

Instituto Tecnológico de Costa Rica

Universidad Nacional

Universidad Estatal a Distancia

Doctorado en Ciencias Naturales para el Desarrollo



Modelo evolutivo de forma para el ajuste de organismos vermiformes  
en imágenes digitales

Tesis sometida a consideración del tribunal evaluador como requisito para optar el grado  
de Doctor en Ciencias Naturales para el Desarrollo, con énfasis en Tecnologías  
Electrónicas Aplicadas

Jorge Arroyo Hernández

Costa Rica, 12 de abril de 2021

Declaro que el presente documento de tesis ha sido realizado enteramente por mi persona, utilizando y aplicando literatura referente al tema e introduciendo conocimientos y resultados experimentales propios.

En los casos en que he utilizado bibliografía he procedido a indicar las fuentes mediante las respectivas citas bibliográficas. En consecuencia, asumo la responsabilidad total por el trabajo de tesis realizado y por el contenido del presente documento.

Jorge Arroyo Hernandez

Heredia, 12 de abril de 2021

Ced: 1-0986-0691

DOCINADE  
Tesis de Doctorado  
Tribunal Evaluador

Trabajo nal de graduacion presentado como requisito parcial para optar por el grado de Doctor en Ciencias Naturales para el Desarrollo, con enfasis en Tecnolog as Electronicas Aplicadas.

Miembros del Tribunal

---

Dr. Carlos Travieso Gonzalez  
Profesor Lector

---

Dr. Juan Luis Crespo Mari~no  
Profesor Lector

---

Dr.-Ing. Pablo Alvarado Moya  
Profesor Asesor

Los miembros de este Tribunal dan fe de que la presente tesis de doctorado ha sido aprobada y cumple con las normas establecidas por Doctorado en Ciencias Naturales para el Desarrollo, con enfasis en Tecnolog as Electronicas Aplicadas.

Costa Rica, 12 de abril de 2021

Instituto Tecnológico de Costa Rica  
Universidad Nacional de Costa Rica  
Universidad Estatal a Distancia

TEC | Tecnológico  
de Costa Rica

UNA  
UNIVERSIDAD  
NACIONAL  
COSTA RICA



**Modelo evolutivo de forma para el ajuste de organismos  
vermiformes en imágenes digitales**

Trabajo sometido a consideración del Tribunal Evaluador como requisito para optar  
por el grado de Doctorado en Ciencias Naturales para el Desarrollo con  
énfasis en Tecnologías Electrónicas Aplicadas

Jorge Arroyo Hernández  
Sustentable

Aprobado por los miembros del tribunal examinador:

Tomás Guzmán Hernández, Ph.D.  
Representante del Sistema de la Unidad de Posgrado

TOMAS DE JESUS  
GUZMAN  
HERNANDEZ  
(FIRMA)  
Firmado digitalmente por  
TOMAS DE JESUS GUZMAN  
HERNANDEZ (FIRMA)  
Fecha: 2021.12.07 07:51:08  
-06'00'

Giovanni Sáez Arce, Ph.D.  
Coordinador General del DOCINADE

Giovanni Sáenz-  
Arce  
2021.12.07  
17:07:59 Z

Pablo Alvarado Moya, Ph.D.-Ing.  
Director de Tesis

JOSE PABLO ALVARADO MOYA (FIRMA)  
PERSONA FISICA, CPF-01-0753-0713.  
Fecha declarada: 07/12/2021 02:32:48 PM  
Razón: Acta Jorge Arroyo Hdz  
Lugar: Cartago

Juan Luis Crespo Mariño, Ph.D.-Ing.  
Asesor de Tesis

JUAN LUIS  
CRESPO MARIÑO  
(FIRMA)  
Firmado digitalmente  
por JUAN LUIS CRESPO  
MARIÑO (FIRMA)  
Fecha: 2021.12.08  
08:34:29 -06'00'

Carlos Travieso González, Ph.D.-Ing.  
Asesor de Tesis

TRAVIESO  
GONZALEZ  
CARLOS MANUEL  
- 43761645M  
Firmado digitalmente por  
TRAVIESO GONZALEZ  
CARLOS MANUEL -  
43761645M  
Fecha: 2021.12.09  
08:59:27 Z

# Resumen

Los nematodos han ganado interés por su función de agentes de control biológico, así como por el efecto directo en los agro-ecosistemas tales como sembrados y sistemas de producción animal, y en consecuencia, el impacto económico a nivel país.

Debido a su importancia, en el presente trabajo se desarrolla un modelo evolutivo de forma basado en subdominios permitidos de siluetas vermes expresados en hitos de frontera que ajustan la silueta de nematodo presente en una imagen digital.

El modelo desarrollado trabaja sobre subdominios de forma permitidos en conjunción con el método de optimización enjambre de partículas multiobjetivo. A través de este, se evalúa iterativamente la bordicidad y el tamaño del nematodo hasta que se logre hallar el mejor ajuste de la forma verme en la imagen digital.

Asimismo, el modelo se apoya en dos procesos que asisten a la adaptación de la forma en el espacio de búsqueda: caminatas aleatorias entre subdomnios de formas vermes validas y deformaciones a través de los métodos serpenteo y forrajeo. Con el algoritmo k medias se construyen subdomnios de forma permitidas.

El modelo matemático de análisis de formas se nutre de dos bases de datos: una de imágenes digitales de nematodos y, la otra un conjunto de formas de nematodos expresados con hitos de frontera y almacenados vectorialmente. Esta última, es normalizada en cuanto a la cantidad de hitos así como la distancia entre estos. Además, cada instancia vectorial es rotada, escalada y alineada a una en particular previamente de nida.

