del proceso que los produce generalmente es poco conocida, hace que no exista un criterio bien definido sobre cual descriptor es más adecuado en cada aplicación.

Con el propósito de analizar y comparar el método TRFG con otros descriptores, se propone una evaluación sobre series simuladas, generadas computacionalmente con parámetros controlados para determinar la bondad de los resultados, ya que las muestras de *biospeckle* obtenidas experimentalmente están sujetas a variabilidad inherente al objeto en observación y requieren de condiciones ambientales controladas que condicionan los PS registrados.

Cuando un PS es generado por el movimiento de un difusor rígido bajo las condiciones más generales es posible observar dos fenómenos. El primero es la traslación del patrón como un todo y, por consiguiente, también la traslación de cada punto del PS. El segundo aparece cuando el punto del PS cambia su forma y eventualmente desaparece o aparece con los movimientos del difusor, lo cual se conoce como ebullición. Generalmente, ambos fenómenos ocurren simultáneamente; sin embargo, existen condiciones para las cuales es posible observar PS de traslación pura o ebullición pura.

Hay varios modelos numéricos existentes para simular PS [1][2][3], el elegido es el modelo propuesto por Sendra et al. [4]. El modelo describe adecuadamente un experimento simple y de ebullición repetible, es decir, un PS producido por un difusor de movimiento en el plano bajo adecuadas condiciones geométricas del sistema de observación.

Para probar la eficiencia de los descriptores en descubrir el nivel de la actividad de una secuencia de PS, se propone una evaluación en términos de linealidad con respecto a la velocidad del difusor, convergencia y performance con respecto a la cantidad de imágenes necesarias y tiempo de procesamiento.

Con ese objetivo, se generó un conjunto de PS simulados utilizando un modelo numérico validado con experimentos reales. Se basa en la simulación de un difusor móvil en condiciones de ebullición puros, donde el nivel de actividad varía según la velocidad del difusor en forma controlada. De este modo, los descriptores deberían proporcionar valores numéricos altamente correlacionados con la actividad de la muestra simulada.

Hay muchos descriptores definidos en la literatura para extraer características de PS [5]. Para hacer la comparación con el TRFG, se seleccionó un subconjunto de ellos como los más representativos dentro de las siguientes categorías:

1. Basados en análisis estadístico
2. Basados en análisis de frecuencia
3. Basados en análisis temporal

Primeramente se presentan los descriptores y luego el estudio comparativo de los mismos. En adelante, en todas las ecuaciones presentadas, la variable X es considerada como el vector de valores x_i de la serie de tiempo que representa la variación temporal de la intensidad de un pixel en la secuencia de las imágenes (SSD), con una cantidad de muestras N , siendo $i=1, \dots, N$ y donde $\langle X \rangle$ corresponde a la media de los valores x_i .

3.1 Descriptores basados en análisis estadístico

Entre los descriptores basados en análisis estadístico se consideraron: Desviación Estandar, Contraste Temporal y Autocorrelación.

3.1.1 Desviación Estándar (*Standard Deviation - SD*)

Desde el punto de vista estadístico, el método más simple para descubrir variaciones en una serie es la desviación estándar (SD), que es una medida de las variaciones en la serie de tiempo con respecto al valor medio [6][7].

$$SD = \sigma(X) = \sqrt{\frac{\sum_{i=1}^N (x_i - \langle X \rangle)^2}{N}} \quad (1)$$

3.1.2 Contraste Temporal (*Temporal Contrast - TC*)

En experimentos reales, el SD es muy sensible a la intensidad media de la serie, ya que el *speckle* no es un proceso lineal. Una forma de solucionar este problema es la división del SD por la intensidad media.

$$TC = \frac{\sigma(X)}{\langle X \rangle} \quad (2)$$

3.1.3 Autocorrelación (*Full Width Half Maximum of the Autocorrelation - FWHMA*)

La función de autocorrelación es definida como la correlación cruzada en la misma señal con una versión desplazada en el tiempo de la misma. El propósito es encontrar patrones repetitivos. En SSD, la función de autocorrelación R_k , es por lo general una función monótonicamente decreciente expresada como:

$$R_k = \sum_{n=1}^N x_{n+k} x_n, \quad \text{where } 0 \leq k \leq N \quad (3)$$

Una versión normalizada típicamente empleada, es el resultado de dividir Eq (3) por R_0 (desfasaje 0). De ahí, FWHMA es calculado como el desfasaje de R_k en la mitad de su máximo [8].

3.2 Descriptores basados en análisis de frecuencia

La información de una señal que varía tiempo por lo general es mejor interpretada desde el punto de vista de la frecuencia. La transformada de Fourier de la función de autocorrelación es la Densidad Espectral de Potencia (*PSD*), que también puede ser empleada para describir la actividad de señal.

La Fig. 3.1 muestra dos SSD simuladas en velocidades bajas y altas, junto con su valoración respectiva *PSD*. Para reducir artefactos en la transformada de Fourier debido a la longitud finita de la señal discreta, el *PSD* es calculado usando el estimador Bartlett-Welch [9]

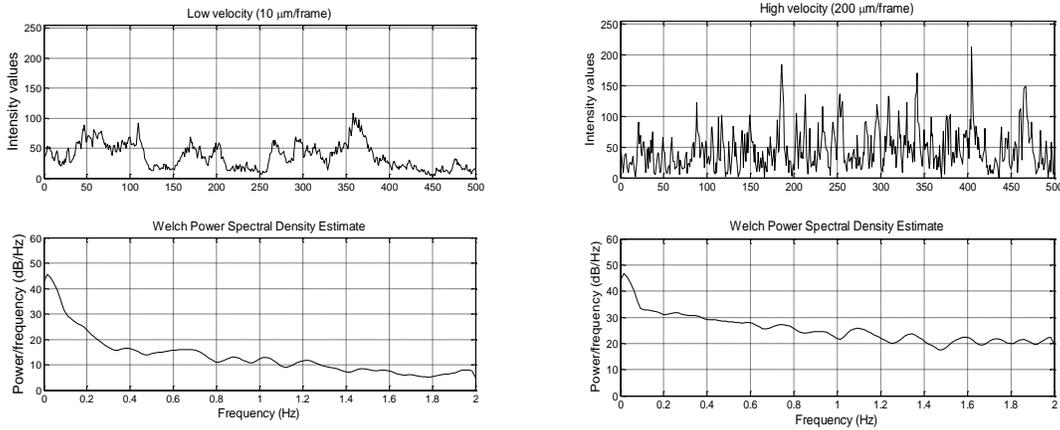


Fig 3.1. SSD simuladas en velocidades bajas y altas

La naturaleza multispectral de las SSD y su análisis en el dominio de frecuencia da lugar a plantear varios descriptores de interés.

3.2.1 Energía de Banda Espectral (ESB)

Conforme a la hipótesis de utilidad de la información proporcionada por el espectro, se propone un descriptor basado en la energía de la señal filtrada, ya que a veces, el filtrado del patrón de intensidad en el dominio de frecuencia ayuda a encontrar una banda particular que puede caracterizar el *speckle* en ebullición. El descriptor se calcula como la energía de la señal X filtrada previamente [9].

$$ESB = \frac{1}{N} \sum_{n=1}^N x_n^2 \quad (4)$$

No hay ningún método a priori para conocer en cual banda de frecuencia está la información "útil" de la señal. Aunque el ESB sea también un descriptor empírico, un banco inicial de filtros puede ser aplicado para descubrir las bandas de interés [10]. El ESB es el análisis más fácil de los fenómenos que originaron la SSD.

Para el caso de bandas de baja frecuencia se requiere una substracción previa del valor medio de la señal. Este descriptor ha resultado ser eficaz para caracterizar algunos procesos bajo la iluminación no uniforme, donde cada valor de señal es preprocesado con la expresión siguiente:

$$\tilde{x}_i = (x_i - \langle X \rangle) / \langle X \rangle \quad (5)$$

3.2.2 Relación Alta Baja frecuencia (High Low Ratio - HLR)

La relación Alta-Baja frecuencia (HLR) puede ser aplicada para relacionar dos bandas de frecuencia. Fujii et al. [11] proponen HLR considerando dos frecuencias:

$$HLR = \frac{S_H}{S_L} \quad (6)$$

donde S_H y S_L son valores del PSD en una frecuencia alta y baja respectivamente. Generalmente, S_L es calculado dentro del intervalo de frecuencia $f=0$ a 0.25 de f_{max} y S_H es calculado de 0.25 de f_{max} a f_{max} . Considerando f_{max} como la frecuencia máxima de la descomposición PSD.

3.2.3 Frecuencia Media (Mean Frequency - MF)

Otro descriptor del *PSD* es la frecuencia media (*MF*) introducido por Aizu y Asakura [12], definido como:

$$MF = \frac{\sum_{k=1}^{N_f} f_k s_k}{\sum_{k=1}^{N_f} s_k} \quad (7)$$

donde s_k es el componente de k -th del *PSD*, f_k su valor de frecuencia y N_f es el número total de componentes de frecuencia.

3.2.4 Frecuencia de Corte (Cutoff Frequency - CF)

Este descriptor calcula la frecuencia en la mitad del máximo *PSD*, de ahí este procedimiento es análogo al FWHMA, pero aplicado ahora al *PSD* en vez de a la autocorrelación [12].

3.2.5 Entropía de Shannon (SE) del PSD

Un descriptor alternativo del *PSD* es la entropía introducida al principio por Shannon como una medida del "desorden" de la señal [13]. El valor de entropía espectral es obtenido multiplicando la estimación de *PSD* [$P_f(X)$] por su logaritmo natural [$\log_e P_f(X)$], sumado sobre todos los componentes de frecuencia de f . A partir de entonces, el valor de entropía es normalizado para extenderse entre 1 (la irregularidad máxima) y 0 (la regularidad completa) [14]. El valor también es dividido por el máximo de la entropía de espectro de muestras de N_f . Siendo N_f igual al número total de componentes de frecuencia, matemáticamente expresado como:

$$SE = \frac{-\sum_{f=1}^{N_f} \frac{s_f}{S} \log\left(\frac{s_f}{S}\right)}{\log(N_f)} \quad (8)$$

donde s_f es el elemento de f -th del vector de espectros de densidad de potencias s de longitud N_f , siendo S :

$$S = \sum_f s_f \quad (9)$$

3.2.6 Entropía de la Transformada Discreta de Onditas (Discrete Wavelet Transform Entropy - DWTE)

En vez de usar *PSD*, la Entropía Shannon también puede ser aplicada a la descomposición de la señal que usa la Transforma Discreta de onditas (DWTE) [15][16][17][18]. *DWTE* no hace ninguna suposición sobre las características de la señal estacionaria entonces, esto proporciona un instrumento útil para el análisis de frecuencias que consideran regiones temporales [17]. Este rasgo hace posible calcular la evolución de tiempo de su entropía como una medida de la variación de la complejidad o el desorden de la serie de tiempo.

La transformada de Onditas es la representación de una señal X mediante sus productos internos con un conjunto de funciones de onditas básicas. Una familia de onditas $\Psi_{a,b}$ es el conjunto de funciones generadas por dilataciones y traslaciones de una única ondita madre admisible (t).

$$\psi_{a,b}(t) = |a|^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad (10)$$

donde $a, b \in \mathbb{R}$ con $a \neq 0$ son los parámetros de escala y traslación respectivamente y t es el tiempo. La ondita se estrecha acorde a como a decrementa. La Transforma de onditas (WT) proporciona un instrumento para observar simultáneamente una serie de tiempo en una gama completa de escalas a diferentes, conservando la dimensión de tiempo de los datos originales. La teoría de análisis de multi-resolución muestra que ninguna información es perdida si los coeficientes continuos de onditas son probados en un conjunto escaso de puntos en el plano de escala de tiempo conocido como la grilla *dyadic*. Esta grilla conduce al DWTE, dónde el parámetro de escala es $a_j = 2^{-j}$ y la traslación $b_k = 2^{-j}k$, con $j, k \in \mathbb{Z}$.

Si se considera que la señal está dada por un conjunto de valores correspondientes a una grilla de tiempo uniforme, aplicando la descomposición sobre todos los niveles de resolución $M = \log_2(N)$, entonces la extensión de ondita será:

$$S(t) = \sum_{j=0}^{\infty} \sum_k C_j(k) \psi_{j,k}(t) = \sum_{j=0}^{\infty} r_j(t) \quad (11)$$

donde $C_j(k)$ puede ser interpretado como los errores locales residuales entre sucesivas aproximaciones de la señal en las escalas j y $j+1$, y $r_j(t)$ es la señal residual en la j de escala. La energía en cada nivel de resolución $j = -1, \dots, -M$, donde $M = \log_2(N)$ será la energía de la señal de detalle en una ventana de tiempo dada.

Para estudiar la evolución en el tiempo del PS, la señal X es dividida en ventanas temporales i de longitud L . La siguiente expresión es usada para obtener la energía media de la ondita de la señal j en cada ventana i .

$$E_j^{(i)} = \sum_{k=0}^{(L/2^j)-1} |C_{k,j,i}|^2 \quad (12)$$

con $i=1, \dots, NT$, con $NT=N/L$. La energía total en el intervalo puede ser obtenida por:

$$E_{total}^{(i)} = \sum_{j<0} E_j^{(i)} \quad (13)$$

La energía de ondita relativa de la ventana i de la señal:

$$p_j^{(i)} = \frac{E_j^{(i)}}{E_{total}^{(i)}} \quad (14)$$

La siguiente expresión se usa para evaluar la entropía Shannon de la ventana i [16]. El valor obtenido se asigna al punto central de la ventana, normalizado con el máximo registro del nivel de descomposición, para obtener valores de entropía en el intervalo $[0,1]$.

$$DWTE = \frac{-\sum_{j<0} p_j \cdot \log[p_j]}{\log M} \quad (15)$$

En consecuencia, si los cambios de comportamiento integrados de la SSD pueden caracterizarse por el valor de entropía que evoluciona en el tiempo, este parámetro se puede considerar como un descriptor en el *biospeckle* dinámico. Este descriptor se ha aplicado con éxito a

la evaluación de fenómenos que varían en el tiempo, como el secado de pintura del esmalte acrílico de secado rápido [19].

3.3 Descriptores basados en el análisis de dominio de tiempo

Los siguientes descriptores se basan en cálculos en el dominio del tiempo; por lo tanto, dependen fuertemente del número de muestras de la serie. Para evitar este efecto, se incluyó una división por la cantidad de muestras N en sus expresiones matemáticas.

3.3.1 Diferencias promedio (Averaged Differences - AD)

Debido a la no linealidad del fenómeno de *speckle*, el valor de intensidad media no es adecuado para ponderar la desviación estándar. Fujii et al. [20] introdujeron un enfoque alternativo llamado Diferencias Promedio (AD), también conocido como el descriptor de Fujii. En este descriptor, la diferencia entre las muestras contiguas se pondera por el promedio local mediante la siguiente expresión:

$$AD = \left(\sum_{n=2}^N \frac{|x_n - x_{n-1}|}{|x_n + x_{n-1}|} \right) / N \quad (16)$$

donde $|\cdot|$ indica valor absoluto

3.3.2 Diferencias Generalizadas (Generalized Differences - GD)

Aunque el descriptor AD es muy adecuado para muchas aplicaciones, adolece de dos desventajas: es muy sensible al ruido en regiones de valores de baja intensidad y no es adecuado para detectar señales de *speckle* que varían lentamente. Para adaptarlo a estas situaciones, Arizaga et al. [21] presentaron un descriptor llamado Diferencias Generalizadas (GD), donde las variaciones de intensidad en diferentes escalas de tiempo se toman en cuenta usando la siguiente expresión:

$$GD = \left(\sum_n \sum_l |x_n - x_{n+l}| \right) / N \quad (17)$$

donde n y l son índices que abarcan todos los números posibles de imágenes registradas. Cada valor x_n se resta de cualquier otro valor en X , por lo tanto el resultado no depende de la secuencia pero es muy sensible al número de muestras.

3.3.3 Diferencias generalizadas ponderadas (Weighted Generalized Differences - WGD)

Posteriormente se añadió al descriptor de GD un parámetro adicional p con el objetivo de controlar su sensibilidad. Los elementos de este vector permiten dar diferentes pesos de acuerdo con el espacio de cada resta:

$$WGD = \left(\sum_{n=1}^{N-p} \sum_{l=1}^p |x_n - x_{n+l}| p_l \right) / N \quad (18)$$

El descriptor resultante, llamado Diferencias Generalizadas Pesadas (WGD), fue útil para detectar diferentes tipos de actividades, sin embargo la selección del parámetro p es altamente empírica y limita su aplicación desde el punto de vista práctico.

3.3.4 Resta promedio de intensidades consecutivas (Subtraction Average - SA)

Uno de los descriptores más simples es el promedio de substracción de dos elementos consecutivos de la SSD [22].

$$SA = \left(\sum_{n=1}^{N-1} |x_n - x_{n+1}| \right) / (N - 1) \quad (19)$$

3.4 Comportamiento de los distintos descriptores

Para analizar el comportamiento de los distintos descriptores, incluyendo *TRFG*, se simularon conjuntos de 2000 PS de 512x512 píxeles, utilizando velocidades del difusor (*Diffuser Velocity*) de 1 a 200 en pasos de 2 $\mu\text{m}/\text{imagen}$.

Los gráficos mostrados fueron realizados en base al promedio de los resultados de 512 SSD (variación de 512 píxeles del conjunto de PS), para 50, 200, 500, 1000 y 2000 PS (*samples*) (Fig. 3.2 a 3.4).

3.4.1 Descriptores estadísticos

En la Fig. 3.2 a) muestra la SD como una función de la velocidad del difusor. En todos los casos, el descriptor fue asintótico con el mismo valor. Este descriptor puede ser útil solo para describir velocidades bajas y requiere solo un pequeño número de muestras. Los resultados del descriptor TC (Fig. 3.2 b)) son bastante similares a SD, mostrando una tendencia menos ruidosa que la SD.

La Fig. 3.2 c) muestra que FWHM puede distinguir velocidades de hasta 60 $\mu\text{m} / \text{difuso}$., por encima de ese valor los cambios en la actividad son indistinguibles.

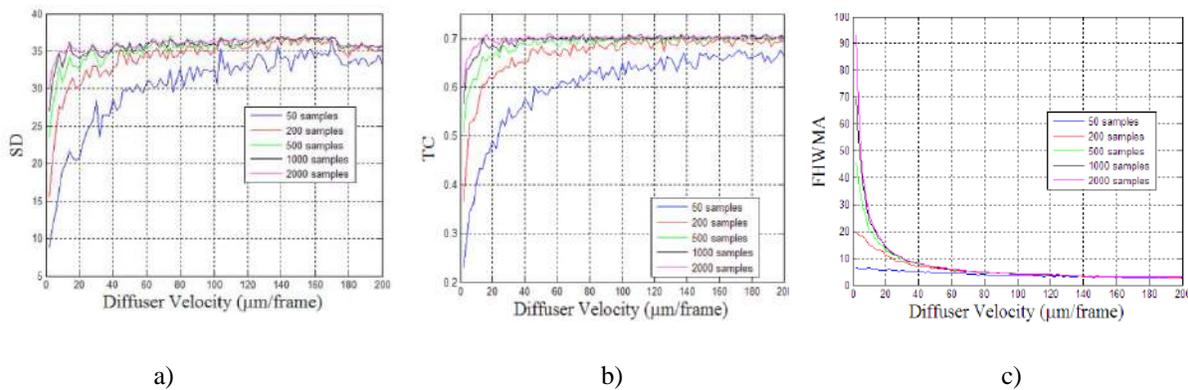


Fig. 3.2 Valores de descriptores estadísticos utilizando diferentes cantidades de muestras Descriptores. a) SD, b) TC y c) FWHMA

3.4.2 Descriptores basados en análisis de frecuencia

El filtro de energía del paso de banda (0,25 Hz a 5 Hz) se muestra en la Fig. 3.3 a). La especificación de pérdidas en cada uno de estos filtros es la siguiente: máximo tolerado en la banda de paso 1dB y pérdidas mínimas requeridas en la banda de rechazo 40 dB. Se usaron filtros de aproximación elíptica (Cauer) porque, a pesar de su mayor complejidad de implementación, exhiben una respuesta de frecuencia más selectiva que la solución de Butterworth [23].

Se observa un comportamiento de linealidad aceptable con el HLR (Fig. 3.3 b) altamente independiente del número de PS con excepción del experimento que usa solo 50 PS.

El MF (Fig. 3.3 c) también muestra una linealidad aceptable con la velocidad del difusor; con valores muy similares cuando se computan más de 200 PS.

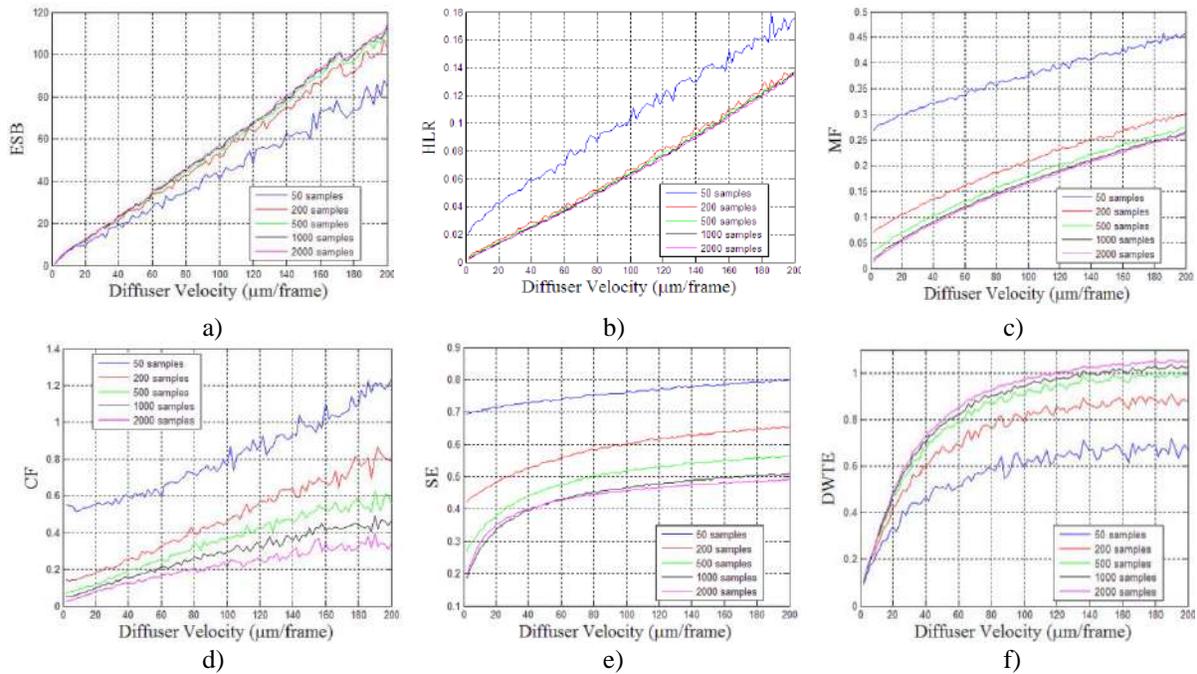


Fig 3.3 Valores de descriptores basados en análisis de frecuencia utilizando diferentes cantidades de muestras.
a) ESB, b) HLR, c) MF, d) CF, e) SE, f) DWTE

Los descriptores CF, SE, y DWTE (DWTE calculados usando Daubechies 8 dB) mostrados en las Fig.s 3.3 d), e) y f) respectivamente, exhiben una alta dependencia con la cantidad de muestras. Las descripciones SE y DWTE no discriminan tan bien como ESB, HLR y MF velocidades más altas que 50 μm /cuadro.

3.4.3 Descriptores basados en el análisis de dominio de tiempo

La Fig.3.4 muestra que los descriptores a) AD, d) SA y e) TRFG son comparables con la velocidad del difusor, no muestran un ruido apreciable y son poco sensibles a la cantidad de PS considerados. Una ventaja de estos descriptores es la capacidad para diferenciar una gama mucho más amplia de tipos de dinámicas.

En la Fig.3.4 b) se puede observar GD como una función constante de la velocidad del difusor; por lo tanto, no es apropiado para caracterizar la actividad de los PS de ebullición puros generados por el desplazamiento de un difusor. Este comportamiento indeseable se supera con el descriptor WGD usando $p = 5$ que se muestra en la Fig. 3.4 c), la tendencia es ruidosa particularmente cuando se consideran pocas muestras.

3.4 Estudio comparativo

Analizando todos los descriptores propuestos, los que exhiben menos dependencia al número de muestras son AD, SA y TRFG, seguidos por ESB y HLR. Se puede apreciar en los gráficos como curvas superpuestas para diferentes cantidades de PS usados.

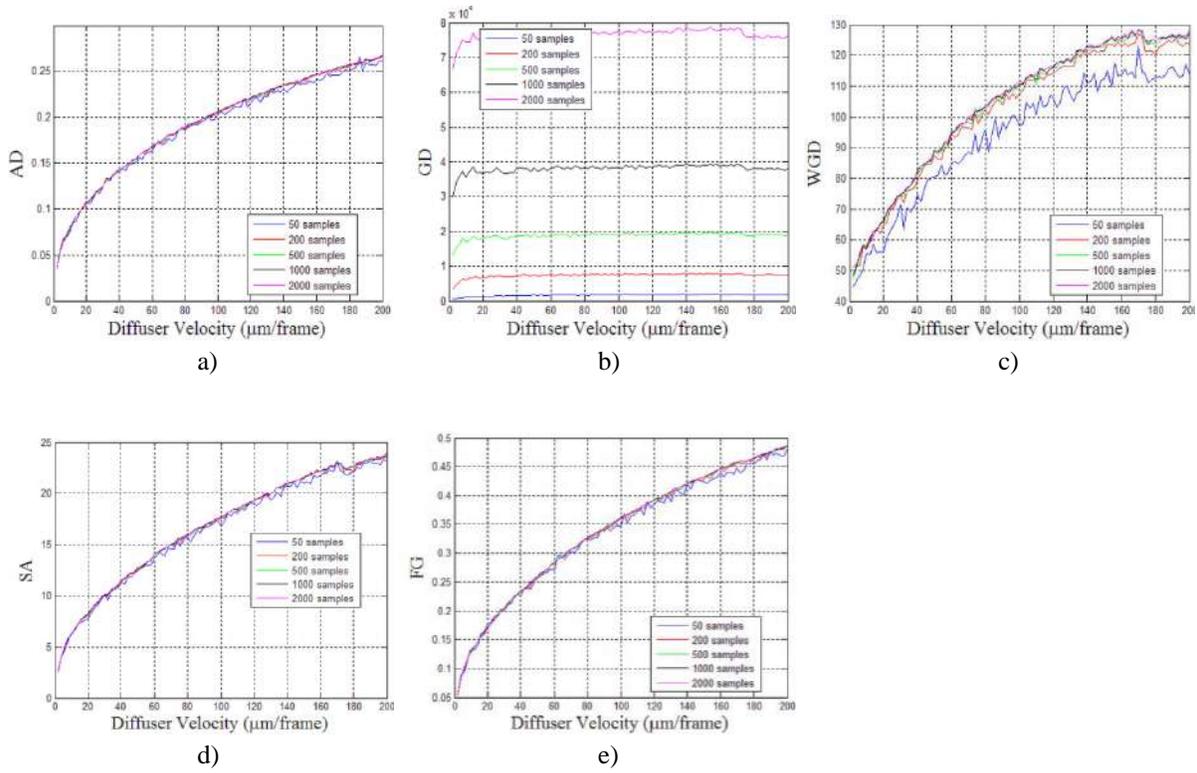


Fig. 3.4 Valores de descriptores basados en el análisis de dominio de tiempo utilizando diferentes cantidades de muestras. a) AD, b) GD, c) WGD, d) SA, e) TRFG

La variación de los valores de los descriptores fue evaluada en función de la variación de la velocidad del difusor y la cantidad de PS considerados. Para cada descriptor fueron calculados: el Coeficiente de Correlación Lineal r_{vd} , el Coeficiente de Variación C_d , la Sensibilidad del Descriptor s_{di} y el Tiempo de Procesamiento TP para cada tamaño de muestra.

- El *Coeficiente de Correlación Lineal (de Pearson)* r_{vd} se calcula para evaluar cuantitativamente la linealidad del valor del descriptor en relación a la velocidad del difusor. Es definido como:

$$r_{vd} = \frac{\sum_{i=1}^L (v_i - \langle v \rangle)(d_i - \langle d \rangle)}{(L-1)\sigma_v\sigma_d} \quad (20)$$

donde v corresponde al valor de velocidad del difusor, d es el valor resultante del descriptor, L es el número de velocidades consideradas, σ son las desviaciones estándar y, $\langle v \rangle$ y $\langle d \rangle$ representan las medias de v y d respectivamente.

- El *Coeficiente de variación* C_d se calcula para analizar el grado de variabilidad en relación con la media calculada sobre los 512 valores. Se define como la razón de las desviaciones estándar σ a la media de la variable descriptiva d :

$$C_d = \frac{\sigma_d}{\langle d \rangle} \quad (21)$$

- La *Sensibilidad del Descriptor*, s_{di} , se utiliza para evaluar la diferencia relativa entre los resultados obtenidos con diferentes números de PS (50, 200, 500 y 1000). Es la diferencia relativa entre el valor obtenido usando i PS (d_i) y 2000 PS (d_{2000}).

$$s_{di} = \frac{|d_i - d_{2000}|}{d_{2000}} \quad (22)$$

- El *Tiempo de procesamiento TP* es el promedio del tiempo transcurrido en el procesamiento de cada SSD en segundos.

A partir de la necesidad de distinguir eficientemente los cambios de velocidad, se puede afirmar que un buen descriptor es aquel que

- exhibe una respuesta lineal con respecto a las tasas de cambio de la muestra (alto r_{vd});
- debe tener una dispersión baja en relación con su valor estimado (C_d bajo);
- debe ser independiente del número de PS utilizados para su cálculo (s_{di} bajo);
- el tiempo de procesamiento TP debe ser reducido, lo que lo haría susceptible de operar en procesos en casi tiempo real.

Tabla 3.1. Evaluación de los distintos descriptores

PS	r_{vd}					C_d					s_{di}				TP [s]				
	50	200	500	1000	2000	50	200	500	1000	2000	50	200	500	1000	50	200	500	1000	2000
SD	0,79	0,65	0,60	0,55	0,54	0,32	0,19	0,13	0,10	0,07	0,16	0,05	0,02	0,01	0,001	0,002	0,004	0,011	0,026
TC	0,79	0,65	0,60	0,52	0,44	0,21	0,12	0,08	0,06	0,05	0,14	0,05	0,02	0,01	0,001	0,002	0,005	0,013	0,030
FWHMA	0,95	0,79	0,66	0,59	0,54	0,26	0,20	0,15	0,12	0,09	0,23	0,10	0,04	0,02	0,115	0,145	0,196	0,304	0,588
ESB	0,98	0,99	0,99	0,99	0,99	0,58	0,29	0,19	0,14	0,10	0,22	0,06	0,02	0,01	0,485	0,499	0,536	0,616	0,757
HLR	0,98	0,99	0,99	0,99	0,99	0,31	0,25	0,17	0,12	0,09	1,10	0,10	0,05	0,02	1,179	1,305	1,190	1,334	1,429
MF	0,99	0,99	0,99	0,99	0,99	0,09	0,10	0,09	0,07	0,05	2,24	0,47	0,15	0,04	1,181	1,304	1,188	1,330	1,424
CF	0,97	0,98	0,98	0,98	0,98	0,35	0,40	0,47	0,50	0,63	3,58	1,26	0,65	0,31	1,188	1,315	1,200	1,343	1,440
SE	0,99	0,95	0,90	0,88	0,85	0,02	0,03	0,04	0,04	0,03	0,78	0,35	0,13	0,03	1,187	1,310	1,195	1,336	1,433
DWTE	0,86	0,86	0,85	0,85	0,85	0,40	0,21	0,13	0,08	0,06	0,35	0,16	0,06	0,03	0,695	0,697	0,714	0,767	0,866
AD	0,96	0,96	0,96	0,96	0,96	0,18	0,10	0,06	0,05	0,03	0,02	0,01	0,00	0,001	0,004	0,013	0,033	0,068	
GD	0,77	0,61	0,57	0,52	0,53	0,31	0,18	0,12	0,09	0,06	0,98	0,90	0,75	0,50	0,007	0,155	1,310	8,441	35,355
WGD	0,95	0,95	0,95	0,95	0,95	0,28	0,15	0,10	0,07	0,05	0,98	0,90	0,75	0,50	0,001	0,002	0,005	0,013	0,054
SA	0,97	0,97	0,98	0,98	0,98	0,20	0,11	0,07	0,05	0,04	0,02	0,01	0,01	0,00	0,001	0,002	0,005	0,014	0,028
TRFG	0,97	0,98	0,98	0,98	0,98	0,11	0,09	0,07	0,05	0,04	0,02	0,01	0,00	0,00	0,006	0,023	0,057	0,113	0,225

En la tabla 3.1 se puede observar:

- La capacidad de los descriptores para identificar la dinámica del proceso evaluada con el coeficiente de correlación r_{vd} . Los altos coeficientes indican una relación lineal con la velocidad simulada. La zona sombreada corresponde a $r_{vd} \geq 0.95$, esta condición se cumple en los descriptores de tiempo (AD, WGD, SA, TRFG) y de frecuencia (ESB, HLR, MF, CF, SE, DWTE) aunque no en los estadísticos (SD, TC y FWHMA) ni en el GD.
- Un descriptor con C_d bajo implica una alta fiabilidad en su uso. Como se puede observar en general el C_d disminuye con el aumento del número de PS, con la excepción de CF. Las celdas sombreadas muestran las mejores habilidades, $C_d < 0.1$.
- La sensibilidad S_{di} que es la capacidad del descriptor para obtener un buen rendimiento aun utilizando una baja cantidad de PS. Las celdas sombreadas muestran los mejores rendimientos, $S_{di} < 0.1$.

- Los tiempos de procesamiento promedio más cortos indicados con celdas sombreadas, $TP < 0.1$.

Como conclusión para muestras simuladas los mejores comportamientos son los de AD, SA y TRFG, todos ellos basados en el dominio del tiempo. Sin embargo, en experimentos con muestras biológicas algunos descriptores no muestran el mismo comportamiento, como se observará en el capítulo 4, ya que en la simulación no pueden ser consideradas las variables propias del objeto analizado. Algunos resultados comparativos con simulaciones fueron publicados en [24], [25], [26] y [27].

3.6 Conclusiones

En el experimento simulado, el conjunto de descriptores basados en estadísticas y GD no tienen un coeficiente de correlación aceptable. El coeficiente de variación es aceptable para la mayoría de los descriptores de experimentos para más de 500 muestras, excepto CF cuya variabilidad es alta en relación con el promedio. Los descriptores basados en análisis de frecuencia como MF, CF, SE y DWTE y también GD y WGD muestran una alta sensibilidad al número de PS utilizados. El tiempo de cálculo es alto para los descriptores basados en el análisis de frecuencia y también para el descriptor GD.

TRFG exhibe el mejor rendimiento, seguido de aquellos basados en el análisis de frecuencia, demostrando que son robustos a los cambios espaciales de intensidad dentro de la muestra, de acuerdo con el análisis de correlación en las simulaciones.

3.7 Referencias

- [1] Rabal H, Arizaga R, Cap N, Grumel E, Trivi M. (2003). Numerical model for dynamic speckle: an approach using the movement of scatterers. *Journal of Optics A: Pure and Applied Optics*. S381-S385.
- [2] Equis S, Jacquot P. (2006). Simulation of speckle complex amplitude: advocating the linear model. En: *Speckle06: Speckles, From Grains to Flowers. International Society for Optics and Photonics 6341*, 634138-634144.
- [3] Federico A., Kaufmann G.H., Galizzi G.E., Rabal H., Trivi M, Arizaga R. (2006). Simulation of dynamic speckle sequences and its application to the analysis of transient processes. *Optics Comm.* 260, 493-499.
- [4] Sendra GH, Rabal H, Triv M, Arizaga R. (2009). Numerical model for simulation of dynamic speckle reference patterns. *Optics Comm.* 282 (18) 3693-3700.
- [5] Rabal H.J., Braga R. A ed. (2009). *Dynamic Láser Speckle and Applications*. CRC Press. Boca Raton, USA ISBN 978-1-4200-6015-7.
- [6] Briers D., Duncan D.D, Hirst E, et al.(2013). Láser speckle contrast imaging: theoretical and practical limitations. *J. Biomed. Opt.* 18 (6) 066018-066028.
- [7] Briers D. (1975). A note on the statistics of láser speckle patterns added to coherent and incoherent uniform background fields and a possible application for the case of incoherent addition. *Optical and Quantum Electronics*, 7, 422-424
- [8] Rabal H, Arizaga R, Cap N, Trivi M, Romero G, Alanís E. (1996). Transient phenomena analysis using dynamic speckle patterns. *Opt. Eng.* 35 (1). 57-62.
- [9] Passoni L.I., Sendra G.H., Arizmendi C.M. (2009). Frequency Analysis . In: *Dynamic Láser Speckle and Applications*, Rabal H, Braga RA Ed. CRC Press Taylor & Francis Group.. ISBN-13: 978-1420060157.

- [10] Murialdo SE, Passoni LI, Guzman MN, Sendra GH, Rabal H, Trivi M, Gonzalez JF. (2012). Discrimination of motile bacteria from filamentous fungi using dynamic speckle. *J Biomed Opt.* 17 (5), 056011. doi: 10.1117/1.JBO.17.5.056011.
- [11] Fujii H, Asakura T, Nohira K, Shintomi Y and Ohura T . (1985). Blood flow observed by time-varying láser speckle. *Opt Lett.* 10 (3) 104-106. <http://dx.doi.org/10.1364/OL.10.000104>.
- [12] Aizu Y, Asakura T. (1991). Bio-speckle phenomena and their application to the evaluation of blood flow. *Opt Láser Technol* 23(4). 205-219.
- [13] Shannon C.E.(1948). A Mathematical Theory of Communication. Bell System Technical Journal 27 (3): 379–423.
- [14] Viertio-Oja H, Maja V, Sarkela M et al. (2004). Description of the entropy algorithm as applied in the Datex-Ohmeda S/5 Entropy Module. *Acta Anaesthesiol Scand* . 48, 154–161.
- [15] Blanco S, D’Attellis C, Isaacson S, Rosso O, Sirne R. (1996). Time-frequency analysis of electroencephalogram series (II): Gabor and wavelet transform. *Phys Rev. E.* 54, 6661-6672.
- [16] Rosso O, Blanco S, Yordanova J, Kolev V, Figliola A, Schürman M, Basar E. (2001). Wavelet entropy: a new tool for analysis of short duration brain electrical signals. *J Neurosc Meth* 105. 65-75.
- [17] Braga R.A, Horgan G.W, Enes A.M, Miron D, Rabelo GF, Barreto Filho JB. (2007). Biological feature isolation by wavelets in biospeckle láser images, *Comput Electron Agric*, 58(2), 123-132.
- [18] Ribeiro K.R Jr. Sáfaci T. and Horgan G. (2013). Comparison between Fourier and Wavelets Transforms in Biospeckle Signals. *Appl Math*, 4 (11), 11-22. doi: 10.4236/am.2013.411 A3003.
- [19] Passoni L.I, **Dai Pra** A.L, Rabal H, Trivi, Arizaga R. (2005). Dynamic speckle processing using wavelets based entropy. *Opt Commun* 246. 219-228.
- [20] Fujii H, Nohira K, Yamamoto Y, Ikawa H, Ohura T. (1987). Evaluation of blood flow by láser speckle image sensing. Part 1. *Appl Optics* 26(24), 5321-5325.
- [21] Arizaga R, Cap N, Rabal H, Trivi M. (2002). Display of local activity using dynamical speckle patterns. *Opt Eng* 41(2). 287-294.
- [22] Braga Jr. R, Silva B, Rabelo G, Marques R, Enes A., Cap N, Rabal H, Arizaga R, Trivi M, Horgan G. (2007). Reliability of biospeckle image analysis. *Opt Lasers Eng.* 45(3) 390-395.
- [23] Bianchi G. y Sorrentino R. (2007). *Simulación y diseño de filtros electrónicos* . McGraw-Hill Professional. 17–20. ISBN 978-0-07-149467-0.
- [24] Ortiz C.C, Sendra G.H, Rabal H.J, Arizaga R, Trivi M. (2008). .Dynamic speckle algorithms comparison using receiver operating characteristic. *Opt Eng* 47 (05), 057005.
- [25] **Dai Pra** A. L., Passoni L. I., Sendra G. H., Trivi M. & Rabal H. J. (2015). Signal Feature Extraction Using Granular Computing. Comparative Analysis with Frequency and Time Descriptors Applied to Dynamic Laser Speckle Patterns, *In J Comput Intell Systems*, 8, 28-40. DOI: 10.1080/18756891.2015.1129589
- [26] G. H. Sendra, A. L. **Dai Pra**, L. I. Passoni, R. Arizaga, H. J. Rabal, M. Trivi . (2010). Biospeckle descriptors: a performance comparison. *Speckle 2010: Optical Metrology*, A. Albertazzi, G. Kaufmann Eds. Proc. SPIE, 7387, 73871K.
- [27] Guzman, M., Meschino G.J., **Dai Pra** A.L., Trivi M., Passoni, L.I., Rabal H. (2010). Dynamic laser speckle: Decision models with computational intelligence techniques. Conference: *Speckle 2010: Optical Metrology*. September 2010. Proceedings of SPIE - The International Society for Optical Engineering 7387. DOI:10.1117/12.870688

Capítulo 4

Aplicación de la técnica propuesta

La metodología TRFG fue aplicada a distintos experimentos:

1. Adquisición de DLS durante secado de pinturas
 - a. Muestras de etapas de secado de pinturas látex, consideradas como una dinámica estacionaria.
 - b. Proceso de secado rápido en esmaltes de uñas, donde el nivel de actividad cambia durante el muestreo (dinámica no estacionaria).
 - c. Detección de grosores de capas de pintura.
2. Adquisición de DLS en muestras biológicas
 - a. Para la detección de viabilidad de semillas de maíz.
 - b. Para la determinación de regiones en semillas de maíz con la finalidad de identificar su uso potencial.
 - c. Detección de golpes en manzanas antes de hacerse visibles.
 - d. TRFG utilizado para entrenar redes SOM.
3. Ultrasonido
 - a. Detección de tumores oculares.
 - b. Reclutación alveolar pulmonary.
4. Detección de actividad en videos

4.1. Secado de pinturas

En algunos procesos de fabricación en los que interviene la aplicación de pinturas, el monitoreo y control del grosor de las capas de pintura y del tiempo de secado son a menudo tareas críticas. Algunos de los dispositivos de monitoreo utilizados están basados en el contacto, por lo cual no son convenientes para capas de pintura húmedas, como pruebas ultrasónicas, pruebas de corriente torbellino y pruebas electromagnéticas. Otros métodos basados en procedimientos de no contacto no son prácticos, como la tomografía de coherencia [1] que no es aconsejable para capas opacas, la tomografía de onda térmica, la microscopía [2] que requieren mucho tiempo para construir una imagen de sección del objeto y la tomografía de Tera hercio [3] que necesita una estructura óptica compleja.

La aplicación de DLS al secado de pinturas fue reportada en [4], [5] y [6] por Amalvy et.al., considerando superficies homogéneas. Cuando la pintura es aplicada en superficies irregulares, la evaluación del proceso de secado debe ser realizada considerando los desniveles de la superficie a evaluar, que generan distintos espesores de pintura.

La granularidad computacional referente al secado de pinturas fue evaluada con distintos experimentos:

1. Estimación del tiempo de secado en capas de pintura látex en una superficie homogénea, considerado como una dinámica estacionaria en cortos períodos de tiempo durante el proceso.
2. Estimación del tiempo de secado en una capa de esmalte de uñas de secado rápido, considerado como una dinámica no estacionaria.
3. Identificación de grosor de la capa de pintura sobre una superficie irregular, donde se evalúa la imagen completa.

Diversos algoritmos orientados a procesar un patrón completo están basados en procesos estadísticos y en el procesamiento clásico de señales, ellos han sido descritos en [7], [8] y [9], los cuales permitieron hacer estudios comparativos. Resultados de la aplicación de TRFG fueron publicados en [10] y [11].

4.1.a. Secado de pinturas látex (dinámica estacionaria)

En el secado de pinturas látex, el fenómeno de speckle dinámico se presenta como un instrumento útil para evaluar el tiempo de secado de superficies pintadas. Su sensibilidad frente al movimiento de centros dispersión y cambios de índices de refracción ayuda a determinar las diferentes etapas del secado. Este caso de estudio fue contrastado con mediciones llevadas a cabo con medidas gravimétricas que permiten evaluar la calidad de los resultados obtenidos con la nueva técnica.

El experimento fue realizado con muestras de pintura látex (de secado lento) extendida sobre un sustrato de cristal. Para iluminar las muestras fue utilizado un láser He-Ne de baja potencia atenuado (5mW, λ -633 nm).

Un total de 23 muestras fueron registradas en intervalos de 4 minutos durante el tiempo de secado. Por cada una, considerada como una dinámica estacionaria, se realizaron 512 adquisiciones sucesivas de PS en intervalos de 0.08 seg. con las cuales se formaron THSP (descritos en Cap. 2). En la fig 4.1 se muestran algunos THSP de la secuencia, 8 de los 23, es decir muestras cada 12'. A simple vista es posible observar como tienden a formar franjas que indican la disminución de actividad de los *speckles* en el tiempo.

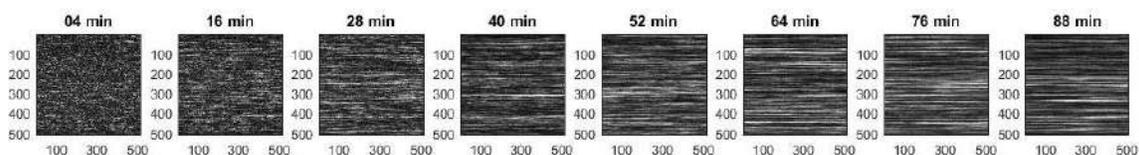
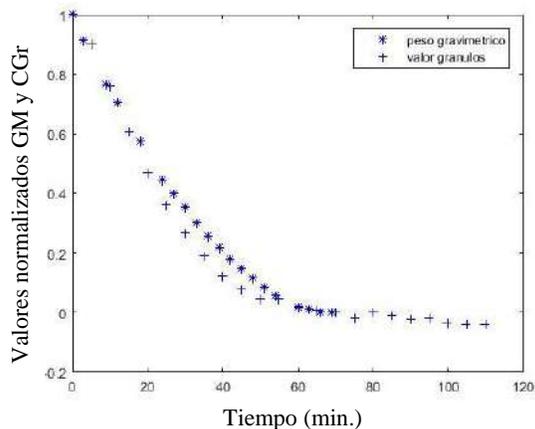


Fig. 4.1 THSPs obtenidos en intervalos de 12 minutos

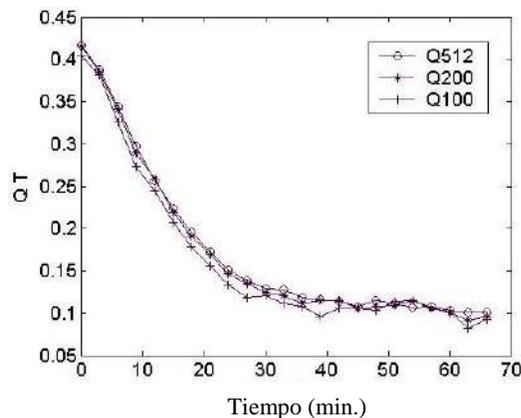
La metodología explicada en el Cap. 2 para el conteo de gránulos (CGr) fue aplicada a cada una de las 512 filas de cada THSP. Los 512 resultados fueron promediados, obteniéndose así un único valor para cada THSP. La Fig. 4.2 a) representa los valores obtenidos comparados con los valores de porcentaje de pérdida de peso obtenidos mediante medición gravimétrica (GM) para los distintos THSP, ambos normalizados en el intervalo [0,1] como se muestra en la tabla 4.1. En el trabajo publicado en [11], estos resultados son comparados con el Momento de Inercia, aplicado a la matriz de co-ocurrencia de segundo orden del THSP, publicada por Amalvy et al. [4]. Los resultados fueron semejantes, pero el tiempo computacional de aplicar granularidad es tres veces menor y muestra una mejor aproximación a GM durante el primer tercio del tiempo de secado.

Para testear la sensibilidad al tamaño de la muestra, la metodología es aplicada a cada THSP completo de 512x512 pixels, y a secciones de 200x200 píxeles y 100x100 píxeles, obteniéndose los valores de Q_{512} , Q_{200} y Q_{100} . La Fig. 4.2b) muestra la comparación de los resultados, pudiendo observarse que los valores obtenidos con los diferentes tamaños de THSP no muestran diferencias significativas; de ahí el método propuesto podría ser puesto en práctica con menor cantidad de PS.

En la Fig. 4.3 se muestra un estudio comparativo de la aplicación de algunos descriptores a THSP de pintura en distintas etapas de secado (presentado en [12] y [13]), para determinar la sensibilidad de cada uno, los métodos comparados fueron los mostrados en el cap. 3: AD, FWHMA, TC, SD, SA, WGD, TRFG, HLR, CF, SE, CF, ESB, WGD, MF, DW.



a)



b)

Fig 4.2 a) Comparación con valores normalizados de Q_T y peso gravimétrico.
 b) Comparación de los resultados Q_T para T 512, 200 y 100 muestras

Tabla 4.1. Peso gravimétrico y resultados obtenidos por granularidad computacional

Tiempo (min.)	GM (% diferencia masa)	GM normalizado	Muestra	Tiempo (min.)	CGr (Cantidad Gránulos prom.)	CGr normalizada	Q_{512} (CGr/512)
0	0.9860	1	1	0	213.3242	1.0000	0.4166
3	0.9730	0.9161	2	4	198.5781	0.9087	0.3878
9	0.9500	0.7677	3	8	175.9844	0.7687	0.3437
12	0.9400	0.7032	4	12	152.1777	0.6212	0.2972
18	0.9200	0.5742	5	16	131.0898	0.4906	0.2560
24	0.9000	0.4452	6	20	114.6777	0.3889	0.2240
27	0.8930	0.4000	7	24	100.0586	0.2984	0.1954
30	0.8860	0.3548	8	28	87.9102	0.2231	0.1717
33	0.8780	0.3032	9	32	77.6094	0.1593	0.1516
36	0.8710	0.2581	10	36	70.5449	0.1156	0.1378
39	0.8650	0.2194	11	40	65.7344	0.0858	0.1284
42	0.8590	0.1806	12	44	65.4414	0.0839	0.1278
45	0.8540	0.1484	13	48	60.8438	0.0555	0.1188
48	0.8490	0.1161	14	52	59.4297	0.0467	0.1161
51	0.8440	0.0839	15	56	58.4336	0.0405	0.1141
54	0.8400	0.0581	16	60	55.5195	0.0225	0.1084
60	0.8340	0.0194	17	64	58.6250	0.0417	0.1145
63	0.8330	0.0129	18	68	56.8867	0.0309	0.1111
66	0.8310	0	19	72	54.7500	0.0177	0.1069
69	0.8310	0	20	76	55.3633	0.0215	0.1081
			21	80	52.7793	0.0055	0.1031
			22	84	51.8828	0	0.1013
			23	88	51.8906	0	0.1013

Con el objetivo de lograr una clara diferenciación de los tiempos de secado, se recompone una muestra a partir de tres muestras con igual cantidad de PS capturados en momentos diferentes: al iniciar el ensayo (con mayor actividad), a los 180 min.(actividad mediana) y a los 210 min. (poca

actividad). Se secciona la parte superior de cada uno de los PS adquiridos al inicio del ensayo, la inferior y central de los PS adquiridos a los 180 min y la central de los PS adquiridos a los 210 min y se genera un nuevo PS para cada instante (ver Fig. 4.3 a)). En la Fig. 4.3 b), cada cuadro muestra el resultado obtenido con cada descriptor aplicado a la muestra resultante de la recomposición. Se puede observar que TRFG marca claramente cada etapa.

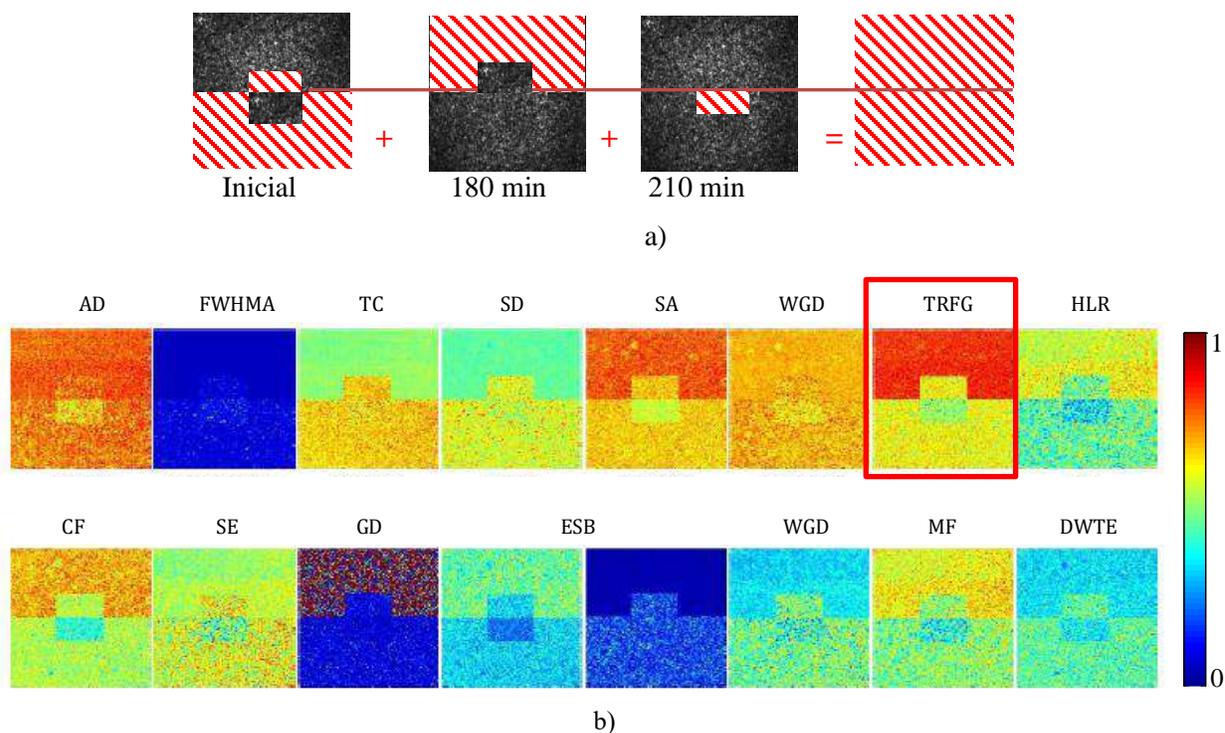


Fig.4.3. Comparación de metodologías en secado de pinturas en distintos tiempos. a) Distribución de los tiempos para cada cuadro. b) Resultados con distintas metodologías

4.1.b. Secado de esmaltes de secado rápido (dinámica no estacionaria)

En este experimento, la muestra fue producida mediante una pincelada con esmalte de uñas de secado rápido sobre un cristal y los PS fueron registradas con propagación libre (con una cámara CCD sin lente). De este modo, rayos de todos los puntos dentro del área iluminada contribuyen a la intensidad del *speckle* en cualquier punto de la imagen observada. Condiciones ideales fueron asumidas en la producción de PS para mantener la intensidad de láser constante durante la adquisición de datos. La distancia a la superficie fue ajustada de modo que los tamaños de los *speckles* fuesen bien resueltos por la cámara CCD. Cada imagen fue obtenida en intervalos de 0.08 seg. aproximadamente.

En este caso, como en el caso anterior, cada PS obtenido es cuasi homogéneo, por lo tanto sólo los píxeles de una misma columna de cada adquisición del PS fueron seleccionados para su tratamiento. La Fig. 4.4 muestra una imagen formada por esas columnas (THSP). Este THSP posee 390 columnas correspondientes a cada una de los 390 PS de una secuencia que muestra la evolución de la pintura desde que es aplicada hasta que se va secando.

Al inicio la intensidad de los *speckles* varía aleatoria y rápidamente en la presencia de alta actividad, y luego la actividad se hace más lenta y la intensidad de los *speckles* es conservada y

puede ser reconocida en columnas sucesivas. Cada fila del THSP constituye una serie de tiempo con cambios de intensidad

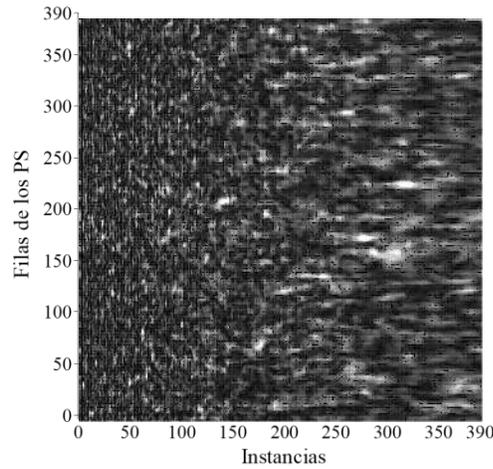


Fig. 4.4 Único THSP de una muestra de esmalte de secado rápido

La Fig. 4.5 describe el proceso aplicado a una de las series correspondiente a una fila del THSP. Los dos primeros gráficos muestran los correspondientes niveles de grises y sus respectivos valores en la serie de tiempo. A continuación se muestran los valores de pertenencia correspondientes a los conceptos difusos: oscuro, medio y claro, y gránulos que determinan. Puede observarse que los primeros gránulos para todos los conceptos son pequeños (alta actividad) y alternados, haciéndose más grandes y definidos más tarde (actividad lenta). Finalmente, el último gráfico muestra la densidad de gránulos (Q_T) como una función de tiempo cuando la TRFG es aplicada. Es importante indicar que los métodos tradicionales requieren la evaluación de períodos de tiempo grandes para calcular un índice de actividad, y utilizar ventanas independientes de la muestra para estimar los distintos grados de actividad en cada una de ellas, los resultados fueron publicados en [10].

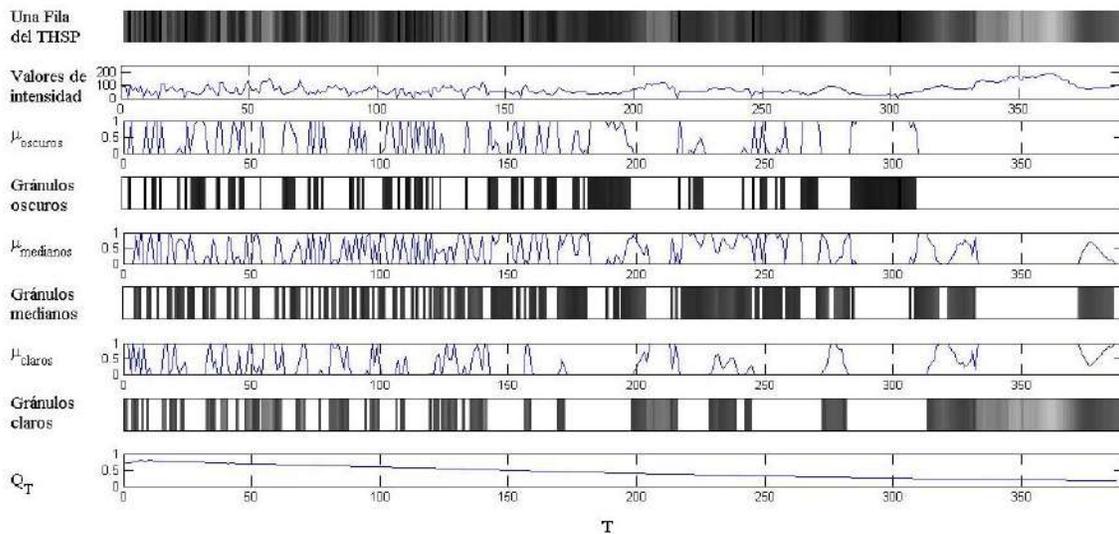


Fig. 4.5 Distribución de gránulos para una fila de un THSP de acuerdo a valores de pertenencia en los respectivos conjuntos difusos

La metodología propuesta procesa las señales de un modo continuo. La Fig. 4.6 a) muestra los resultados obtenidos para todo el THSP como una imagen de intensidad. Q_T es calculado para T de 1 a 390 para cada fila y cada valor normalizado en $[0,255]$ es mostrado como un píxel de una imagen. La imagen de intensidad muestra la disminución de actividad en forma gradual. La diferencia de intensidad entre filas podría ser atribuida al grosor de la pincelada o ser parte del efecto *speckle*. En este caso se puede observar cómo Q_T podría utilizarse para realizar procesos en tiempo real. La Fig. 4.6 b) muestra la diferencia entre la evaluación en forma continua y la evaluación con pequeñas ventanas deslizantes de tan solo 10 píxeles.

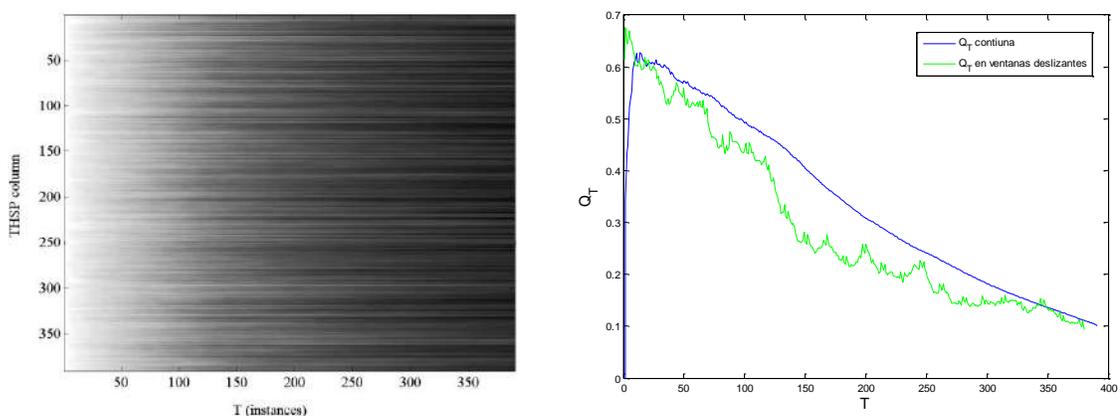


Fig. 4.6. Resultados Q_T , a) como imagen de intensidad, b) proceso en tiempo real y en pequeñas ventanas deslizantes

4.1.c. Grosor de capas de pintura

Como con los experimentos anteriores se obtuvieron resultados adecuados para describir diferentes etapas en el proceso de secado de pinturas y es aceptado que diferentes grosores de la capa de pintura están correlacionados con diferentes tiempos de secado, se evalúa con otra prueba la capacidad de descubrir una topografía oculta bajo una capa de pintura.

Esta prueba fue realizada extendiendo una capa fina de pintura sobre un objeto con una superficie irregular conocida, una vieja moneda argentina de 10 centavos. Se espera que las regiones donde la capa de pintura es más delgada sequen más rápido por poseer menos actividad de evaporación que donde la capa es más gruesa y por consiguiente estará activa más tiempo. En este caso las distintas regiones del objeto iluminado difieren en su actividad, por lo que el proceso se realiza para cada píxel de los PS, obteniéndose un descriptor para cada uno [11] y [13].

En este caso se utilizó un haz de láser de baja potencia expandido del tipo He-Ne (5mW a 10 mW, $\lambda \sim 633$ nm) para iluminar una región amplia de la muestra. Los PS no fueron obtenidos por propagación libre sino que son imágenes de “campo lejano” formadas en un objetivo, con valores altos de apertura de diafragma (usualmente $f=50$ mm, $f/\# = 16$).

Se cuenta con una secuencia de 400 PS de 300×300 píxeles con una resolución de 8 bits a una frecuencia de 4 Hz., partiendo del supuesto que el recubrimiento no sufrió un proceso de secado significativo durante la adquisición de los PS. Por cada uno de los 300×300 píxeles se obtiene una serie a través de las 400 imágenes y un descriptor granular Q_T es obtenido para cada uno de los píxeles. Con cada descriptor ubicándolo en la posición del píxel correspondiente, se recompone una nueva imagen, la cual se normaliza en el rango $[0,255]$ y en ella se podrán diferenciar la actividad en función del valor de intensidad.

En la Fig. 4.7 se muestra, a) una imagen de una moneda similar a la utilizada en el experimento, b) un PS en donde no es posible distinguir la Fig. de la moneda y en c) el resultado del procesamiento con TRFG. Esta última es la imagen de actividad resultante al aplicar la metodología propuesta a cada uno de los píxeles de la secuencia de PS, donde cada píxel corresponde al valor Q_T normalizado en $[0,255]$. Los valores de actividad resultantes reproducen la topografía de la moneda no visible en los PS con suficiente detalle. Los tonos más oscuros de la moneda son las regiones de relieve más alto, que se corresponden con la capa más delgada de pintura, que es la zona más seca o de menor actividad. Las zonas más brillantes son depresiones topográficas que indican áreas con una capa más gruesa de pintura, más húmeda y por lo tanto más activa. Como ejemplo se muestran valores de Q_T en una zona más activa y una menos activa con las correspondientes señales.

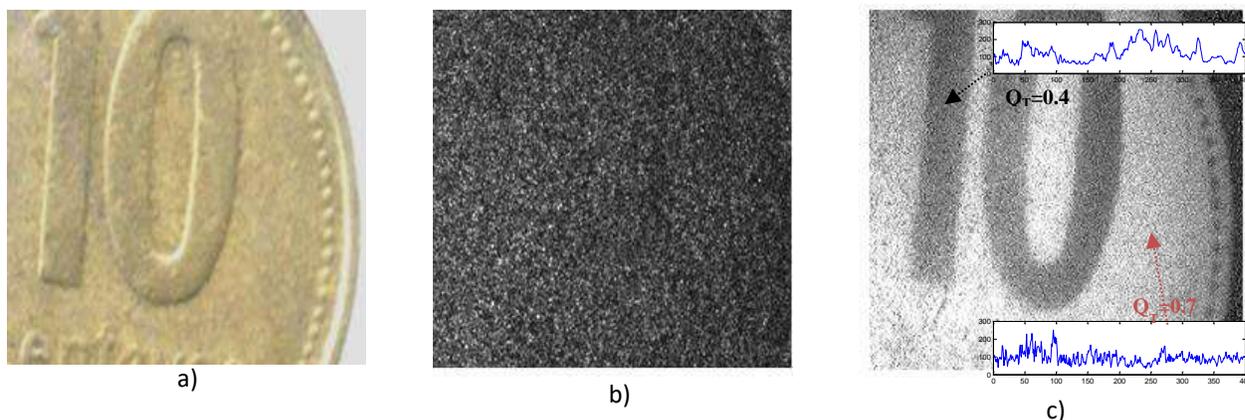


Fig. 4.7. a) Topografía a identificar. b) PS
c) Imagen de actividad, mostrando la topografía de la moneda

Los distintos métodos comparados con TRFG en el Cap. 3 fueron aplicados al experimento, como se muestra en la Fig.4.8. Se comparan además los resultados con el total de patrones (500) y con solo los 20 primeros patrones, observándose que TRFG es el menos sensible a una menor cantidad de patrones.

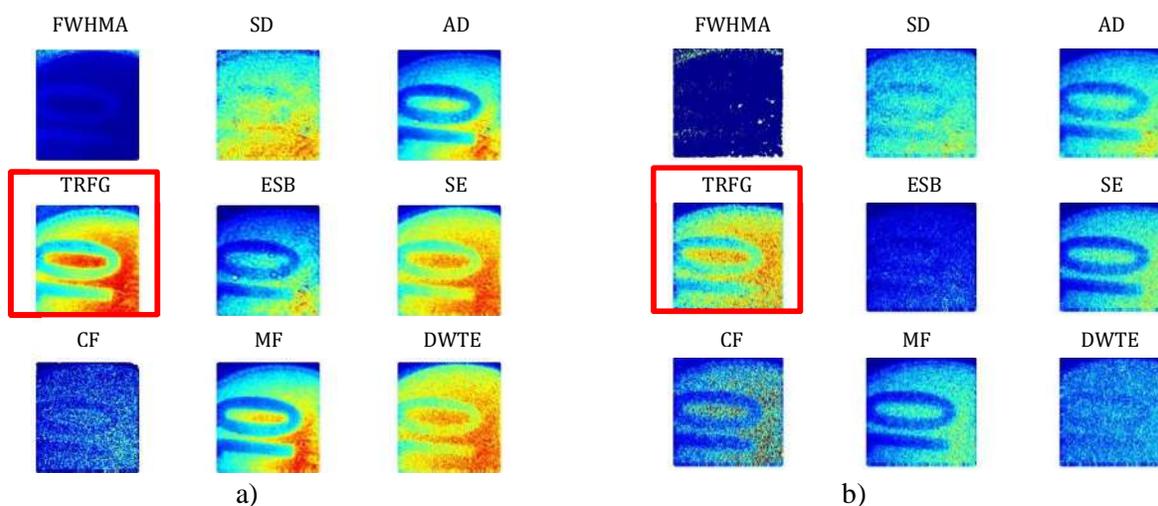


Fig. 4.8. Resultados comparativos obtenidos con TRFG y otras metodologías
a) con los 500 PS, b) con los primeros 20 PS

La Fig. 4.9 a) muestra una secuencia de imágenes de actividad. Solo son mostrados los resultados en intervalos de a 20 PS, con el fin de observar la mejora progresiva de la calidad de la imagen y el tiempo en el que es posible visualizar la topografía. Al mostrar los resultados en intervalos fue posible observar que la cantidad de PS superaba ampliamente el tiempo de secado, lo cual degrada los resultados de cualquier método empleado [15].

Los resultados fueron analizados mediante la observación de gráficos de dispersión 3D (Fig. 4.9 b). Como la representación de todos los píxeles de todas las muestras es confusa y computacionalmente lenta dado el volumen de información (300x300x400), se computa TRFG cada 20 PS y espacialmente se promedian ventanas de 10 x10 píxeles, evitando así una superposición de puntos que dificultaría la visualización de los resultados.

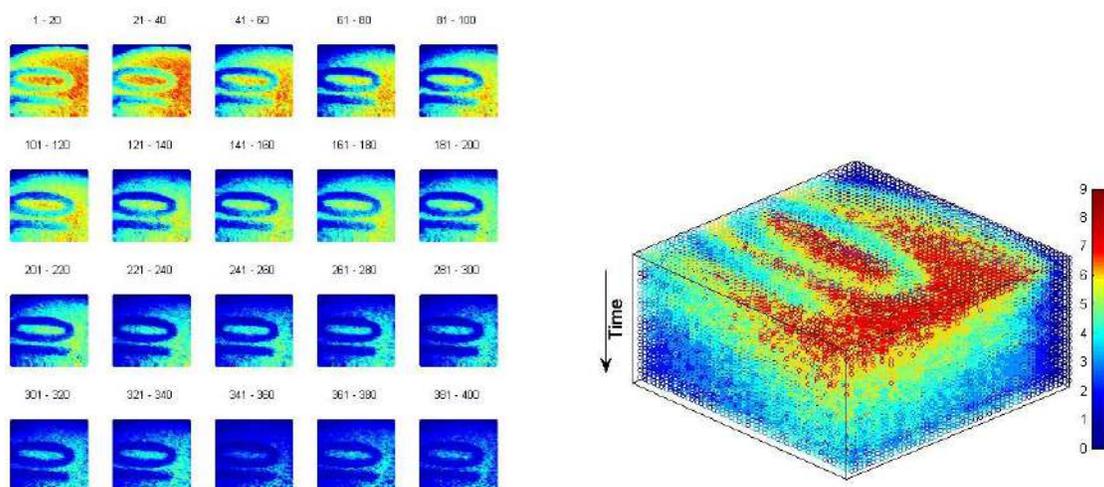


Fig.4.9. Evolución del experimento en el tiempo. a) 2D, b) 3D

4.2. Experiencias en muestras biológicas

4.2.a Viabilidad de semillas de maíz

En la ingeniería agrícola, la evaluación de viabilidad de semillas antes y después del almacenaje es un tema de interés. A pesar de que el único procedimiento eficaz es la germinación real, que toma entre 4 y 28 días, la viabilidad para la siembra por lo general es probada con el test de germinación tetrazolium (TTC), considerado un test rápido, ya que toma de 24 a 48 horas [16]. La metodología de granularidad computacional, una vez obtenidos los PS, permite obtener una respuesta en pocos segundos. Los resultados fueron publicados en [10].

En este caso la experimentación fue llevada a cabo con una semilla hidratada cortada longitudinalmente. Para iluminar la muestra completa se empleó un láser He-Ne de baja potencia expandido (5mW, $\lambda=633$ nm). Se tomó una secuencia de 100 PS de 480x250 píxeles de resolución.

En la Fig. 4.10 a) se muestra una de las imágenes de la secuencia, estas imágenes son ruidosas como todos los PS, con algunos cambios leves de luminosidad, pero donde las partes de la semilla no son claramente distinguibles. En la Fig. 4.10 b) se observa un esquema de la semilla, para identificar las distintas partes de la misma.

La Fig. 4.10 c) muestra la imagen de actividad obtenida como resultado de representar la cantidad de gránulos con la metodología TFG (*Temporal Fuzzy Granularity*). En la imagen se distingue claramente el **cotiledón**, cuyo objetivo es asegurar la nutrición y el desarrollo de la plántula, ocupa gran parte de la semilla siendo el embrión; contiene dos formas de ángulos, que corresponden al **coleóptile** desde donde saldrán las primeras hojas de la plántula una vez que la semilla ha germinado y la **radícula** que da origen a las primeras raíces que surgirán de la semilla cuando ésta se encuentre en proceso de germinación. Distinguir mayor actividad en el **coleóptile** y la **radícula** indica que la semilla es apta para la germinación.

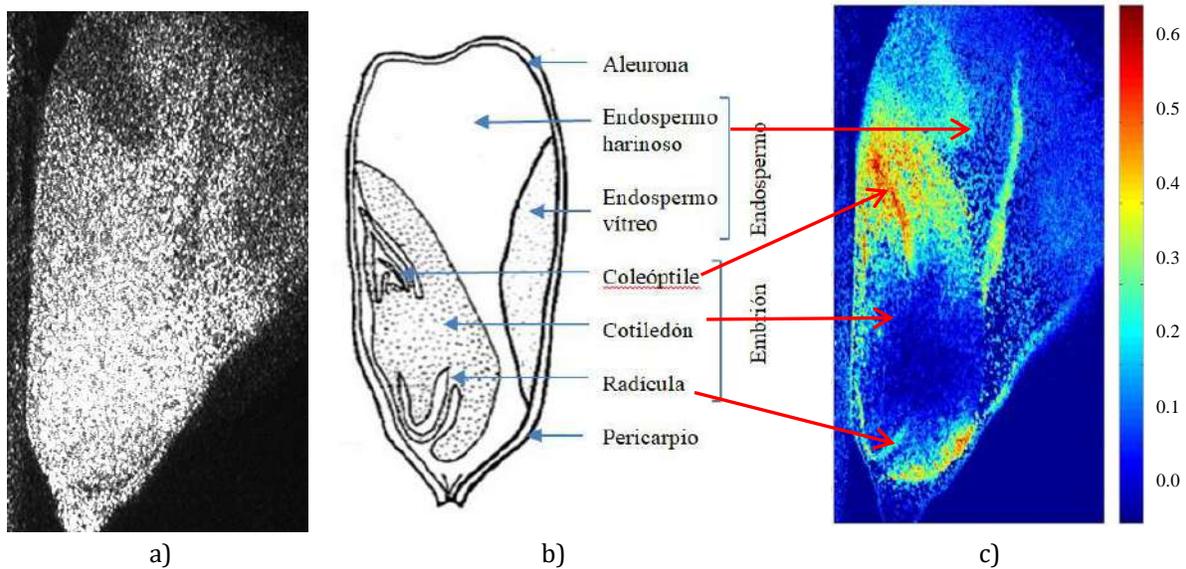
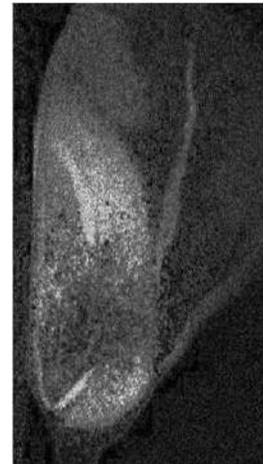
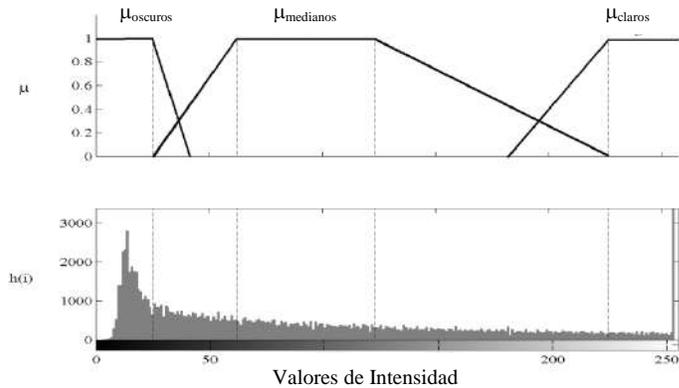


Fig.4.10 Semilla de maíz. a) PS, b) Esquema de partes de la semilla, c) Imagen de actividad

En la Fig. 4.11 a) se muestra el histograma de los valores de intensidad de un PS, que permite determinar las funciones de pertenencia a los conjuntos difusos claros, medianos y oscuros con sus respectivas funciones de pertenencia. En este caso hay un predominio de píxeles de baja intensidad, por lo cual la función de pertenencia del conjunto oscuro es más acotada que las otras funciones de pertenencia. La Fig. 4.11 b) muestra los valores normalizados de Q_{100} como rasgo de intensidad. Esta imagen de actividad muestra diferentes niveles de intensidad conforme a la actividad en las diferentes regiones de la semilla, donde una región de alta intensidad es relacionada con un alto número de gránulos (mayor actividad) mientras una región de intensidad baja es asociada con un número bajo de gránulos (menor actividad).

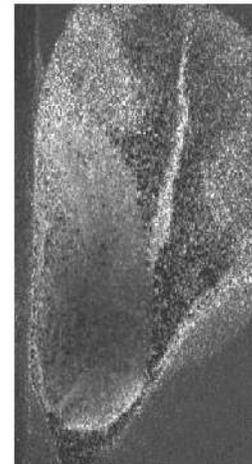
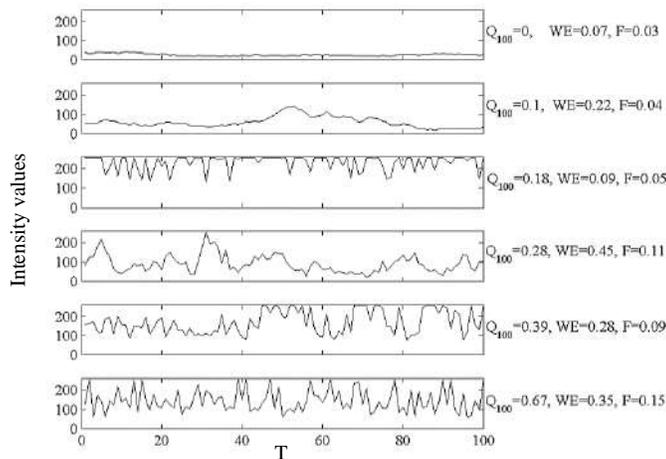
La Fig. 4.12 a) muestra algunas señales correspondientes a diferentes regiones de la semilla y valores de actividad correspondientes a diferentes metodologías y el tiempo medio de procesamiento empleado por cada una. Las metodologías aplicadas son: TFG (Q_{100}), entropía basada en la descomposición wavelet (WE) y frecuencias medias (F). Se puede observar que los valores Q_{100} presentan un amplio rango de variación, siendo más sensible a los cambios de grado de actividad. Los tiempos promedio de procesamiento han sido: WE=0.4s, F=0.3s, TFG=0.01s, destacando que TFG emplea un tiempo de procesamiento significativamente menor.



a) b)
Fig. 4.11 a) histograma de un PS de maíz, b) imagen de actividad en niveles de intensidad

La Fig. 4.12 b) es la imagen de actividad lograda por medio del procesamiento de la secuencia de imágenes con la entropía de Shannon de la descomposición *wavelets*, como propone Passoni et al. [9], de donde se obtienen los valores WE. Los resultados sobre este experimento fueron publicados en [10].

Comparando las imágenes obtenidas (Figs. 4.11 b) y 4.12 b)), puede observarse que ambas metodologías realizan una segmentación similar de las regiones diferentes de la semilla. Sin embargo, en la imagen obtenida con la metodología de TFG, el fondo (región no activa) se ve como una región oscura uniforme y se diferencian más claramente las partes vitales.



a) b)
Fig. 4.12. a) Resultados con distintas SSD de la muestra de maíz con distintos descriptores
b) Imagen de actividad obtenida con WE

Además de los resultados esperados, la Fig. 4.13 muestra imágenes de actividad obtenidas en relación a la acumulación del peso de un tipo de gránulo (pertenencia al conjunto difuso: oscuro, medio o claro). En cada imagen resaltan distintas partes de semilla. Este nuevo parámetro podría ser

relacionado con particularidades diferentes en las señales correspondientes a cada región, que podrían ser utilizadas para la caracterización de cada parte de la semilla. En la Fig 4.13 a), que surge de los gránulos oscuros, se destaca el endospermo. En la Fig.4.13 b), correspondiente a gránulos medios, se destaca el coleóptile y la radícula y en a Fig. 4.13 c), correspondiente a gránulos claros, se destaca el cotiledón.

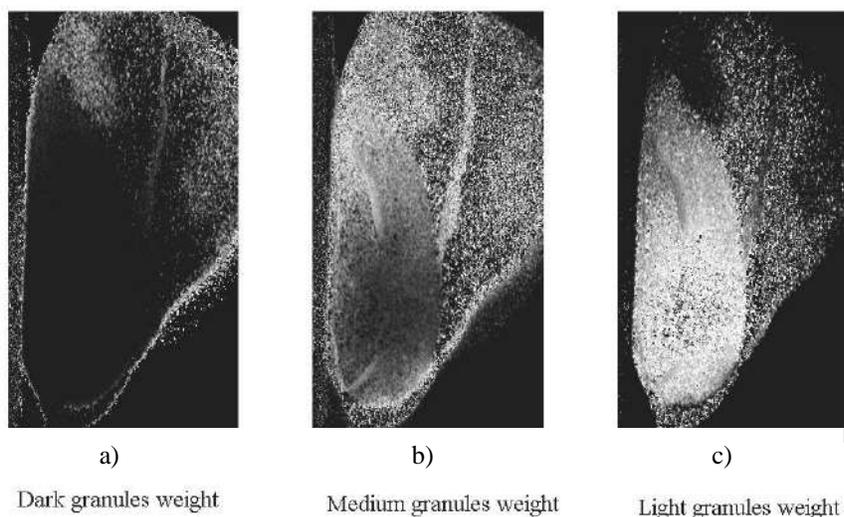


Fig. 4.13 Cuantificación del peso o pertenencia de un tipos de gránulo, a) gránulos oscuros, b) gránulos medianos, c) gránulos claros

4.2.b Segmentación de regiones en maíz

Otro experimento realizado con semillas de maíz, tuvo como propósito identificar la proporción de endospermo harinoso y endospermo vítreo (ver fig 4.10 a)).

Los granos de maíz son utilizados en muchas aplicaciones industriales para la elaboración de almidón, harina, comida, gluten, aceite, papel, pegamentos, bebidas alcohólicas, cosméticos, etc. Para cada empleo, la calidad del maíz está asociada con su constituyente físico que determina textura y dureza, y con sus componentes químicos que definen el valor alimenticio y propiedades tecnológicas. La composición química del endospermo determina diferentes formas y características físicas del grano, lo cual, a los fines comerciales, define los distintos tipos de granos.

Los tipos comerciales de maíz más típicos son el Hard or Flint y el Dent. No obstante, algunas industrias tipifican una tercera categoría como Half-Dent. El tipo Flint presenta granos de naturaleza predominantemente vítrea con un bajo componente de almidón y alto contenido proteico que da una apariencia corneal al endospermo; presentan buen comportamiento para la cosecha, transferencia y almacenamiento. El maíz tipo Dent, por tener apariencia de diente, se caracteriza por un endospermo con alta proporción de almidón y bajo contenido de proteínas (Secretaría de Agricultura, Ganadería, Pesca y Alimentos del Ministerio de Economía y Producción – SAGPyA).

La dureza del grano es una propiedad intrínseca del maíz, con un valor comercial que se expresa en su resistencia a la acción mecánica. Esta característica es muy importante en el procesamiento de molienda en seco, donde se produce una gama de harinas y sémola. Una variedad de mediciones indirectas se han encontrado para establecer dureza, pero en la actualidad no existe un procedimiento estándar para determinar el tipo de grano y cuantificar sus partes, permitiendo una

clasificación eficiente del material industrial [17]. Esto implica posibles pérdidas en la industria debido al bajo rendimiento de la materia prima.

El empleo mundial del maíz bajo una variedad de climas y suelos permite una variedad extraordinaria de aplicaciones del producto cosechado. Es uno de los cereales más cultivados a escala global. Los productores principales son Estados Unidos, China, Brasil, México, India, y Argentina. De la producción total, aproximadamente el 63 % es destinado como ingrediente de raciones de comida en alimentación de animales, mientras el 26 % es usado para el consumo humano y el 11 % restante para la industria [18].

Una semilla de maíz está compuesta por cuatro partes principales (Fig. 4.10 a)), el endospermo, que representa el 80–85%, el embrión el 10–12%, el pericarpio el 5–6% y la aleurona el 2–3%. Los carbohidratos son los principales componentes del grano de maíz, principalmente almidón (75%), proteínas (9%) y lípidos (3.5%). También están presentes algunas pequeñas cantidades de fibras, azúcares, minerales y vitaminas [19]. La composición química del endospermo determina las diferentes formas del grano y sus características físicas definen los tipos comerciales.

La prueba de flotación en una solución de nitrato de sodio (NaNO_3) es actualmente un procedimiento analítico utilizado para determinar el tipo de grano de maíz en Argentina. Esta prueba está basada en el principio de que los granos duros son más densos y flotan en menor grado que aquéllos con menor densidad. Este método se usa para comparar densidades en diferentes lotes de maíz. Esta metodología está relacionada con otras, como el peso del grano, que es utilizado en los Estados Unidos

La cuantificación de granos flotantes no permite una determinación de las proporciones de endospermo harinoso y endospermo vítreo. Se estudia entonces la posibilidad de establecer las proporciones utilizando un método óptico basado en *speckle* láser

Para el experimento se emplean tres muestras de granos de maíz provistas por la Asociación de Cooperativas Argentinas, identificadas por su origen genético como: Flint (ACA 929), Dent (ACA 467) y Half-dent (ACA 926). A los granos de cada muestra se les realizaron los test de flotación en el Laboratorio de Cerealicultura de la Facultad de Ciencias agrarias y Forestales de la Universidad Nacional de La Plata (UNLP), de acuerdo a los Protocolos en la Norma 29 del SAGPyA. Los granos flotantes fueron separados y contados. Luego se calculó el índice de flotación por muestra, es decir el porcentaje de granos flotantes con respecto al número total de granos en la muestra.

Para realizar el experimento, se tomaron 9 semillas de cada muestra, se humedecieron durante 12 hs, luego se cortaron longitudinalmente y se iluminaron con un rayo láser atenuado expandido Ne (10 mW y 632 nm de longitud de onda). Con una cámara CCD se registraron 400 PS de 512x512 píxeles para cada una.

Los registros se procesaron con TRFG, distinguiéndose en las imágenes resultantes zonas con diferentes colores asociados a los niveles de actividad. En la Fig 4.14 se muestra el resultado del procesamiento de las semillas tipo Flint, donde los colores corresponden a las partes de la misma: el naranja corresponde al embrión, el amarillo al endospermo vítreo, el celeste al endospermo harinoso y el azul a la región inerte ajena a la semilla.

Con la finalidad de determinar automáticamente las proporciones de cada parte de la semilla, se procesan las imágenes resultantes. Se reduce la zona inerte (Fig. 4.15 a)), y con el objetivo de unificar a cuatro tonos (naranja, amarillo, celeste y azul) se aplica un filtro promedio en ventanas cuadradas deslizantes de 9 píxeles y se colorea cada ventana en función a la aproximación al color predominante (Fig. 4.15 b)). Finalmente valores intermedios (celestes) alrededor de las zonas activas son convertidos en inertes (azul) (Fig. 4.15 c)). En esta última imagen la proporción de cada área es evaluada mediante el conteo de píxeles de un mismo color. Los resultados obtenidos

son mostrados en la Tabla 4.2 .Los resultados del procesamiento fueron publicados en [20], [21], [22] y [23].

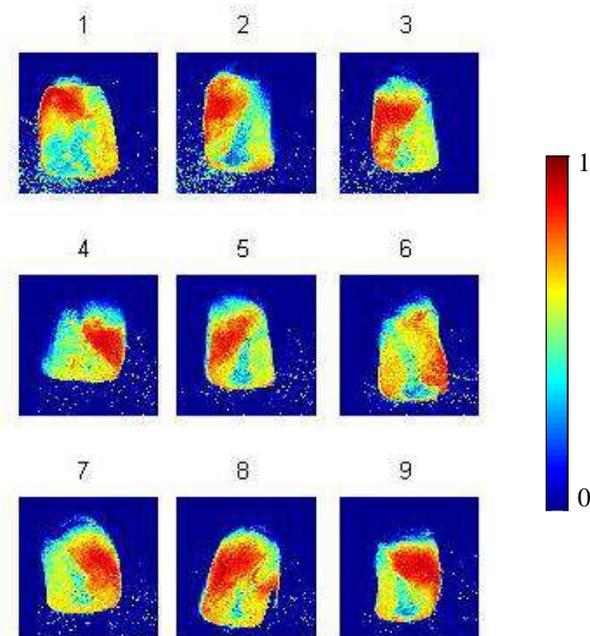


Fig. 4.14. Imágenes de actividad para 9 semillas tipo Flint

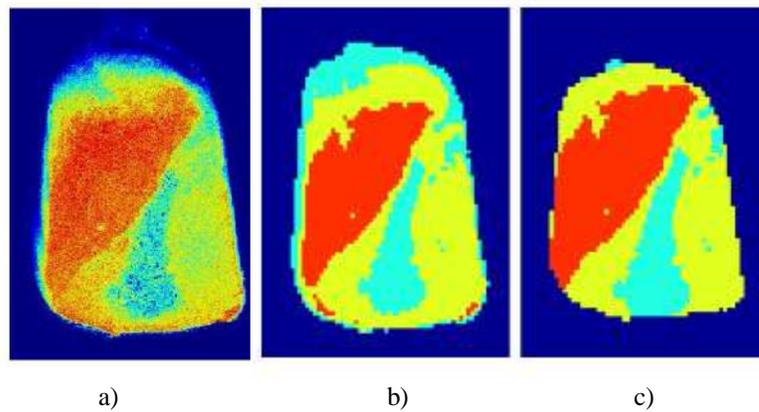


Fig. 4.15 Proceso de segmentación de la semilla 5

Con las mismas muestras fue probado el método espacial (SRFG), obteniéndose resultados satisfactorios. La ventaja de este método es la posibilidad de realizar la segmentación con un único patrón de *speckle*, de todos modos el proceso es computacionalmente más costoso y en tiempo de procesamiento no difiere del temporal. Los resultados pueden verse en la Fig. 4.16, donde se muestra a) un patrón de *speckle*, b) una imagen de actividad obtenida con TRFG y c) la imagen obtenida con SRFG [21].

Tabla 4.2. Segmentación y cálculo de porcentajes

Muestra	Cantidad de píxeles				Porcentaje		
	fondo	Endospermo harinoso	Endospermo vítreo	Embrión	Endospermo harinoso	Endospermo vítreo	Embrión
1	164140	21250	39350	31300	23.123	42.818	34.059
2	170323	28615	23575	33525	33.384	27.504	39.112
3	183235	12580	30075	30150	17.279	41.309	41.412
4	186361	16100	25625	27950	23.107	36.778	40.115
5	182647	14225	27125	32050	19.380	36.955	43.665
6	178692	23275	39550	14525	30.090	51.131	18.778
7	176563	13100	32825	33550	16.483	41.302	42.215
8	174540	10575	26175	44750	12.975	32.117	54.908
9	190291	13150	20825	31775	20.000	31.673	48.327
Promedio	178535	16986	29458	31064	21.758	37.954	40.288

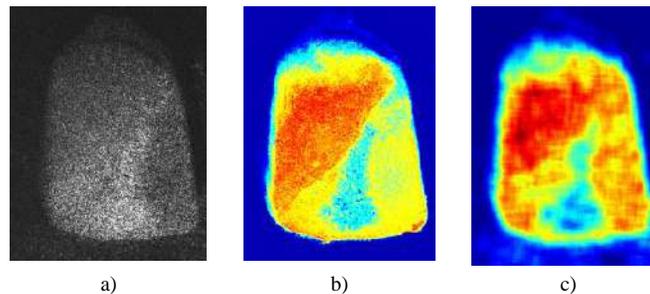


Fig.4.16 a) Patrón de *speckle* b)Imagen de actividad con TRFG c) imagen de actividad con SRFG

4.2.c Detección de golpes en manzanas

Con el objetivo de reconocer una región magullada de una manzana en medio de una región sana se evalúa el comportamiento de TRFG.

Las manzanas se pueden golpear en la cosecha y en el proceso de carga y descarga produciendo magulladuras y deterioro en la calidad de las mismas. El golpe no siempre es visible inmediatamente, lo cual complica la selección de las frutas sanas. El golpe produce una degradación local del tejido combinada con la salida de agua intracelular (agua libre) y el ennegrecimiento (oxidación) de compuestos fenólicos. La rotura o falla del tejido ocurre a nivel microscópico y causa defectos de las células debajo de la piel sin dañar la piel. La rotura de la piel o las magulladuras en la carne liberan enzimas que a su vez provocan el ennegrecimiento de la fruta. La magulladura se vuelve perceptible unos días después. La detección temprana de manzanas golpeadas es un aspecto importante en la comercialización de las mismas [24], [25].

Para el experimento se obtienen muestras de una manzana red deliciosa, a la que se daña mediante un impacto controlado, dejando caer una bola de acero sobre la manzana, como sugieren en [26][27], de manera que el impacto no pueda ser apreciado visualmente. Para poder detectar la evolución del fenómeno, se obtienen secuencias de 500 PS de 300x300 píxeles en distintas etapas: antes del daño, inmediatamente después, 1 hora más tarde y un día más tarde. En este caso se utilizó un haz de láser de baja potencia expandido del tipo He-Ne (5mW a 10 mW, $\lambda \sim 633$ nm) para iluminar una región amplia de la muestra. Las imágenes no fueron obtenidas por propagación libre sino que son imágenes de campo lejano formadas en un objetivo, con valores altos de apertura de diafragma (usualmente $f=50$ mm, $f/\#=16$).

Mediante el proceso TRFG se analizaron las distintas series, siendo detectado el golpe únicamente en la obtenida inmediatamente después. En la Fig. 4.17 pueden observarse los resultados; la Fig 4.17 a) corresponde a un PS, la Fig 4.17, b) al resultado obtenido con TRFG y la Fig 4.17 c) al proceso de filtrado y definición de rangos para detectar 3 regiones: zonas inactivas (en negro), zona de manzana sana (en gris) y zona de manzana golpeada (en blanco). Resultados presentados en [28].

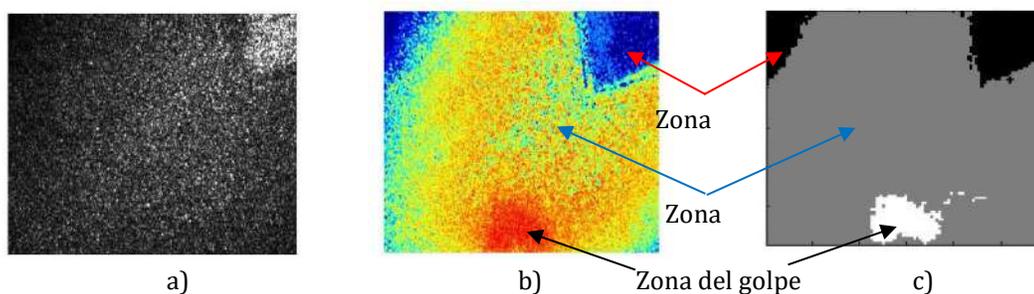


Fig. 4.17. Resultados para la muestra de manzana obtenida inmediatamente después del golpe, a) PS b) Imagen de actividad, c) Filtrado y segmentación de la imagen de actividad

El resultado de emplear TRFG es comparado con otros métodos empleando el conjunto completo de PS y los primeros 50 PS (Fig 4.18). Además, se utilizó una curva ROC (Característica Operativa del Receptor) como una representación gráfica de la sensibilidad frente a la especificidad para un sistema clasificador binario, calculándose el área bajo la curva (AUC) como un índice de calidad. [29], [30].

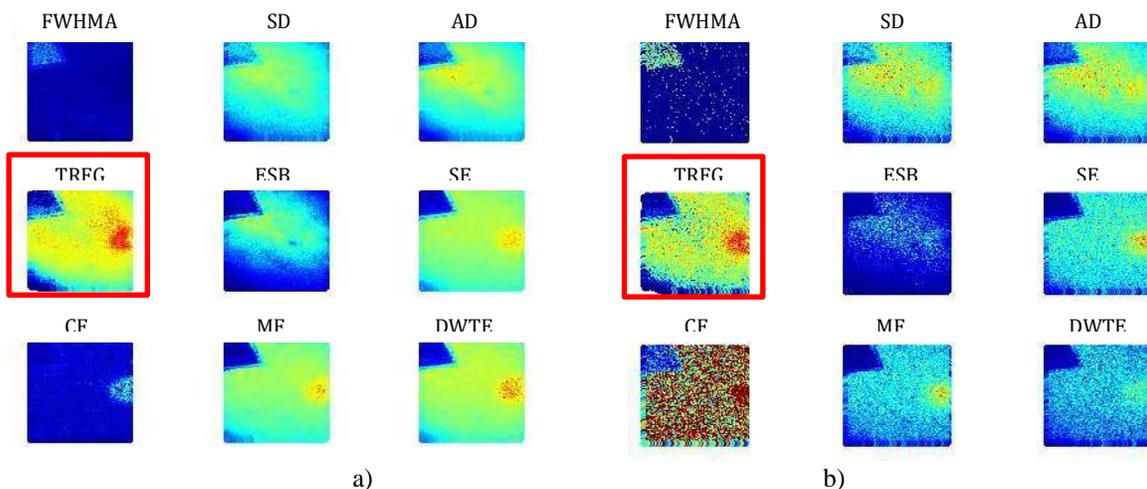


Fig. 4.18. Imágenes comparativas de actividad mediante distintos métodos a) para los 500 PS, b) para los primeros 50 PS

Tabla 4.3. Tabla comparativa de los valores de AUC para distintos descriptores

Descriptor	500 muestras	50 muestras
TRFG	0.954	0.940
MF	0.936	0.902
SE	0,896	0,895
DWTE	0.887	0.692
CF	0,862	0,830
ESB	0.754	0.651
FWHMA	0.276	0.267
AD	0.276	0.276
SD	0.026	0.260

En la Tabla 4.3, se muestran los valores de AUC para cada descriptor en orden descendente. Utilizando 500 PS el descriptor con el AUC más alto es el obtenido con TRFG, que casi no se modifica en relación a la cantidad de muestras, seguido por los basados en frecuencia (generalmente de alto costo computacional) MF, SE, DWTE, CF y ESB con valores > 0.75. Otros descriptores muestran valores inferiores a 0.5, no resultando aconsejables para aplicarlos en muestras con intensidad espacial no homogénea. Cuando se utilizó el conjunto de 50 primeros PS para calcular los descriptores, no se reflejaron diferencias importantes en el rendimiento de TRFG y los basados en frecuencia [29].

A través de TRFG se detecta una actividad inmediatamente después del impacto, pero durante muy poco tiempo, y en la secuencia obtenida después de una hora solo se detecta el estancamiento de la actividad en un punto, lo cual no había sido detectado por otros métodos. Al analizar el ensayo, se observa que este punto coincidiría con el punto donde se ejerce el golpe.

En la Fig. 4.19 las imágenes de actividad para las muestras obtenidas inmediatamente después del golpe se calculan cada 20 PS, la actividad máxima se produce durante los 100 primeros PS y luego el golpe comienza a atenuarse. En los estudios mediante otros descriptores se han realizado sobre 500 PS, lo cual tiende a nivelar los resultados de actividad.

Como en el caso de la detección de grosor en capa de pinturas, se pudo comprobar mediante TRFG cómo la actividad disminuye en el tiempo, dado que TRFG permite analizar actividad en cada instante o con pocas imágenes; se realizó el mismo proceso con los PS de manzanas, ya que se desconoce el tiempo en que el golpe produce alguna actividad y en cuanto tiempo la actividad/inactividad pasa a la parte interna de la manzana [15].

La Fig. 4.20 muestra el proceso en un gráfico de dispersión 3D, la Fig. 4.20 a) calculada con PS tomados inmediatamente después del golpe y la Fig. 4.20 b) PS tomados una hora después del golpe. Los puntos se reducen en el tiempo, calculando TRFG cada 10 imágenes, y en el espacio, aplicando filtro medio en ventanas cuadradas (10x10 píxeles).

TRFG permitió ver que la actividad puede evaluarse en tiempos reducidos, con lo que sería posible analizar los procesos en tiempo cuasi real para ir observando la modificación de la actividad durante el registro de las imágenes. Al no requerir un número grande de imágenes no se pierden los lapsos más evidentes de actividad, evitando una nivelación del resultado entre la actividad máxima y mínima. Mediante gráficos como los diagramas de dispersión es posible visualizar la evolución del grado de actividad y distinguir el punto del golpe que en una imagen 2D es imperceptible [15].

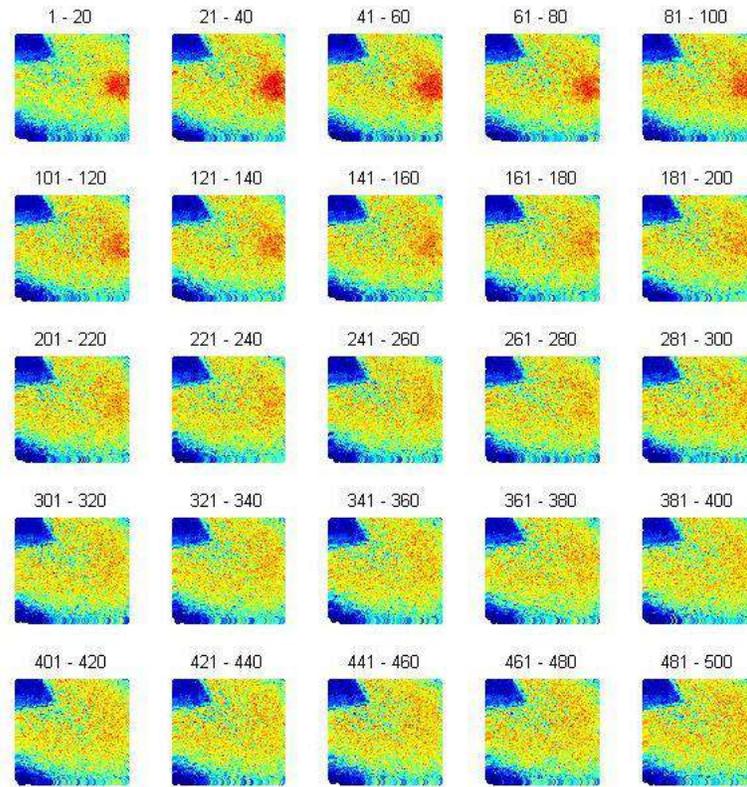


Fig. 4.19. Imágenes de actividad inmediatamente después del golpe en intervalos de 20 PS

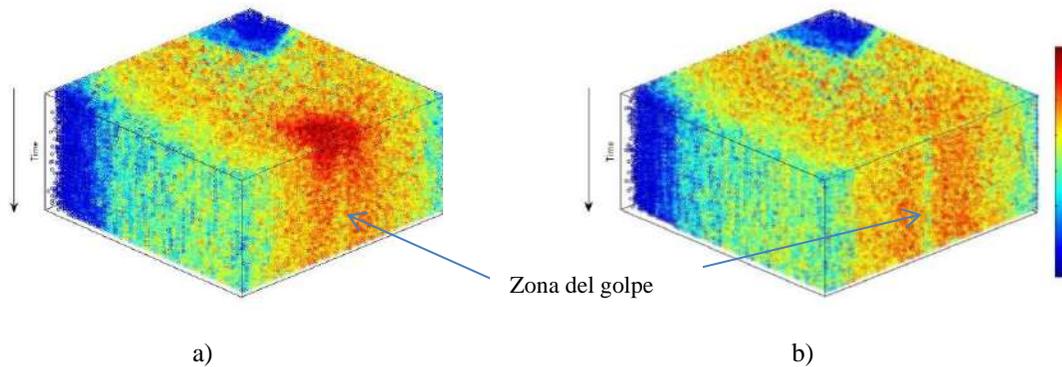


Fig. 4.20 Evolución de la zona del golpe : a) inmediatamente después del golpe, b) a partir de una hora después del golpe

4.2.d TRFG utilizado para entrenar redes SOM

En el capítulo 3 TRFG fue comparado con algunos descriptores que permiten caracterizar un THSP, cada uno de ellos tiene sus ventajas y limitaciones, como poder identificar determinadas áreas de interés pero no poder discernir entre otras o identificarlas erróneamente. Es deseable encontrar una metodología para detectar dinámica en biospeckle y distinguir entre los componentes de la muestra que estarían dictados por el propio fenómeno y las diversas regiones, que no se sabe que están presentes a priori.

Para potenciar la eficacia de esos descriptores individuales, se propuso un método para utilizar los distintos resultados de un conjunto de descriptores, entre ellos TRFG, como entrada a una red neuronal de aprendizaje no supervisado, tal como un mapa auto-organizado o SOM (*Self-Organizing Map*). El objetivo de aplicar SOM es construir modelos capaces de caracterizar patrones dinámicos de *speckle* para identificar regiones con propiedades similares en distintas muestras.

El mapa auto organizado (SOM) propuesto por Kohonen [31] es uno de los modelos más populares de redes neuronales no supervisadas. El SOM cuantifica un espacio de datos formado por datos de entrenamiento y realiza una proyección que preserva la topología de los datos en una grilla bidimensional. Este tipo de red posee un aprendizaje no supervisado competitivo, o sea que no se dispone de ninguna salida objetivo hacia la cual la red neuronal deba tender. El objetivo de este aprendizaje es lograr una proyección bidimensional que permita visualizar agrupamientos de datos en función de su similitud.

Al considerar varios descriptores simultáneos con diferentes significados, el término habitual "nivel de actividad" no parece apropiado, tal vez, el término "actividad equivalente" sería más adecuado, reflejando que la salida de la clasificación se refiere a dinámicas similares vistas desde las distintas técnicas o conceptos de los descriptores.

En este caso, los datos de entrenamiento estarían dados por tantos vectores como píxeles contiene el PS, teniendo como componentes los valores resultantes de los distintos descriptores considerados.

La red está formada por dos capas, una de entrada y otra de salida. Las conexiones entre las dos capas son siempre hacia delante, es decir, la información se propaga desde la capa de entrada hacia la capa de salida. Cada neurona de entrada i está conectada con cada una de las neuronas de salida j mediante un peso W_{ji} . De esta forma, las neuronas de salida tienen asociado un vector de pesos W_j llamado libro de códigos (codebook), debido a que constituye el vector prototipo de la categoría representada por la neurona de salida j . Así, el SOM define una proyección desde un espacio de datos en alta dimensión a un mapa bidimensional de neuronas.

Para entrenar la red, en cada paso se toma un vector de muestra del conjunto de datos de entrada y se calcula una medida de similitud entre el vector de entrada y todos los vectores del libro de códigos. La similitud se define por medio de una medida de distancia, típicamente distancia euclidiana. La celda cuyo vector de peso tiene la mayor similitud con la muestra de entrada se selecciona como la unidad de mejor coincidencia (BMU Best Match Unit).

La adaptación es dada por:

$$W_j(n+1) \leftarrow W_j(n) + \eta(n) h_{ji}(n) [X(n) - W_j(n)],$$

donde n es el número de iteración, j es el índice de neurona considerada en la iteración actual, W_j es el vector prototipo de la celda j , $\eta(n)$ es la tasa de aprendizaje, $h_{ji}(n)$ es la función vecindario centrada en la BMU y $X(n)$ es el vector de datos entrada presentado.

Después del procedimiento de aprendizaje, la red neuronal pudo reconocer diferentes regiones en muestras similares, constituyendo una mejora sustancial con respecto a los procedimientos habituales, ya que se detectaron regiones pasadas por alto por el supervisor humano, evaluadas sobre una base objetiva conocida. Resultados con muestras biológicas y en secado de pinturas fueron publicados en [32] y [33].

4.3 Ultrasonido

Las imágenes de ultrasonido, al igual que las imágenes obtenidas en muestras iluminadas con láser, presentan el fenómeno de *speckle*. Esta particularidad permite analizar dinámicas en videos de ultrasonido cuando uno o varios mecanismos actúan sobre la muestra observada. La investigación de la actividad de los *speckles* en US ha mostrado interés en los últimos años.

La ecografía, también llamada ultrasonografía o ecosonografía, es un procedimiento de diagnóstico usado en los hospitales que emplea el ultrasonido para crear imágenes bidimensionales o tridimensionales. Un instrumento llamado transductor emite ondas de ultrasonidos. Estas ondas sonoras de alta frecuencia se transmiten hacia el área del cuerpo bajo estudio y se recibe su eco. El transductor recoge el eco de las ondas sonoras y mediante un proceso se obtiene el eco en una imagen.

La ecografía es un procedimiento sencillo, a pesar de que se suele realizar en el servicio de radiodiagnóstico. Es un estudio minimamente invasivo a diferencia de los procedimientos de radiografía, en los que se emplea radiación.

La posibilidad de usar técnicas de *speckle* dinámico en imágenes de ultrasonido muestra interesantes posibilidades [34][35]. El *speckle* observado en imágenes de ultrasonido es considerado sólo un artefacto que se desea disminuir para mejorar el reconocimiento y la resolución de las imágenes. Los instrumentos para obtener las ecografías por lo general son provistos de filtros para evitar la interferencia del *speckle*. Para el caso de muestras relativamente rápidas, como la sangre dentro de las venas, la llamada ecografía Doppler o Eco Doppler ha brindado resultados excelentes.

4.3.1. Ultrasonido en tumores oculares

La ecografía ocular o ecografía oftalmológica es un método diagnóstico que utiliza ultrasonido para producir imágenes de las estructuras internas del ojo; es una exploración inocua, rápida, indolora y segura que permite obtener datos y mediciones de la estructura del globo ocular y es de gran utilidad para el seguimiento y diagnóstico de patologías oculares.

Un primer estudio realizado sobre imágenes de ultrasonido fue aplicado a un video de ojo con un diagnóstico de tumor. En este caso, existía una región de circulación activa correspondiente a un tumor maligno como el melanoma.

El melanoma ocular tiene una incidencia global anual de 6 casos por millón de habitantes, siendo un poco más frecuente en los varones que en las mujeres. Es la neoplasia maligna intraocular primaria más frecuente en adultos. El melanoma coroideo es el tumor primario intraocular más frecuente en adultos, representando el 70% de los tumores oculares. La edad media de presentación en el momento del diagnóstico es alrededor de los 60 años. La coroides es parte del tracto uveal, capa pigmentada del globo ocular que abarca el iris, el cuerpo ciliar y la coroides. Estos melanomas por lo general son de difícil detección mediante los estudios convencionales de rutina y además, suelen ser asintomáticos y no son observables a simple vista. El Ultrasonido posee un rol muy importante en el diagnóstico de patologías oculares dada su cualidad de rápido, dinámico, no invasivo y eficaz, pudiendo diagnosticar más de un 97% de los casos de melanoma de coroides [36][37].

El primer video de ultrasonido analizado fue obtenido del *New York Eye Cancer Center* y corresponde a un hombre de 67 años con un tumor en su ojo [38]. En el video, las imágenes dinámicas de ultrasonido (10 MHz) revelan un brillo titilante correspondiente al flujo de sangre dentro de un melanoma coroideo [36].

La Fig. 4.21 a) muestra un esquema de un ojo, para reconocer las distintas partes y zona iluminada. La Fig. 4.21 b) muestra una imagen de ecografía *Brightness scan* (escaneo de brillo), a menudo llamada solo B-scan o modo B, que ofrece una vista transversal bidimensional del ojo y de

la órbita. La exploración B-scan se utiliza en el exterior del párpado cerrado para ver el ojo. En ella se puede diferenciar de izquierda a derecha, la córnea y la cámara anterior. La cámara anterior por lo general es observada como vacío en las imágenes de US, pero aquí se ve un área brillante, como si fuese ocupado por un material fibroso. Luego sigue el cristalino y después el humor vítreo que es transparente (zona ecogénica que no refleja las ondas de sonido). Le sigue una región con la alta reflectividad que sobresale dentro de la cámara vítrea que puede ser reconocida como un retinoblastoma o una metástasis de otro cáncer en el ojo. Detrás de ello la región es ecogénicamente densa como si fuera sólida, la región posterior del ojo y la grasa retro-orbital.

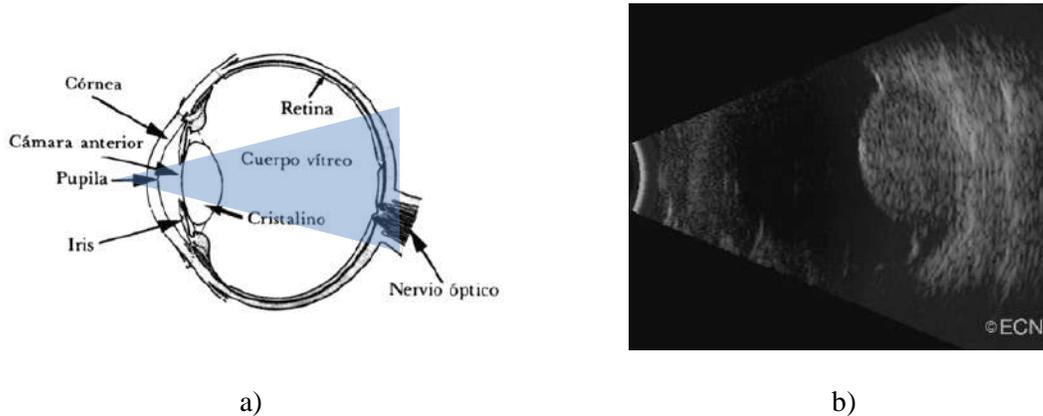


Fig 4.21 a) Esquema del ojo y región del B-scan, b) imagen B-scan

La imagen B-scan muestra un tumor que sobresale en el cuerpo vítreo del ojo. Con sólo esta observación el oftalmólogo debería poder distinguir entre tumores benignos y malignos. En general, los tumores malignos tienen una circulación activa comparando con los benignos. En los casos de tumores grandes es posible para especialistas muy habituados a este tipo de estudio observar en el B-scan "un centelleo" del tumor como "un pulso". Esto es causado por la sangre que circula dentro del melanoma, "el centelleo" representa vascularización intrínseca o flujo de sangre. Este ejemplo, ya diagnosticado como maligno, fue utilizado para probar la utilidad del descriptor y así poder utilizarlo en casos menos evidentes.

La Fig. 4.22 a) se muestra el resultado de aplicar TRFG a una serie de imágenes de B-scan. De izquierda a derecha, se observa que no aparece la córnea (región sin actividad), luego la región no-ecogénica, el humor vítreo y a continuación una región posterior semi oval con puntos rojos en el medio: estos puntos podrían ser los vasos sanguíneos de neo-vascularización correspondientes a un melanoma.

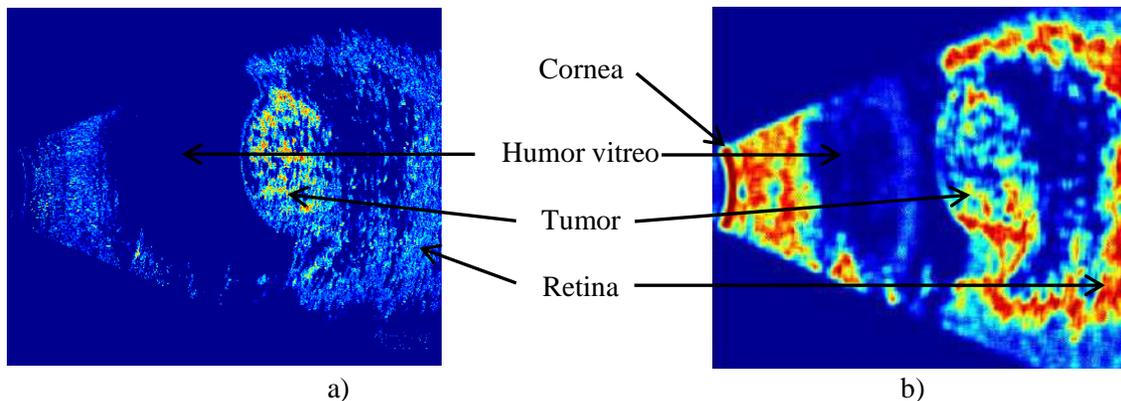


Fig.4.22. a) Imagen de actividad para B-scan b) Resultado de aplicar SRFG a una imagen de B-scan

Para esta muestra también fue utilizado el descriptor espacial (SRFG) explicado en el Capítulo 2. En la Fig. 4.22 b) SFRG es aplicado a una sola imagen, en este caso aparece en el medio de la región vítrea no ecogénica, una región ecogénica delante del tumor, que no se puede ver en las Fig.s 4.21 b) y 4.22 a). Esta región tiene, según el especialista, correlación con una neomembrana fibrosa del humor vítreo. Por último, puede ser vista una zona de elevada actividad (en rojo) correspondiente a la retina, que generalmente no puede ser percibida en otras imágenes. Basado en la opinión de un oftalmólogo, TRFG y SRFG podrían proveer información complementaria. Estos resultados fueron presentados en [39] y [40].

Con el objetivo de identificar regiones oftálmicas vascularizadas utilizando solo videos ecográficos en modo B, los ensayos se aplicaron luego a imágenes de melanoma uveal provistas por un experto especialista en cirugía de retina y oncología ocular. La adquisición de videos fue realizada con un ecógrafo marca Quantel, modelo Aviso, con punta de prueba de 20 MHz, utilizado en modo B, los videos comprenden entre 70 y 100 imágenes. En este caso han sido pacientes diagnosticados, los cuales se analizan en dos etapas, antes y después de una cirugía y/o tratamiento, con el objetivo de caracterizar la actividad temporal en la región interior del melanoma coroideo. [41].

El modo B permite una adecuada valoración de la localización, la morfología, la biometría y la ecogenicidad del tumor tanto en el momento del diagnóstico como durante el seguimiento. Constituye una herramienta precisa para asegurar el diagnóstico de melanoma coroideo y para valorar las dimensiones del tumor como ya han demostrado una gran cantidad de estudios. Aunque la biopsia con aguja fina es una técnica que permite la confirmación histopatológica, presenta gran variedad de limitaciones y complicaciones, sobre todo en los tumores de pequeño tamaño, que han ocasionado que no sea una herramienta utilizada de manera rutinaria para su confirmación, quedando reservada únicamente para los casos más dudosos.

Es de importancia encontrar una metodología con el propósito minimizar los tiempos y costos en la detección y evaluación clínica de la patología del paciente. Considerando que son escasos los profesionales que realizan mencionado diagnóstico, podría ser además utilizado como herramienta de capacitación, entrenamiento o perfeccionamiento a profesionales médicos oftalmólogos generalistas o con poca experiencia en el diagnóstico de mencionada patología, facilitando la detección de mencionadas vascularizaciones.

4.2.2 Ecografías de pulmón

El ultrasonido pulmonar (UP) constituye una herramienta diagnóstica dinámica, no invasiva, que puede ser realizada a la cabecera del paciente que se encuentra en ventilación mecánica, por lo cual ha ganado un terreno muy importante en el campo de la anestesia y los cuidados críticos [42][43][44]. Es altamente sensible a las variaciones del contenido de aire y fluidos pulmonares, constituyendo un verdadero densitómetro del parénquima pulmonar [45]. A través de un análisis dinámico y estático de una combinación de artefactos sonográficos permite la obtención de una imagen en tiempo real. Dicha imagen no es una imagen anatómica sino que es debida a la interacción del haz de ultrasonido con las estructuras torácicas y el parénquima pulmonar, lo cual genera artefactos que se producen debido a la reflexión y reverberación de los ecos sobre las interfaces de los tejidos con distinta impedancia acústica. Los diferentes signos ecográficos que permiten el diagnóstico de las distintas patologías pleuro-pulmonares en pacientes adultos se encuentran también en neonatos y niños críticamente enfermos [45].

Para el diagnóstico y seguimiento de pacientes con sospecha de neumonía, el *gold standard* es la tomografía axial computada (TAC). Este método diagnóstico a veces no está disponible, es de elevado costo y no es posible de realizar en neonatos debido a la elevada dosis de radiación [46]. La

radiografía posee una especificidad del 95% pero una sensibilidad del 68% para el diagnóstico, por ejemplo, de consolidación alveolar, mientras que el UP posee una sensibilidad del 90% y una especificidad del 98%, lo que lo posiciona como una excelente herramienta para el diagnóstico y seguimiento de esta patología pulmonar [47].

El UP posee un rol muy importante en el diagnóstico de enfermedades pulmonares en pacientes pediátricos, incluidas las atelectasias obstructivas o compresivas de diferentes etiologías [43]. En un estudio realizado recientemente el UP demostró tener una sensibilidad del 88% y una especificidad del 89% para el diagnóstico de atelectasias inducidas por anestesia general en pacientes pediátricos, así como también una elevada concordancia inter-observador [48].

La anestesia general se asocia a la aparición de áreas de atelectasias en un alto porcentaje de pacientes. La incidencia reportada de atelectasias inducidas por anestesia general en pacientes pediátricos es de 68-100% [49]. El tejido pulmonar colapsado no solo reduce la distensibilidad (*compliance*) pulmonar sino que también causa deterioro en la oxigenación venosa mixta y arterial. A pesar de que las atelectasias inducidas por la anestesia general suelen resolverse espontáneamente en la gran mayoría de los pacientes pediátricos [ASA (*American Society of Anesthesiologist physical status classification system*) I-II], esta entidad puede persistir en pacientes de alto riesgo y producir complicaciones asociadas a la ventilación mecánica en el periodo post-operatorio.

El UP permite valorar la efectividad de la maniobra de reclutamiento alveolar a través de una monitorización dinámica, optimizando la estrategia ventilatoria durante la anestesia general. Sin embargo, la UP (ecografía) no permite un control preciso de la hiperinsuflación inducida por la Presión Positiva al Final de la Espiración (PEEP), por lo que no debe ser utilizada como un método para detectar la sobredistensión.

El beneficio de la utilización del UP como guía para realizar la maniobra de reclutamiento alveolar (reexpansión de áreas pulmonares previamente colapsadas mediante un incremento breve y controlado de la presión transpulmonar) ha sido estudiada por Gardelli y Bouhemad [50] Estos grupos han publicado la relación entre los diferentes patrones ecográficos de apertura pulmonar y el resultado de las maniobras de reclutamiento en pacientes adultos que se encuentran en unidad de cuidados intensivos (UCI) con síndrome respiratorio agudo (SDRA) y con Injuria pulmonar aguda (ALI).

La Fig. 4.23 muestra un patrón ecográfico de pulmón donde se pueden observar distintas líneas que determinan el estado del pulmón. En un pulmón normalmente aireado, la única estructura perceptible es la pleura, visualizada como una línea horizontal hiperecoica (estructura muy reflexiva que resulta más brillante en comparación con otras estructuras del entorno). La línea pleural se mueve sincrónicamente con la respiración, este movimiento dinámico horizontal se llama "desliz de pulmón". Hay otras líneas horizontales que surgen a intervalos regulares de la línea pleural, las líneas A. Cuando las líneas A se combinan con el desliz de pulmón, estos artefactos de reverberación representan un signo de contenido normal de aire en los espacios alveolares. Cuando disminuye el contenido de aire y la densidad pulmonar aumenta, el desajuste acústico entre el pulmón y los tejidos circundantes permite que el rayo de ultrasonido en parte pueda ser reflejado en zonas más profundas y repetidamente se generan algunos artefactos de reverberación verticales conocidos como líneas B. La presencia de líneas B coalescentes con una separación menor de 3 mm entre sí se corresponde con una disminución más grave de la aireación pulmonar resultante del llenado parcial de los espacios alveolares por edema pulmonar, bronconeumonía confluyente o atelectasias.

Por último, la presencia de consolidación pulmonar con broncogramas aéreos se corresponde con la pérdida completa de aireación pulmonar persistente. Este grupo demostró una correlación estadísticamente significativa entre dicho índice de re-aireación obtenido con imágenes de ultrasonido pulmonar y el reclutamiento pulmonar inducido por Presión Positiva al Final de la

Espiración (PEEP) medido con las curvas presión/volumen. Este índice se basa en la evaluación por observación de las imágenes de ultrasonido pre y post aplicación de una PEEP de 15 cm H₂O.

Se plantea entonces el uso de TRFG para el procesamiento de videos de ultrasonido con el objetivo de cuantificar tanto de la re-aireación como de la pérdida de aireación pulmonar. Ello puede aportar elementos no subjetivos en la interpretación de resultados de la aplicación de una PEEP durante una maniobra de reclutamiento pulmonar.

En este caso, el desafío de la evaluación de los patrones ecográficos pulmonares es realmente alto, dado que para su interpretación no basta el conocimiento anatómico sino que es esencial la interpretación del fenómeno fisiológico en sus diversos estadios de normalidad y posibles patologías que genera, debiéndose descubrir diferentes artefactos en las imágenes ecográficas.

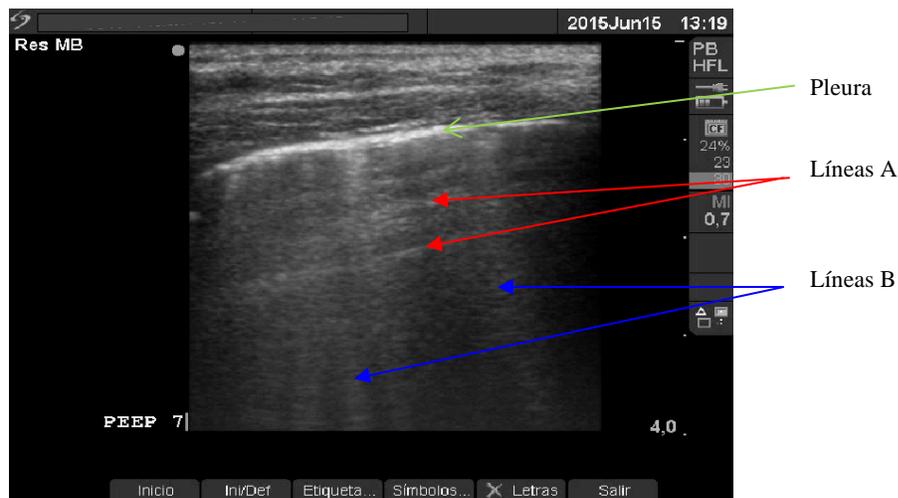


Fig. 4 .23. Imagen ecográfica donde se pueden distinguir líneas A y líneas B

La Fig. 4.24 muestra imágenes de UP. La Fig. 4.24 a) muestra un pulmón normalmente ventilado, es caracterizado por la presencia de líneas A horizontales y paralelas, la línea brillante horizontal bien definida corresponde a la pleura. La Fig. 4.24 b) muestra la presencia de Líneas B coalescentes correspondientes a la pérdida de aireación moderada-severa causada por aire y material surfactante atrapado dentro del tejido colapsado, las líneas B verticales que comienzan de posiciones no alineadas anulan las líneas A y la línea de la pleura. Estas imágenes muestran estados extremos, que pueden variar durante el monitoreo generando una variedad de estados intermedios difíciles de reconocer.

Una primera alternativa del uso de TRFG fue procesar los videos al igual que en otras experiencias, para obtener potenciales indicadores de aireación en maniobras de reclutamiento, con la aplicación de progresivos aumentos de PEEP, a fin de generar un sistema de soporte al análisis de UP para diversas situaciones y patologías, como se publicó en [51].

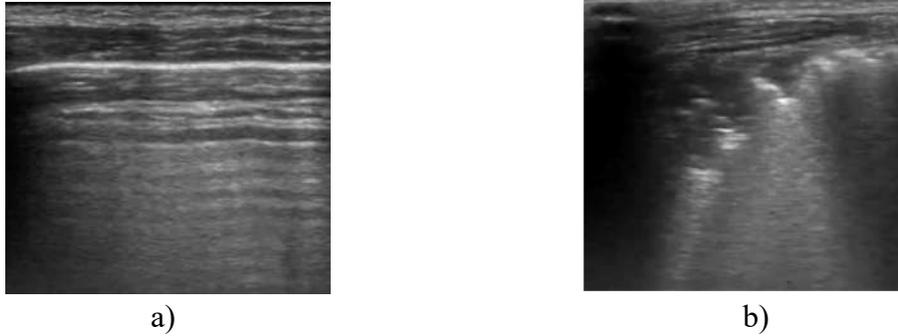


Fig.4.24 Imágenes de UP. a) paciente sano. b) pérdida de aireación severa

Otra alternativa consistió en evaluar los gránulos claros en cada imagen en dirección horizontal y vertical como si fueran THSPs para reconocer el predominio de Líneas A y/o B. Con $Q_T = \sum_T \mu_{claros}$ al aplicar TFG a cada señal de cada imagen, en sentido horizontal para detectar líneas A y vertical para detectar líneas B, se forma una matriz representada como una nueva imagen (Fig.4.25 y 4.26), donde cada fila corresponde a los resultados del proceso de una imagen de US. Con los valores promedio de cada columna, se obtienen los gráficos bajo las imágenes de las Fig 4.25 y 4.26.

La Fig. 4.25 corresponde a los cálculos realizados con la secuencia a la cual corresponde la Fig. 4.24 a), donde predominan las líneas A. La línea pleural está claramente definida en la Fig. 4.25 a) mostrando un pico marcado en el gráfico correspondiente, y una secuencia de picos que corresponden a las distintas líneas A. La Fig. 4.25 b) presenta un patrón bastante parejo, no denotando predominio de líneas B, ello está asociado a un pulmón bien ventilado.

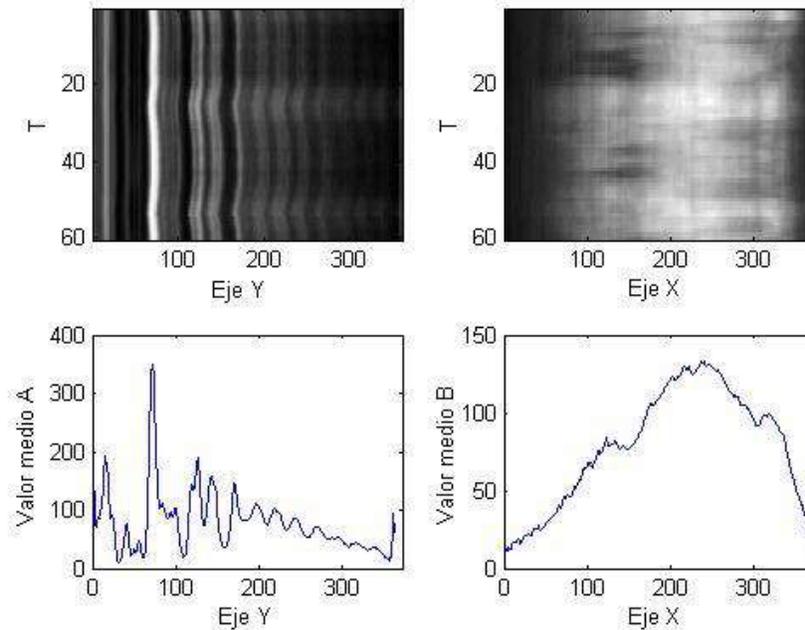


Fig 4.25. Resultado de procesar la Fig. 4.24 a)

La Fig. 4.26 corresponde a los cálculos realizados con la secuencia a la cual corresponde la Fig. 4.24 b), donde predominan las líneas B. El gráfico de la Fig. 4.26 a) casi no presenta oscilaciones, indicando la ausencia de líneas A y línea pleural. El gráfico correspondiente a líneas B tiene un pico pronunciado y centrado.

Los gráficos de los valores medios de las Fig.s 4.25 y 4.26 muestran comportamientos claramente diferentes, como lo son las imágenes a) y b) de la Fig. 4.24, los casos escogidos son bien diferenciados a los objetivos de mostrar la metodología. El objetivo es obtener un cuantificador para la observación rápida, considerando que estos son vídeos cortos y cambiantes, y no tan claramente diferenciables que son tomados como diagnóstico en situaciones de anestesia y cuidado crítico [40].

El paso siguiente es procesar datos correspondientes a los gráficos de líneas A y B para obtener un único valor representativo de la situación observada. En primer lugar, las líneas A son cuantificadas por la amplitud, la intensidad de línea pleural y cantidad de oscilaciones bien definidas; y las líneas B por la distribución de sus valores y la variación en el tiempo. A tal efecto se diseña un sistema basado en reglas que, a partir de distintos parámetros de los gráficos, genera una señal que indica el grado de gravedad en un score de 1 a 5.

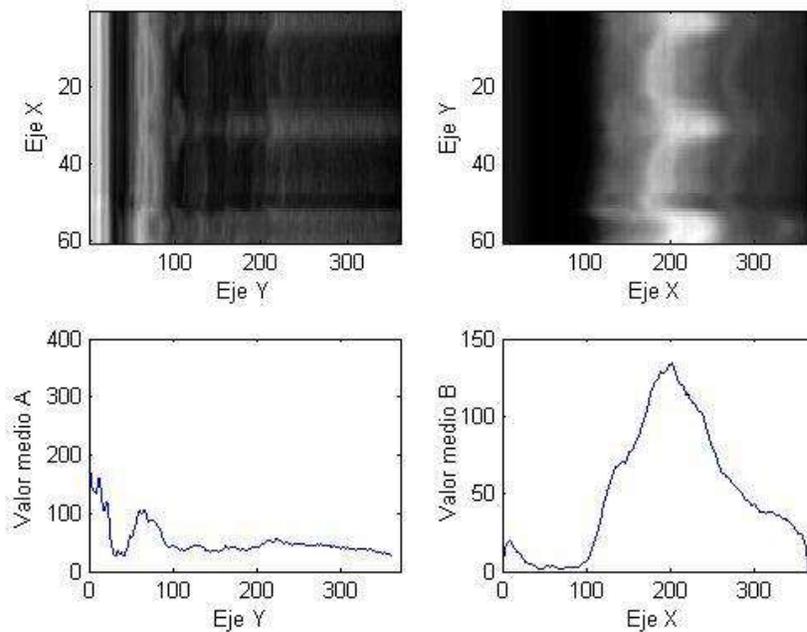


Fig 4.26. Resultado de procesar la Fig. 4.24 b)

La Fig. 4.27 muestra imágenes de un caso real sometido a distintos grados de PEEP. En la Fig. 4.27 a) cada imagen corresponde a la primera de una secuencia, luego se muestran en la Fig 4.27 b) los gráficos correspondientes a líneas B y por debajo, Fig. 4.27 c), los gráficos correspondientes a líneas A. En los gráficos se puede observar cómo se va aplanando la gráfica correspondiente a líneas B y como se acentúa la oscilación en la correspondiente a líneas A, mostrando una mejora en la aireación.

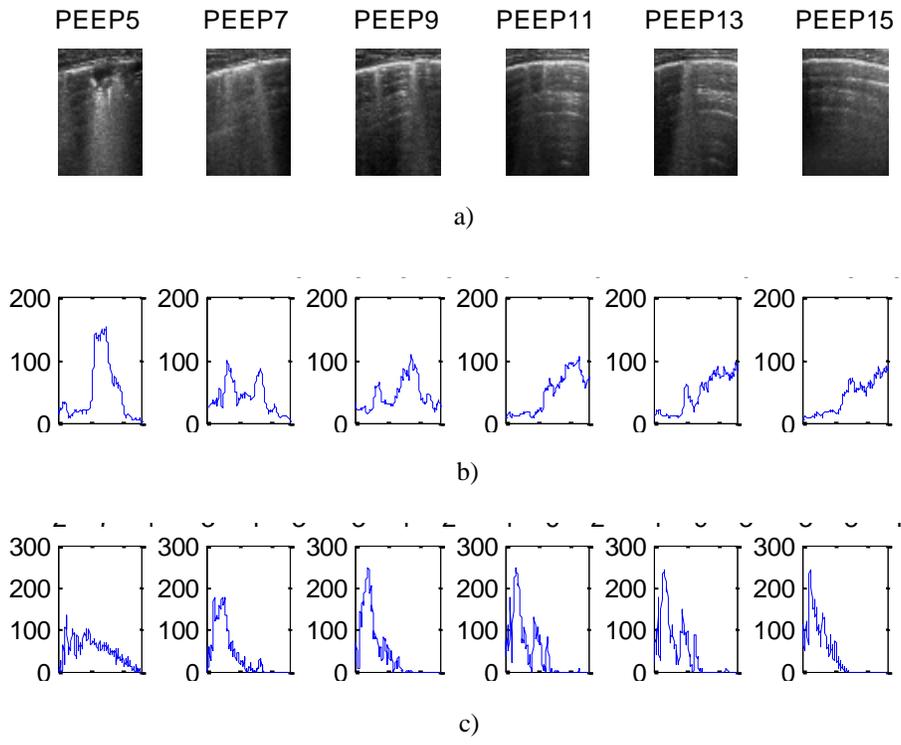


Fig. 4.27 Procesamiento de imágenes de UP de un caso real. a) imágenes para distintos valores de PEEP, b) valores obtenidos para líneas A c) valores obtenidos para líneas B

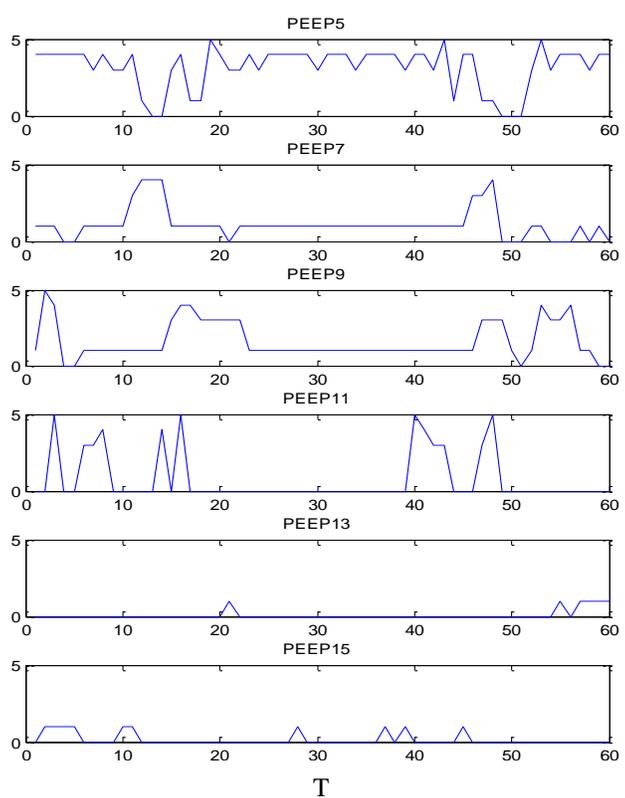


Fig.4.28 Score resultante para las imágenes de cada video

Las señales de la Fig. 4.28 están generadas procesando cada imagen de la secuencia, asignando un score a cada una. Se observa claramente cómo con el aumento del PEEP disminuyen los valores de score, lo cual indica la mejora en la aireación,

La aplicación del TFG sería una herramienta útil para evaluar la aireación lograda tras las maniobras de reclutamiento en tiempo real, ayudando a los profesionales en el reconocimiento de las imágenes de ecografías pulmonares, permitiendo cuantificar la recirculación y la pérdida de aireación pulmonar, contribuyendo con elementos no subjetivos en la interpretación de los resultados.

4.4 Otras muestras en videos

A modo de prueba, se considera que el método TRFG también podría ser adecuado para analizar trayectorias y movimientos en videos, siempre procesando cada píxel a través del tiempo como una señal. Se muestran dos ejemplos con videos tomados con una cámara fija, obtenidos de la base de datos *changedetection.net* [52] y *Action Recognition de Hueijian* [53][54] respectivamente.

El primer caso (Fig. 4.29) corresponde a una serie de imágenes tomadas en una estación de tren, donde se puede analizar el movimiento de peatones, en este caso se tomaron fragmentos del conjunto de imágenes consecutivas, uno del principio (Fig. 4.29 b)) y otro en un momento de más actividad (Fig. 4.29 c)). En ambos casos se detecta claramente la dirección en que se mueven los peatones en cada período y la densidad de peatones en los mismos.

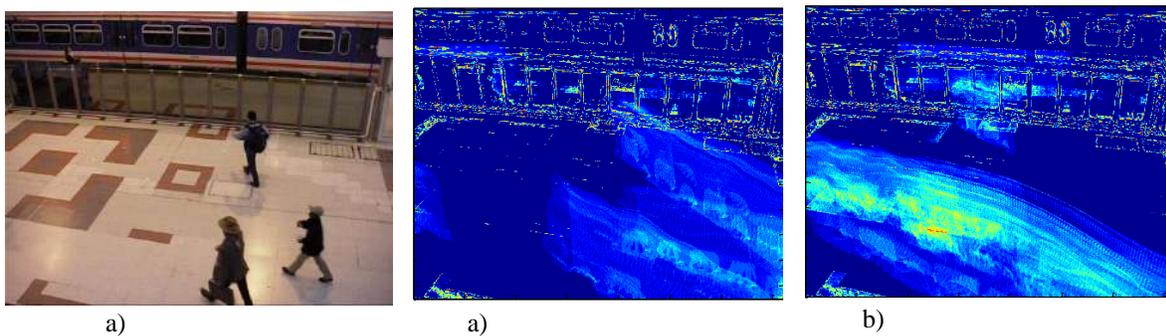


Fig. 4.29 Movimiento en una estación de tren, a) Una imagen original, b) Actividad en la apertura, c) Actividad con mayor concurrencia

El segundo caso (Fig. 4.30) corresponde a un video de una persona saltando. En la Fig 4.30 b) se toma la actividad continua y en la Fig 4.30 c) la actividad en intervalos. En este caso las figuras muestran la ubicación de la persona en distintos tiempos dentro de la misma imagen. En ambas figuras la posición de la persona es claramente detectada.

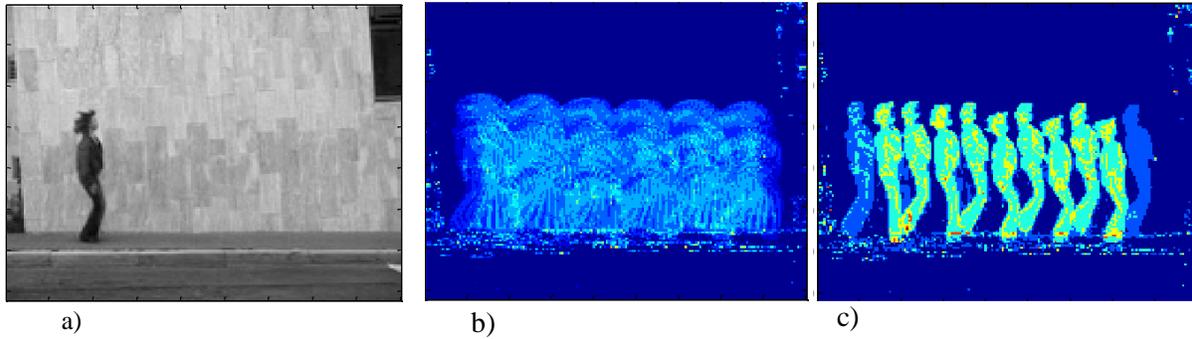


Fig. 4.30 Movimiento de una persona saltando, a) Primer imagen del video, b) Actividad total, c) Actividad en intervalos

4.5 Conclusiones

Los algoritmos TRFG y SFRG fueron creados con la idea de detectar actividad en muestras de DLS. Los resultados fueron satisfactorios en todos los casos aplicados, permitiendo reconocer actividad sin necesidad de un conocimiento profundo del fenómeno. En los casos que la metodología pudo ser comparada con distintos métodos utilizados, se lograron resultados positivos con menor costo computacional, permitiendo además obtener resultados en tiempos breves de muestreo, lo cual a la vez influyó en la posibilidad de observación de la evolución de la actividad durante el muestreo, pudiendo utilizarse para procesar la información en tiempo real.

En ultrasonido fue posible detectar actividad creada por el *speckle*, obteniéndose nuevos parámetros para la evaluación de las imágenes, detectando actividades casi imperceptibles en los videos. Al igual que con el DLS, los resultados obtenidos dieron lugar a diversas publicaciones.

En otros videos, en los cuales no existe el fenómeno *speckle*, el algoritmo TRFG permitió detectar claramente los objetos en movimiento, lo cual podría ser de utilidad en la visión computacional.

4.6 Referencias

- [1] Huang, D., Swanson, E., Lin, C., Schuman, J., Stinson, W., Chang, W., Hee, M., Flotte, T., Gregory, K., Puliafito, C. and Fujimoto, (1991), Optical coherence tomography. *Science*. 254. 1178-1181.
- [2] Nicolaides, L., Mandelis, (2000), A. Experimental and image-inversion optimization aspects of thermal-wave diffraction tomographic microscopy. *Opt. Express*, 7 (13). 519-532.
- [3] Yasuda, T., Yasui, T., Araki, T. and Abraham E., (2006), Real-time two-dimensional terahertz tomography of moving objects. *Opt. Commun.* 267. 128-136.
- [4] Amalvy, J., Lasquibar, C., Arizaga, R., Rabal, H., Trivi, M., (2001), Application of dynamic speckle interferometry to the drying of coatings, *Prog. Org. Coat.* 42. 89-99.
- [5] Arizaga, R., Grumel E., Cap, N., Trivi, M., Amalvy, J., Yepes, B., Ricaurte, G. (2006), Following the drying of spray paints using space and time contrast of dynamic speckle, *J. Coat. Technol.* 3 (4). 295-299.
- [6] Faccia, P., Pardini, O., Amalvy, J., Cap N., Grumel, E., Arizaga, R. and Trivi M. (2009), Differentiation of the drying time of paints by dynamic speckle interferometry. *Prog.Org.Coat.* 64 (4), 350-355.
- [7] Rabal H.J., Braga R. editores. (2008). *Dynamic Láser Speckle and Applications*. CRC Press. Boca Raton, USA. ISBN 978-1-4200-6015-7.

- [8] Sierra Sosa, D. E. ; Tebaldi, M. C. ; Grumel, E. E.; Rabal, H. J. ; Elmaghraby, A. (2018), Localized analysis of paint-coat drying using dynamic speckle interferometry. *Opt Lasers Eng.*, 106. 61-67.
- [9] Passoni I., **Dai Pra** A., Rabal H., Trivi M., Arizaga R. (2005). Dynamic speckle processing using wavelets-based entropy. *Opt. Commun.*, 246. 219-228.
- [10] **Dai Pra**, A., Passoni, L., Rabal, H. (2009), Evaluation of laser dynamic speckle signals applying granular computing, *Signal Process.* 89. 266–274.
- [11] **Dai Pra**, A.L., Passoni, L. I., Rabal H. (2009), Fuzzy Granular Computing and Dynamic Speckle Interferometry for the Identification of Different Thickness of Wet Coatings. *Journal of Computing Science.* 8 (4). 45-51.
- [12] Passoni L. I., **Dai Pra** A. L, Meschino G. J., Guzmán M. N., Scandurra A. G., González M. A., Cap N. Rabal H. L., Trivi J., M. (2016), DLS algorithms assessment applied to the identification of minor differences in sample activity. Poster. IX. *Iberoamerican Meeting on Optics and XII Iberoamerican Meeting on Optics, Lasers and Applications (RIAO / OPTILAS)*. Pucón, Chile, 21 al 25 de Noviembre 2016.
- [13] **Dai Pra** A. L., González M. A., Guzmán M. N., Scandurra A. G., Meschino G. J., Passoni L. I., Cap N. Rabal H. L., Trivi. J., M. (2017), Comparison of Algorithms for Descriptor Computation in Activity Speckle Images. *24th Congress of International Commission for Optics*, Tokyo, Japan, August 2017.
- [14] **Dai Pra**, A.L., Passoni, I.L., Maldonado, E. (2007), Granularidad Difusa para la Segmentación de Topografías Utilizando Speckle Dinámico, *Simposio Argentino de Tecnología - AST 2007 (36 JAIIO)*. Mar Del Plata - Buenos Aires. 27-31 agosto 2007.
- [15] **Dai Pra**, A.L., Rabal H. (2018), Visualization of natural processes applying rough-fuzzy temporal granularity to laser speckle images. *Opt. Pura Apl.* 51 (2) 50017:1-11.
- [16] AOSA (1983), *AOSA Seed Vigor Testing Handbook*, 32, Springfield, IL, 82–88..
- [17] Blandino, M., M. C. Mancini, A. Peila, L. Rolle, F. Vanara, and A. Reyneri. (2010), Determination of maize kernel hardness: comparison of different laboratory test to predict dry-milling performance. *J. Sci. Food Agric.* 90. 1870–1878.
- [18] Bruinsma J, ed. (2003). *World agriculture: towards 2015/2030*, an FAO perspective. Earthscan Publications Ltd. FAO, Rome.
- [19] Berger, L., and V. Singh. (2010), Changes and evolution of corn co-products for beef cattle. *J. Anim. Sci.* 88. 143–150.
- [20] Weber, C., **Dai Pra** A. L., Passoni L. I., Rabal H., Trivi M., Poggio Aguerre G. J. (2014), Determination of maize hardness by biospeckle and fuzzy granularity. *Food Science & Nutrition.* 2 (5). 557–564.
- [21] **Dai Pra** A. L., Rabal H., Bértora G., Finger P., Passoni L.I. (2015), Temporal and Spatial Fuzzy granularity of laser and ultrasound frames. *VI Latin American Congress on Biomedical Engineering CLAIB 2014*. Springer-Verlag. Series: IFMBE Proceedings 49. Braidot, Ariel, Hadad, Alejandro (Eds.). 405-408. DOI 10.1007/978-3-319-13117-7_104. Print ISBN 978-3-319-13116-0. Online ISBN 978-3-319-13117-7.
- [22] Passoni L. I., **Dai Pra** A. L., Meschino G. J., Guzmán M., Weber C., Rabal H., Trivi M., (2014). Unsupervised learning segmentation for dynamic speckle activity images *physics.optics* arXiv:1408.3818.
- [23] Meschino G J, Gaggini A, Weber C, **Dai Pra** A L, Rabal H, Trivi M. y Passoni L I. (2013), Caracterización del endospermo de semillas de maíz con técnicas de speckle láser dinámico. *SABI 2013- XIX Congreso Argentino de Bioingeniería*. 4 al 5 de setiembre, 2013. San Miguel de Tucumán.
- [24] Han F, Long H, Shaochun M, Manoj K, Du Ch, Qin Z, Shumao W. (2016), Bruise Responses of Apple-to-Apple Impact. *IFAC-PapersOnLine* 49. 347–352.

- [25] Yuhui Y, Zengrong Y, Hubin L, Huaibin W, Junhui L, Longlian Z. (2022), Detection of early bruise in apple using near-infrared camera imaging technology combined with deep learning. *Infrared Physics & Technology* 127. 104442.
- [26] Pajuelo M, Baldwin G, Rabal H, Cap N, Arizaga R and Trivi M. (2003), Bio-speckle assessment of bruising in fruits *Opt. Lasers Eng.* 40 13–24.
- [27] Oulamara A., Tribillon G., Duvernoy J. (1989). Biological activity measurements on botanical specimen surfaces using a temporal decorrelation effect of laser speckle, *Journal of Modern Optics* 36, 165-179.
- [28] **Dai Pra** A. L., Passoni. L. I. Rabal H. (2009), Temporal Granular Computing in Dynamic Speckle Signal processing. *XIII Reunión de Trabajo en Procesamiento de la Información y Control. RPIC 2009*. 16 al 18 setiembre 2009. Rosario. ISBN 950-665-340-2.
- [29] **Dai Pra** A. L., Passoni L. I., Sendra G. H., Trivi M. & Rabal H. J. (2015), Signal Feature Extraction Using Granular Computing. Comparative Analysis with Frequency and Time Descriptors Applied to Dynamic Laser Speckle Patterns, *International Journal of Computational Intelligence Systems*, 8. 28-40. DOI: 10.1080/18756891.2015.1129589
- [30] Ortiz CC, Sendra GH, Rabal HJ, Arizaga R, Trivi M. (2008), Dynamic speckle algorithms comparison using receiver operating characteristic. *Opt Eng* 47 (05). 057005.
- [31] Kohonen T.(1995). *Self-Organizing Map*, Springer, SSINF 30,
- [32] Passoni L. I., **Dai Pra** A. L., Scandurra A., Meschino G., Weber C., Guzmán M., Rabal H., Trivi M. (2013), Improvements in the Visualization of Segmented Areas of Patterns of Dynamic Láser Speckle. *Advances in Self-Organizing Maps*. Springer-Verlag. Berlin. Pablo A. Estevez, José C. Príncipe, Pablo Zegers editors. 163-171. ISBN 978-3-642-35230-0.
- [33] **Dai Pra** A. L., Meschino G., Guzmán M., Scandurra A., Gonzales M.A., Weber C., Trivi M., Rabal H., Passoni L. I. (2016), Dynamic speckle image segmentation using self-organizing maps. *J. Opt.* 18085606-18085617.
- [34] Damerjian V., Tankyevych O., SouagN., Petit E. (2014), Speckle characterization methods in ultrasound images – A review. *IRBM* 35 (4). 202–213.
- [35] Dantas R. G., Costa E.T., Leeman S. (2005), Ultrasound speckle and equivalent scatterers, *Ultrasonics* 43. 405–420.
- [36] Marín Aguilera B., Moreno Anaya P., García Raya P. S., . Fernández Prieto A. Frutos Martínez F, R., Asencio Durán M. (2012). Utilidad de la ecografía en el melanoma coroideo: Revisión de 200 casos. *31 congreso nacional SERAM (sociedad española de radiología médica) 2012*. Granada , mayo 2012
- [37] Ruiz-Medranoa J., Flores-Morenoa I., Gutierrez-Bonetb R., Chhablanic J., Ruiz-Moreno J.M. (2017), Update of choroidal imaging techniques: Past, present and future. *Arch Soc Esp Oftalmol* . 92 (3). 128–136.
- [38] Eye Cancer Network , in <https://www.eyecancer.com/research/case-studies/31/eye-cancer-network-case-17-ultrasound-of-intrinsic-vascularity>
- [39] **Dai Pra** A. L., Rabal H., Bértora G., Finger P. Passoni I. (2015), Temporal and Spatial Fuzzy granularity of láser and ultrasound frames. *VI Latin American Congress on Biomedical Engineering CLAIB 2014*. Springer-Verlag. Series: IFMBE Proceedings 49. Braidot, Ariel, Hadad, Alejandro (Eds.). 405-4082015, DOI 10.1007/978-3-319-13117-7_104.Print ISBN 978-3-319-13116-0. Online ISBN 978-3-319-13117-7. .
- [40] **Dai Pra** A.L., Passoni L.I. (2015), Rough-Fuzzy Granularity in the Study of Optical Phenomena. *Workshop Fuzzy Logic in Artificial Intelligence, IJCAI 2015*, Buenos Aires, Julio 2015. CEUR Workshop Proceedings 1424, CEUR-WS.org.
- [41] Basso F., **Dai Pra** A.L., Passoni L.I. Irarrázaval A. (2017), Análisis de videos de ultrasonido de melanomas oculares usando descriptores de granularidad temporal. *XXI Congreso Argentino de Bioingeniería SABI 2017- X Jornadas De Ingeniería Clínica*. Córdoba. 25 al 27 de Octubre de 2017.

- [42] Volpicelli G, Elbarbary M, Blaivas M, Lichtenstein D A, Mathis G, Kirkpatrick A W, Melniker L, Gargani L, Noble V E, Via G, Dean A, Tsung J W, Soldati G, Copetti R, Bouhemad B, Reissig A, Agricola E, Rouby J J, Arbelot C, Liteplo A, Sargsyan A, Silva F, Hoppmann R, Breitzkreutz R, Seibel A, Neri L, Storti E, Petrovic T and International Liaison Committee on Lung Ultrasound for International Consensus Conference on Lung U 2012. International evidence-based recommendations for point-of-care lung ultrasound. *Intensive Care Med.* 38(4) 577-591.
- [43] Lichtenstein D A and Meziere G A (2008). Relevance of lung ultrasound in the diagnosis of acute respiratory failure: the BLUE protocol *Chest* 134. 117-25.
- [44] Lichtenstein D A (2009), Ultrasound examination of the lungs in the intensive care unit. *Pediatr Crit Care Med.* 10 693-698.
- [45] Volpicelli G.(2013), Lung sonography. *J Ultrasound Med* 32. 165-171.
- [46] Parlamento S, Copetti R and Di Bartolomeo S.(2009), Evaluation of lung ultrasound for the diagnosis of pneumonia in the ED. *The American journal of emergency medicine* 27 379-384.
- [47] Lichtenstein D A, Lascols N, Meziere G and Gepner A. (2004), Ultrasound diagnosis of alveolar consolidation in the critically ill. *Intensive care medicine* 30 276-281.
- [48] Acosta C M, Maidana G A, Jacovitti D, Belaunzaran A, Cereceda S, Rae E, Molina A, Gonorazky S, Bohm S H and Tusman G. (2014), Accuracy of transthoracic lung ultrasound for diagnosing anesthesia-induced atelectasis in children *Anesthesiology* 120. 1370-1379.
- [49] Tusman G, Bohm S H, Tempura A, Melkun F, Garcia E, Turchetto E, Mulder P G and Lachmann B (2003), Effects of recruitment maneuver on atelectasis in anesthetized children. *Anesthesiology* 98 14-22.
- [50] Bouhemad B, Brisson H, Le-Guen M, Arbelot C, Lu Q and Rouby J. (2011), Bedside ultrasound assessment of positive end-expiratory pressure-induced lung recruitment *American journal of respiratory and critical care medicine* 183 341-347.
- [51] **Dai Pra** L, Meschino G. J., Acosta C., Tusman G., Rabal H. J., Passoni L. I. (2015), Análisis dinámico de ecografías de pulmón por medio de descriptores basados en el cálculo de gránulos temporales, *XX Congreso Argentino de Bioingeniería (SABI 2015) y IX Jornadas de Ingeniería Clínica*. San Nicolás. Prov..Bs As. 28 al 30 de octubre de 2015.
- [52] <http://jacarini.dinf.usherbrooke.ca/dataset2012/>
- [53] https://github.com/hueihan/Action_Recognition/tree/master/data/WIS/video
- [54] Kuhne H., Jhuang H., Garrote E., Poggio T. and Serre T. (2011), HMDB: A Large Video Database for Human Motion Recognition. *IEEE International Conference on Computer Vision (ICCV)*.

Conclusiones

La presente tesis expone una estrategia computacional para el procesamiento de señales, partiendo de conceptos de la IC, particularmente muestra la aplicación de la granularidad computacional (GrC), un concepto que surge de la utilización de la lógica difusa.

La GrC, surge como una forma de procesar datos para encontrar información oculta en los mismos y como un paradigma para la resolución de problemas, reuniendo varias metodologías anteriormente existentes que se enriquecieron con el surgimiento de la lógica y los conjuntos difusos, así como con otros tipos de conjuntos como los rugosos y sombreados, que fueron surgiendo como necesidad para simplificar los procesos de la GrC. El principal objetivo parte de la premisa “divide y conquistarás” pudiendo existir muchas formas de dividir un todo para hacerlo tratable.

En la actualidad son muchos los dispositivos que muestran sus resultados mediante señales digitales, especialmente en el área de las ciencias biológicas/médicas. La comprensión de esas señales generalmente está dada por el conocimiento de expertos que las manejan, aunque a veces no puedan ser totalmente comprendidas. La IC tiene, entre sus propósitos, responder con mayor eficiencia a requerimientos del ser humano, brindando resultados útiles y comprensibles.

A diferencia de algunas metodologías tradicionales, no existe una forma general para aplicar GrC. Como todo tema vinculado al comportamiento humano inteligente, es dependiente de contexto y de la visión del observador.

En el caso de señales digitales, las lógicas difusas pueden aplicarse a alguna/s de las características que definen una señal, más bien dadas por la visión del usuario que por el ingeniero de procesamiento de señales. La señal se particiona en un conjunto de atributos de límites imprecisos que expresan preferencias del usuario y/o particularidades del contexto de los datos o dominio de aplicación, definiendo así gránulos en un concepto particular y que podrán estar representado por reglas de producción en un sistema experto con componentes difusos, *clusters* difusos, conjuntos e intervalos, entre otros.

La principal aplicación desarrollada corresponde al análisis del fenómeno de *speckle* dinámico, fenómeno que se produce al iluminar con láser una muestra que presenta algún tipo de actividad no perceptible a simple vista. El patrón generado puede ser capturado en el tiempo, y la variación de intensidad de cada píxel a través del tiempo muestra señales, aparentemente azarosas, que dependen de la superficie del objeto observado y de la actividad que en éste se está produciendo en cada parte de la zona observada.

Distintos estudios se han llevado a cabo para tratar explicar una dinámica del comportamiento de las superficies estudiadas, obteniéndose descriptores de actividad en cada píxel. La obtención de esos descriptores muchas veces requiere de gran cantidad de PS y su procesamiento puede ser de alto costo computacional. Además, algunas metodologías responden adecuadamente solo en algunos tipos de muestras. El algoritmo de TRFG, desarrollado con el concepto de GrC, ha demostrado su efectividad en todas las muestras analizadas y un bajo costo computacional, tanto en tiempo de ejecución como en recursos de memoria, presentando la posibilidad de estudios en tiempo real.

El algoritmo fue desarrollado en la plataforma Matlab, que por su característica matricial, permite procesar todas las señales de un muestreo simultáneamente. Para realizar comparaciones con otros métodos, todos fueron reprogramados con cálculo matricial y la misma lógica a fin evaluar el costo computacional con parámetros comparables.

Como otra alternativa al análisis de los PS se desarrolló una metodología espacial (SRFG), con la que se ha logrado observar regiones de distintos tipos de actividad con un único PS, en algunos casos esa actividad coincidió con la obtenida con varios PS con TRFG y en otros mostró ser complementaria, brindando otro tipo de información. Al analizar gránulos espaciales en el tiempo, el valor actividad de los gránulos espaciales tendía a mantenerse en el tiempo. Esto señala que el gránulo espacial marca características por sí solo y podría ser importante solo para analizar PS individuales.

Como básicamente el algoritmo TRFG fue creado para detección de actividad, es probado para detectar actividad en videos donde hay objetos en movimiento sobre un fondo estático, abriendo la posibilidad de detección de movimiento en visión artificial.

El objetivo de la granularidad computacional es dividir un volumen de datos en partes para hacerlo tratable. Desde este punto de vista, la idea es que la granularidad pueda ir variando de granularidades más finas (la más fina es el dato) a más gruesas para el tratamiento de los datos. Como tal, en el caso de los descriptores de actividad en speckle, se podrían aplicar distintos niveles de granulación para caracterizar una actividad. Ello es muy útil en los casos de ultrasonido donde las señales cambian con mucha facilidad por movimientos difíciles de controlar. El poder distinguir distintas particularidades brinda información para implementar sistemas expertos que expliquen características de las actividades.

Apéndice A

Abreviaturas utilizadas en orden alfabético

AD: (*Averaged Differences*) Diferencias Promedio
AUC: (*Area Under the Curve*) Área Bajo la Curva
CCD: (*Charge Coupled Device*) Dispositivo de Carga Acoplada
CF: (*Cutoff Frequency*) Frecuencia de Corte
DLS: (*Dynamic Laser Speckle*) Speckle Láser Dinámico
DWTE : (*Discrete Wavelet Transform Entropy*) Entropía de la Transforma Discreta de Onditas
ESB: (*Energy Spectral Band*) Energía de Banda Espectral
FCM (*Fuzzy C Means*) C medias difuso
FPGA: (*Field Programmable Gate Array*) Matriz de puertas lógicas programable en campo
FWHMA : (*Full Width Half Maximum of the Autocorrelation*) Autocorrelación
GD : (*Generalized Differences*) Diferencias Generalizadas
GrC: (*Granular Computing*) Granularidad Computacional
GrI: Gránulo de Información
GrCT: Granularidad Computacional Temporal
IA: Inteligencia Artificial
IC: Inteligencia Computacional
HLR: (*High Low Ratio*) Relación Alta Baja frecuencia
MF: (*Mean Frequency*) Frecuencia Media
PEEP: (*Positive End-Expiratory Pressure*) Presión Positiva al Final de la Espiración:
PS: Patrón de Speckle
PSD: (*Density Spectral Power*) Densidad Espectral de Potencia
RFGD : (*Rough Fuzzy Granular Descriptor*) Descriptor Granular Rugoso-Difuso
ROC : (*Receiver Operating Characteristic*) Característica Operativa del Receptor
SA: (*Subtraction Average*) Resta promedio de intensidades consecutivas
SD: (*Standard Deviation*) Desviación Estándar
SE: (*Shannon Entropy*) Entropía de Shannon
SOM: (*Self-Organizing Map*) Mapa Auto-Organizado
SRFG: (*Spacial Rough-Fuzzy Granularity*) Granularidad Difuso-Rugosa Espacial
SSD: Señales de Speckle Dinámico
TC: (*Temporal Contrast*) Contraste Temporal
THSP: (*Time History Speckle Pattern*) Historia temporal de los Patrones de Speckle

TRFG: (*Temporal Rough-Fuzzy Granularity*) Granularidad Difuso-Rugosa Temporal

UP: Ultrasonido Pulmonar

US: Ultrasonido

WGD: (*Weighted Generalized Differences*) Diferencias Generalizadas Ponderadas

Apéndice B

Conjuntos

En este apéndice se da una breve descripción acerca de la teoría de conjuntos, sin entrar en la lógica o en definiciones que no hacen al tema de la tesis. Básicamente se refiere a los conjuntos difusos, a los conjuntos rugosos y al agrupamiento difuso (FCM)

B.1 Conjuntos clásicos

La noción de conjuntos es básica en las matemáticas. La definición de esta noción y la creación de la teoría de conjuntos fue formulada por el matemático alemán Georg Cantor (1845-1918) [1], quien estableció los fundamentos de esta teoría contemporánea hace más de 100 años. Según Cantor, un conjunto es una colección de objetos, que pueden ser considerados como un todo según alguna ley.

Conceptos matemáticos tales como relaciones, funciones, números, son ejemplos de conjuntos. La noción de conjunto no solo es fundamental en las matemáticas, sino que también juegan un rol importante en la lengua y la informática

La pertenencia de un objeto a un conjunto o relación entre conjuntos se basa en la lógica clásica, donde su pertenencia toma valores de verdadero o falso.

Los miembros de un conjunto son tomados de un universo de discurso. El universo consiste en todos los objetos que pueden entrar en consideración, lo cual depende del contexto.

B.2 Conjuntos difusos

La matemática requiere que toda noción y razonamiento (incluyendo conjuntos) sea exacto; sin embargo; filósofos [2][3][4][5] e informáticos así como otros investigadores se han interesado en los conceptos vagos o imprecisos

En la teoría clásica de conjuntos, un conjunto es determinado únicamente por sus elementos, es decir que cada elemento únicamente debe ser clasificado como perteneciendo o no al conjunto. Casi todos los conceptos utilizados en la lengua natural son vagos; por lo tanto, el razonamiento del sentido común basado en el lenguaje natural, debe estar basado en conceptos vagos y no en la lógica clásica [5]. Este es el caso de los problemas relativos a la lengua natural, la ciencia cognoscitiva, la inteligencia artificial, el estudio del aprendizaje de máquina, filosofía e informática.

A principios del siglo XX, el filósofo y matemático británico Bertrand Russell divulgó la idea de que la lógica produce contradicciones [5]. Realizó un estudio sobre las vaguedades del lenguaje, concluyendo con precisión que la vaguedad es un grado. En 1920 Jan Lukasiewicz, desarrolló la primera lógica de vaguedades. Para él los conjuntos tienen un posible grado de pertenencia con valores que oscilan entre 0 y 1, y en este intervalo existen un número infinito de valores [7]

Basado en esas ideas, Lotfi Zadeh formaliza el concepto de lógicas difusas (*fuzzy logic*). Zadeh propuso el concepto científico en 1965 [8], siendo profesor de ciencia de computadoras en la Universidad de California en Berkeley, ejerciendo un fuerte impacto en las tecnologías de computación.

El argumento de Zadeh se asemejó a una idea que Albert Einstein había expresado cuatro décadas antes en su libro "La Geometría y la Experiencia", la cual decía "En la medida en que las leyes de las matemáticas se refieren a la realidad, no son ciertas; y en la medida en que son ciertas, no se refieren a la realidad" ("As far as the laws of mathematics refer to reality, they are not certain; and as far as they are certain, they do not refer to reality"). Su idea no tardó en trascender, en particular en Japón. En los años ochenta, ingenieros de la empresa Hitachi en Sendai, incorporan la lógica difusa en el diseño del nuevo metro de la ciudad, usándola para desarrollar un sistema que mejoraba y suavizaba las frenadas y paradas del tren, logrando mejora y economía en el servicio. Surgieron a continuación gran cantidad de aparatos electrónicos domésticos, como cámaras fotográficas y filmadoras, lavaropas y secaropas, transmisiones de vehículos y sistemas de frenado antipatinada, acondicionadores de aire y termostatos, cocinas de arroz, aspiradoras y helicópteros no tripulados, que incorporaron controladores difusos.

Muchas proposiciones sobre el mundo real no son verdaderas o falsas, siendo la lógica clásica inadecuada para razonar con tales proposiciones. Además, la mayor parte de conceptos usados en la comunicación humana no tienen fronteras definidas, siendo los conjuntos clásicos inadecuados para representar esos conceptos. El objetivo principal de lógica difusa y los conjuntos difusos es superar las limitaciones de la lógica y los conjuntos clásicos en la solución de problemas reales.

B.2.1 Notaciones

La lógica difusa es básicamente una lógica multivaluada que permite valores intermedios para poder definir evaluaciones convencionales como sí/no, verdadero/falso, negro/blanco, etc. Las nociones como "más bien caliente" o "poco frío" pueden formularse matemáticamente y ser procesados por computadoras. La necesidad de trabajar con conjuntos difusos surge de del hecho que existen conceptos cuyos límites no están claramente definidos. De esta forma se ha realizado un intento de aplicar una forma más humana de pensar en la programación de computadoras.

Considerando la teoría de conjuntos tradicionales. Dado un conjunto X que comprende todos los números reales entre 1 y 10, en este caso Universo de discurso, se puede definir un subconjunto A de X con los números reales entre 4 y 6.

$$A = \{ x \in U / 4 \leq x \leq 6 \} \quad (1)$$

Definiendo el conjunto A por su función característica, se asigna un valor 1 o 0 a cada elemento en X , dependiendo de si el elemento pertenece o no al subconjunto A .

$$\mu_A(x) = \begin{cases} 1 & \text{si } x \in [4,6] \\ 0 & \text{si } x \notin [4,6] \end{cases} \quad (2)$$

Como un ejemplo más natural se podría describir el conjunto de las personas jóvenes. Más formalmente se puede denotar como $B = \{persona\ joven\}$.

Los miembros del conjunto B estarán definidos por su edad. El rango de edad que define el conjunto Universal considerado será dependiente del contexto. En general, se podría considerar un rango de 0 a 100 y se podría definir en un conjunto clásico $B = [0,23]$. Ello implica que una persona de 24 años no es joven dentro del contexto definido.

En muchos casos resulta difícil determinar la pertenencia o no a un conjunto, ya que intervienen consideraciones subjetivas. En el conjunto de las personas jóvenes no puede determinarse un criterio que establezca un límite exacto entre pertenecientes y no pertenecientes al mismo. En estos casos se introduce la vaguedad y desaparece la frontera que divide a los miembros y no miembros de un conjunto.

Una manera más natural de construir el conjunto B es suavizar la separación estricta entre el joven y el no joven y hacer frases más flexibles como "pertenece casi al conjunto de persona joven" o "es más o menos joven". Un conjunto difuso permite definir esas nociones.

En los conjuntos clásicos los elementos del conjunto B en U deben ser valuados con 0 o 1. Una manera de generalizar el concepto "joven" está en permitir utilizar valores de pertenencia reales entre 0 y 1. El valor 1 asignado a un elemento significa que claramente pertenece al conjunto B y el valor 0 significa que el elemento no está definitivamente en el conjunto el B . Pero se podrá asignar una pertenencia gradual al conjunto B a los elementos que no tienen pertenencia claramente definida.

Gráficamente el conjunto de *persona joven* dado por su edad sería como se muestra en la Fig.B.1. De esta forma, con conjuntos difusos, una persona de 25 años de edad todavía sería joven en un cierto grado.

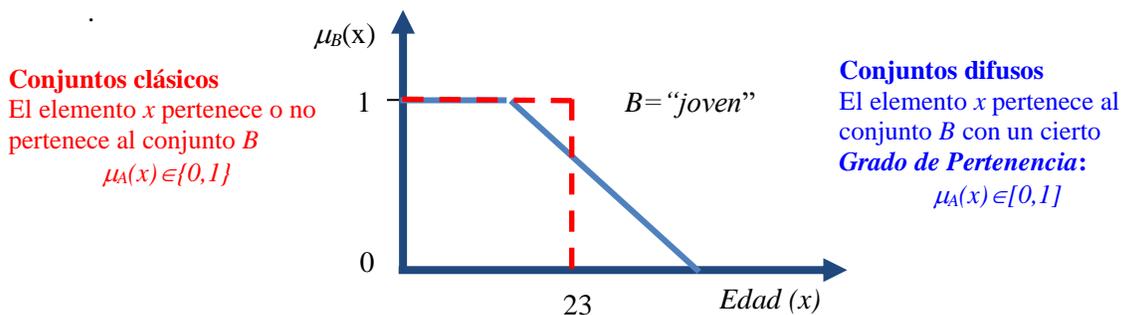


Fig. B.1. Representación del conjunto B como conjunto clásico y conjunto difuso

Un conjunto difuso se define con una función de pertenencia $\mu_A(x)$, que empareja los elementos X de un dominio $\subseteq U$ con elementos del intervalo $[0,1]$. La función de pertenencia puede tomar distintas formas, tales como: triangular, trapezoidal, campana, gaussiana u otras, de acuerdo a sus parámetros (Fig. B.2). Por ejemplo, una función de pertenencia trapezoidal es una función lineal y continua por partes, controlada por cuatro parámetros $\{a, b, c, d\}$, donde $\mu_A(x)=1$ para $x \in [b, c]$ y toma valores decrecientes a ambos lados de ese intervalo.

Un conjunto difuso A cuyo universo es discreto, puede representarse como un conjunto de pares de valores: Cada elemento $x \in X$ con su grado de pertenencia a A .

$$A = \{(x, \mu_A(x)) / x \in U\} \tag{3}$$

también puede expresarse como una "suma" de pares:

$$A = \sum_U \mu_A(x) / x \tag{4}$$

o como una integral, si el Universo es continuo:

$$A = \int_U \mu_A(x) / x \tag{5}$$

la suma y la integral no deben considerarse como operaciones algebraicas, solo indican una enumeración de duplas, donde / no indica división sino la separación de las duplas.

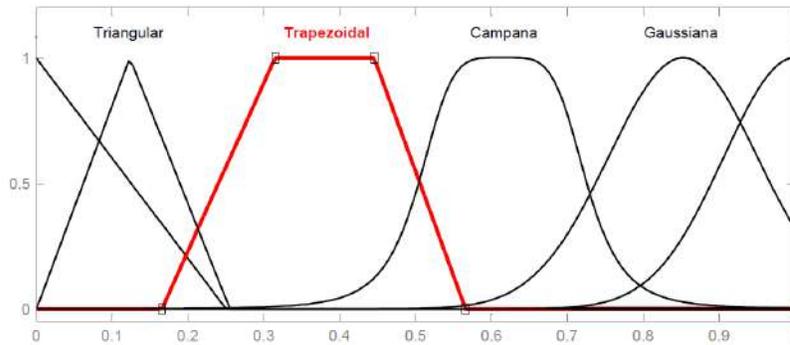


Fig. B.2. Distintos tipos de funciones de pertenencia para conjuntos difusos

B.2.2. Definiciones

Algunas definiciones referentes a los conjuntos difusos se presentan a continuación, las cuales están representadas en la Fig B.3.

- *variable lingüística*: noción o concepto que se va a calificar de forma difusa. Por ejemplo: altura, edad, error, variación del error.
- *universo de discurso (U)* : rango de valores que pueden tomar los elementos que poseen la propiedad expresada por la variable lingüística.
- *valor lingüístico*: diferentes clasificaciones o conceptos sobre la variable lingüística: en el caso de la altura, se podría dividir el universo de discurso en diferentes valores lingüísticos: por ejemplo baja, mediana y alta.
- *conjunto difuso*: valor lingüístico junto a una función de pertenencia. El valor lingüístico es el “nombre” del conjunto, y la función de pertenencia se define como aquella aplicación que asocia a cada elemento del universo de discurso el grado con que pertenece al conjunto difuso. Un conjunto es preciso (*crisp*) si su función de pertenencia toma valores en $\{0,1\}$ y difuso si toma valores en $[0,1]$.

Para un conjunto difuso A:

- *alfa-corte* de A, es el conjunto de elementos que pertenecen al conjunto difuso A con grado mayor o igual que α , es decir:

$$A_{\alpha} = \{x \in X / \mu_A(x) \geq \alpha\} \quad (6)$$

- *alfa corte estricto* de A, es el conjunto de elementos con grado de pertenencia estrictamente mayor que alfa, es decir:

$$A_{\alpha+} = \{x \in X / \mu_A(x) > \alpha\} \quad (7)$$

- *soporte (support)* de un conjunto difuso A, es el conjunto de elementos que tienen grado de pertenencia estrictamente mayor que 0, o sea, al α -corte estricto es 0.

$$Supp(A) = \{x \in X / \mu_A(x) > 0\} \quad (8)$$

- *núcleo (core)* de un conjunto difuso A, es el conjunto de elementos que tienen grado de pertenencia 1. (α -corte = 1)

$$Core(A) = \{x \in X / \mu_A(x) = 1\} \quad (9)$$

- *altura* de un conjunto difuso A es el valor más grande de su función de pertenencia.

- Un conjunto difuso está *normalizado* si y solo si su núcleo contiene algún elemento (o alternativamente, si su altura es 1), es decir:

$$\exists x \in X / \mu_A(x) = 1 \quad (10)$$

- Un conjunto difuso cuyo soporte es un único punto x de U y tal que la función de pertenencia de x es 1 (es decir, el soporte coincide con el núcleo y tienen un único punto) se llama un unitario (*singleton*).

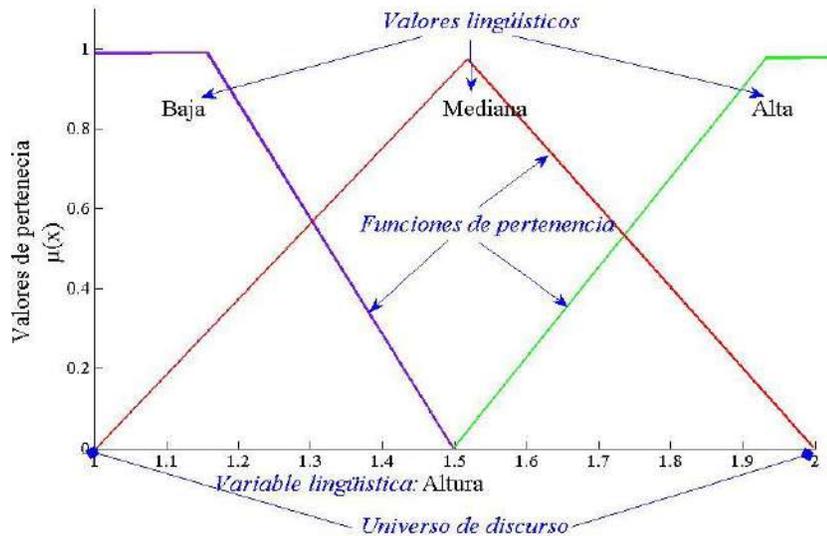


Fig.2.3. Definiciones en conjuntos difusos

Según Zadeh, un conjunto difuso induce una distribución de posibilidades en el universo, lo que implica que uno puede interpretar los valores de pertenencia como posibilidades, que deben ser diferenciadas de las probabilidades. En primer lugar, en un caso discreto, las probabilidades deben sumar uno, las posibilidades pueden sumar cualquier valor. En segundo lugar, una distribución de probabilidad se refiere a la probabilidad de que ocurra un evento, basada en observaciones, mientras que una distribución de posibilidades (función de pertenencia) es subjetiva. La palabra "probablemente" es sinónimo de "presumiblemente", "sin duda", "probable" o "presuntamente". La palabra "posible" es sinónimo de "factible", "practicable" o "viable". Su relación se describe mejor en la oración, "lo que es probable siempre es posible, pero no al revés".

B.3. Conjuntos rugosos o aproximados (rough sets)

La teoría de conjuntos rugosos, propuesta por Pawlak en 1982 [9] es otro acercamiento matemático a la imprecisión [10][11].

La filosofía de conjuntos rugosos está fundada en la suposición de que a cada objeto del Universo de discurso asociamos alguna información (datos, conocimiento). Objetos caracterizados por la misma información son similares en vista de la información disponible sobre ellos. La relación de indiscernibilidad generada de este modo es la base matemática de la teoría de conjuntos rugosos. Esta relación está relacionada con la idea de Gottfried Wilhelm Leibniz que los objetos son indiscernibles si y sólo si todas las funcionalidades disponibles toman valores idénticos [11]. En los conjuntos rugosos la indiscernibilidad es definida en relación con un conjunto de atributos.

Un conjunto con todos los objetos indiscernibles es un conjunto elemental y forma un gránulo básico (átomo) de conocimiento sobre el Universo. Por consiguiente, cada conjunto rugoso

tiene casos de frontera, por ej., los objetos que no pueden con certeza ser clasificados como miembros del conjunto o de su complemento, porque no pueden ser clasificados empleando el conocimiento disponible.

Así, la suposición que los objetos pueden ser identificados sólo por la información disponible sobre ellos conduce a la opinión que el conocimiento tiene estructura granular. Debido a la granularidad de conocimiento, algunos objetos de interés no pueden ser distinguidos y aparecer como similares. Como consecuencia, conceptos difusos en contraste con conceptos precisos, no pueden ser caracterizados en términos de la información sobre sus elementos. Por lo tanto, la propuesta es, asumir que cualquier concepto difuso es substituido por un par de conceptos exactos, llamados aproximación superior e inferior del concepto difuso. La aproximación inferior consiste en todos los objetos que seguramente pertenecen al concepto y la aproximación superior contiene todos los objetos que posiblemente pertenecen al concepto. La diferencia entre la aproximación superior e inferior constituye la región límite del concepto difuso. Las aproximaciones son dos operaciones básicas en la teoría de conjuntos rugosos.

La teoría de conjuntos rugosos expresa vaguedad por emplear regiones límites en lugar de pertenencia como en los conjuntos difusos. Si la región límite del conjunto es vacía, quiere decir que el conjunto es preciso, sino es rugoso. Una región límite no vacía quiere decir que nuestro conocimiento sobre el conjunto no es suficiente para definir el conjunto con precisión.

Dado un sistema de información $S = (U, A)$, con U conjunto Universal que define todos los objetos a considerar, A es el conjunto que define todos los posibles atributos de los objetos considerados en U , se pueden definir subconjuntos $X \subseteq U$ and $B \subseteq A$ y clases de equivalencia $[x]_B$ las cuales definen una relación en la cual los elementos en X son indiscernibles de otros elementos por los atributos en B . Un conjunto rugoso es entonces definido por dos conjuntos:

$$\underline{B}X = \{x \in U : [x]_B \subseteq X\} \quad (11)$$

$$\overline{B}X = \{x \in U : [x]_B \cap X \neq \emptyset\}$$

los cuales son denominados como *B-aproximación inferior (B-lower approximation)* y *B-aproximación superior (B-upper approximation)* de X en B , Los objetos en $\underline{B}X$ son ciertamente miembros de B y los objetos en $\overline{B}X$ son posiblemente miembros de B , como lo expresa Pawlak en [9]. Las *aproximaciones inferior y superior* para una clase se muestran en la Fig. B.4, donde cada región rectangular representa una clase de equivalencia.

Los conjuntos rugosos pueden ser definidos a partir de conjuntos difusos dentro de un Universo. Dado $X \subseteq U$, se puede definir: la aproximación inferior como el conjunto todos los elementos de X que tienen función de pertenencia 1, es decir, $\mu_X(x)=1$; la aproximación superior es el conjunto de todos los elementos de X que tienen una función de pertenencia no igual a cero, es decir, $\mu_X(x) \neq 0$; la región límite (*RL*) son todos los elementos de X que tienen función de pertenencia $0 < \mu_X(x) < 1$, pudiendo expresar la aproximación superior, la aproximación inferior y la región límite del conjunto $X \subseteq U$ de la siguiente manera [13]:

$$\overline{R}X = \{x \in U / \mu_X(x) > 0\}$$

$$\underline{R}X = \{x \in U / \mu_X(x) = 1\} \quad (12)$$

$$RL(X) = \{x \in U / 0 < \mu_X(x) < 1\}$$

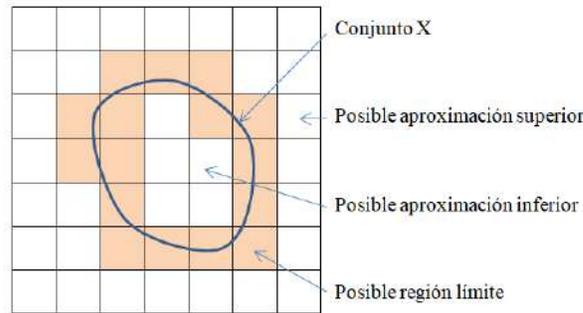


Fig. B.4: Representación de un conjunto rugoso

B. 4. Agrupamiento difuso FCM (*Fuzzy c-means*)

El agrupamiento de datos o clusterización consiste en la clasificación de datos en grupos de acuerdo a alguna característica en común. Existe distintos tipos algoritmos de agrupación, como los basados en densidad, donde los datos se agrupan por áreas de altas concentraciones de puntos de datos rodeadas por áreas de bajas concentraciones; los basados en la distribución, en los que se considera que todos los puntos de datos forman parte de un grupo según la probabilidad de que un punto pertenezca a un grupo determinado; los basados en jerarquías, se utilizan normalmente en datos jerárquicos; y los basados en centroides.

En el agrupamiento basado en centroides se separan los datos en función de centroides o centros de cluster. Cada punto de datos se asigna a un grupo en función de su distancia (generalmente euclidiana) al centroide. El algoritmo más conocido de este tipo de agrupamiento es el *k-means*, también denominado *Hard C Means* (HCM), por su comparación con FCM (*Fuzzy c-means*).

El agrupamiento FCM es una extensión del HCM. FCM fue propuesto por Dunn [14] en 1973 y generalizado por Bezdek [15] en 1981.

El agrupamiento se refiere a identificar un número c de subclases o clusters en un Universo de discurso X de n muestras o datos. Es un proceso iterativo de optimización que busca minimizar una función objetivo que determina las distancias de los datos a los centroides.

Los algoritmos HCM y FCM utilizan dos enfoques diferentes, en HCM los datos se incluirán en un cluster particular, mientras que en FCM, un dato puede incluirse en todos los clústeres existentes, pero con diversos grados de pertenencia, en un rango de valores [0 1]. Las funciones objetivo son prácticamente idénticas, la única diferencia es la introducción de una variable que expresa el grado de pertenencia de un dato dado a cada uno de los centroides. Ello está destinado a dar más importancia a las conexiones más fuertes (puntos más cercanos) y minimizar el peso de las más débiles.

Para HCM la función objetivo es:

$$J = \sum_{k=1}^n \sum_{i=1}^c \|x_k - v_i\|^2 \quad (13)$$

donde n es el número de datos, c es el número de clusters, que debe ser suministrado, x_k es el k -ésimo dato, v_i es i -ésimo centro de cluster, $\| \cdot \|^2$ indica distancia euclidiana (o norma 2) y $|\cdot|$ indica cantidad de elementos. Cada nuevo centro se calcula como:

$$v_i = \frac{\sum_{x \in C_i} x_i}{|C_i|} \quad (14)$$

En el caso del algoritmo FCM la función objetivo es:

$$J = \sum_{k=1}^n \sum_{i=1}^c \mu_{ik}^m \|x_k - v_i\|^2 \quad (15)$$

La cual se diferencia de HCM en el término μ_{ik}^m , donde m es una constante mayor que 1 (típicamente 2) relativa a la difusión (*fuzziness*) del cluster. μ_{ik} es definido como:

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_k - v_i\|}{\|x_k - v_j\|} \right)^{\frac{2}{m-1}}} \quad (16)$$

y cada nuevo centro se calcula como:

$$v_i = \frac{\sum_{k=1}^n \mu_{ik}^m x_k}{\sum_{k=1}^n \mu_{ik}^m} \quad (17)$$

El costo computacional del FCM es proporcional a la cantidad de datos y cantidad de clusters elegidos.

B.5. Referencias

- [1]. Cantor G. (1883), *Grundlagen einer allgemeinen Mannigfaltigkeitslehre*, B.G. Teubner, Leipzig.
- [2]. Keefe R. (2000), *Theories of Vagueness*. Cambridge Studies in Philosophy, Cambridge, UK,
- [3]. Keefe R., Smith P. (1997), *Vagueness: A Reader*, MIT Press, Massachusetts, MA.
- [4]. Read S.(1994), *Thinking about Logic: An Introduction to the Philosophy of Logic*, Oxford University Press, Oxford, New York.
- [5]. Russell B. (1940), *An Inquiry into Meaning and Truth*, George Allen & Unwin Ltd. and W.W. Norton, London and New York.
- [6]. Read S. (1994), *Thinking about Logic: An Introduction to the Philosophy of Logic*, Oxford University Press, Oxford, New York.
- [7]. Łukasiewicz J. (1970), *Die logischen Grundlagen der Wahrscheinlichkeitsrechnung*, 1913, in: L. Borkowski (Ed.), Jan Łukasiewicz, Polish Scientific Publishers, Amsterdam, London, Warsaw, 16–63.
- [8]. Zadeh L.A. (1965), Fuzzy sets, *Inform Control* 8, 338–353.
- [9]. Pawlak Z. (1982), Rough sets, *Int J Comput Inf Sci* 11, 341–356.
- [10]. Pawlak Z. (1991), Rough Sets: Theoretical Aspects of Reasoning about Data, System Theory, *Knowledge Engineering and Problem Solving* 9, Kluwer Academic Publishers, Dordrecht, The Netherlands.
- [11]. Skowron A. and Dutta S. (2018), Rough sets: past, present, and future. *Nat comput.* 17(4), 855–876. doi: 10.1007/s11047-018-9700-3
- [12]. Leibniz G.W. (1989), Discourse on metaphysics. R. Ariew, D. Garber, G.W. Leibniz (Eds.), *Philosophical Essays*, Hackett Publishing Company, Indianapolis, 35–68.
- [13]. Ali M. E., Medhat T. (2018), The Relation Between Rough Sets And Fuzzy Sets Via Topological Spaces. *International Journal of Engineering and Information Systems* 2 (10), 1-10.

- [14]. Dunn J C. (1973), A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. *Cybernetics and Systems*, 3(3), 32-57.
- [15]. Bezdek J C. (1981), *Pattern recognition with fuzzy objective function algorithms*. New York, Plenum Press, 10-16.

Apéndice C

Algoritmos

C.1. Algoritmo TRFG en Matlab

El algoritmo en Matlab, dada su potencia matricial, puede ser utilizado tanto para procesar una señal (1D), un THSP (2D) o una secuencia de PSs (3D)

```
function [act,final]=granTemp(b,in)

% b es la hiper-matriz temporal de m*n*frames, donde m*n
% puede ser 1x1 en el caso de una única señal
% act es el resultado de actividad por tipo de granulo m*n*3
% final es la suma de las 3 act

% in son los cuatro valores que determinan las regiones.
% Si entra solo el primer argumento calcula los parametros in
% sino pueden pasarse valores in particulares

% pasa b a uint8 por si está en otro formato, para facilitar
% cálculos

b=uint8(b);

% determina tamaño del arreglo

[ir,ic,im]=size(b);

% determina parámetros mediante histograma en caso que
% no figure el segundo argumento

if nargin == 1
    a=b(:, :, 1);
    [x,n]=imhist(a);
    ma= max(b(:));
    s=cumsum(x(1:ma));
    p=s(ma)/5;
    for i=1:4
        pp(:,i)=s-p*i;
    end
    ppa=abs(pp);
    [mi,in]=min(ppa(1:ma,:))
end

% valores iniciales
act=zeros(ir,ic,3);
ff=zeros(ir,ic,3);
fn=zeros(ir,ic,3);

for j=1:im

% Se identifican los intervalos dados por in
```

```

% la function roicolor selecciona región of interes (ROI)
% basada en el rango de color/intensidad, resultando una
% imagen binaria con 0's fuera de la región de interés y 1's
% dentro.

fn(:,:,1)=roicolor(b(:,:,j),0,in(2));
fn(:,:,2)=roicolor(b(:,:,j),in(1),in(4));
fn(:,:,3)=roicolor(b(:,:,j),in(3),255);

% detecta continuación o finalización del gránulo
fn=double(fn);
f=ff-fn;
iac=find(f==1);
act(iac)=act(iac)+1;
ff=fn;
end

% resultado final numerico e imagen
final=sum(act,3);

figure, imagesc(final)

```

C.2. Algoritmo SRFG en Matlab

```

function Gr = granosEspac(cuadro, b)
% cuadro es el tamaño del cuadro deslizante a evaluar (nxn)
% b es imagen a evaluar en forma espacial
% Salida: Gr cantidad de granulos en cada cuadro

[x,n]=imhist(b);
ma=max(b(:));
s=cumsum(x(1:ma));
p=s(ma)/5;

for i=1:4
pp(:,i)=s-p*i;
end
ppa=abs(pp);
[mi,in]=min(ppa(1:ma,:));

[ir,ic]=size(b);

fn(:,:,1)=roicolor(b,0,x2);
fn(:,:,2)=roicolor(b,x1,x4);
fn(:,:,3)=roicolor(b,x3,ma);

%-----
%Evalua cuantos granulos hay formados por valores contiguos de
%pertenencia

for i=1:ir-cuadro
for j=1:ic-cuadro

[b1,p1(i,j)]=bwlabel(fn(i:i+cuadro-1,j:j+cuadro-1,1));
[b2,p2(i,j)]=bwlabel(fn(i:i+cuadro-1,j:j+cuadro-1,2));

```

```

        [b3,p3(i,j)]=bwlabel(fn(i:i+cuadro-1,j:j+cuadro-1,3));
Gr(i,j)=(p1(i,j)*10+p2(i,j)*120+p3(i,j)*250)/(p1(i,j)+p2(i,j)+p3(i,j));
    end
end

figure
subplot(1,3,1),imagesc(p1),axis off, title('dark')
subplot(1,3,2),imagesc(p2),axis off, title('medium')
subplot(1,3,3),imagesc(p3),axis off, title('light')
figure, imagesc(Gr)
end

```