Palabras clave: ajuste de forma, vermiformes, optimización, n-s mplexes, serpenteo, forrajeo, segmentación.

# Abstract

Nematodes have gained interest because of their role as biological control agents, as well as for their direct effect on agro-ecosystems such as crops and animal production systems, and consequently, their economic impact at the national level.

Due to its importance, in the present work, an evolutionary shape model is developed based on allowed subdomains of verm silhouettes expressed in boundary landmarks that adjust the nematode silhouette present in a digital image.

The developed model works on shape-allowed subdomains in conjunction with the multi-objective particle swarm optimization method. Through this, the bordericity and size of the nematode is iteratively evaluated until the best fit of the shape seen in the digital image is found.

The model also relies on two processes that assist in the adaptation of the shape in the search space. of the shape in the search space: random walks between subdomains of valid verme shapes and deformations through the snaking and foraging methods. With the k means algorithm, allowable shape subdomains are constructed.

The mathematical shape analysis model is fed by two databases: one of digital images of nematodes and, the other a set of nematode shapes expressed with boundary landmarks and vectorially stored. The latter is normalized in terms of the number of landmarks as well as the distance between them. Also, each vector instance is rotated, scaled, and aligned to a particular one previously defined.

Keywords: shape fit, vermiform, optimization, n-simplex, snaking, meandering, segmentation.

A mi padre, madre y esposa. Gracias eternas ...

# Agradecimientos

En primera instancia, darle gracias a Dios y a la Virgencita de los Angeles, quienes han sido acompañantes en este largo proceso de crecimiento personal y profesional.

Al Dr.-Ing. Pablo Alvarado-Moya, de quien estar eternamente agradecido por la extraordinaria asesoría brindada durante todo el proceso de investigación, y sobre todo, por su enorme disposición en cada momento que le necesitaba. ¡Gracias Pablo!

A los profesores Dr. Juan Luis Crespo-Morales y Dr. Carlos Manuel Travieso-Gonzalez por toda la colaboración y consejos brindados.

Finalmente a mis padres Jorge Luis y María Eugenia, y a mi esposa María Fernanda por ser los bastiones en mi vida.

Jorge Arroyo Hernandez

Costa Rica, 12 de abril de 2021



# Indice general



Indice de figuras	V
Indice de tablas	
1. Introduccion	1
1.1. Hipotesis y objetivos de investigacion	6
1.2. Contribuciones del trabajo propuesto	7
1.3. Metodologia	7
1.4. Delimitaciones al alcance de la investigacion	9
1.5. Estructura del documento	9
2. Marco teorico	10
2.1. Trabajos relacionados	10
2.2. Imagenes digitales	16
2.3. Metodos de reduccion de dimensionalidad	17
2.3.1. Analisis de componentes principales	17
2.3.2. Analisis de componentes principales con kernel	17
2.4. Modelos deformables	21
2.4.1. Modelos de forma basados en aprendizaje profundo	23
2.4.2. Modelos de forma basados en hitos de frontera	24
2.5. Alineamiento de formas vectoriales	26
2.6. Curva de interpolacion polinomica parametrica	27
2.7. Simplexes geometricos	28
2.8. Optimizacion multiobjetivo	29
2.8.1. Dominancia de Pareto	30
2.8.2. Optimizacion por enjambre de particulas	31
2.8.3. Optimizacion por enjambre de particulas multiobjetivo	33
2.9. Metricas de evaluacion	35
2.9.1. Validacion cruzada de k-iteraciones	35
2.9.2. Indice de Jaccard	36
3. Modelo evolutivo de forma	37
3.1. Base de datos de imagenes digitales de nematodos	39
3.2. Base de datos de formas vermes expresadas en hitos de frontera	40

3.2.1.	Normalizacion de la base de datos de hitos de frontera . . . . .	43
3.2.2.	Aumento de cardinalidad de la base de datos por simetría de forma . . . . .	47
3.3.	Metodo del serpenteo . . . . .	48
3.3.1.	Dominio y subdominio de formas vermes . . . . .	49
3.3.2.	Generacion de nuevas formas vermes en un $S_{Df}$ . . . . .	50
3.3.3.	Simulacion de movimientos aleatorios vermes . . . . .	50
3.4.	Metodo de deformacion de nematodos: forrajeo . . . . .	53
3.4.1.	Deformaciones del esqueleto . . . . .	53
3.4.2.	Deformaciones vermes oscilantes de cola y cabeza . . . . .	54
3.4.3.	Deformaciones vermes de crecimiento y decrecimiento . . . . .	56
3.5.	Truncamiento a un $S_{Df}$ . . . . .	58
3.6.	Funciones objetivo . . . . .	59
3.6.1.	Funcion verme de distancia . . . . .	59
3.6.2.	Funcion verme de contorno . . . . .	60
3.7.	Modelo evolutivo de forma . . . . .	64
3.7.1.	Ajuste de forma usando M OP SO . . . . .	65
3.8.	Medida de ajuste a la forma verme . . . . .	73
4.	Resultados experimentales y analisis . . . . .	74
4.1.	Representacion vectorial de la forma verme a traves de hitos . . . . .	75
4.2.	Emulacion y adopcion de nuevas formas vermes usando ACP K y MEF . . . . .	79
4.2.1.	Aproximacion de siluetas vermes . . . . .	79
4.2.2.	Variabilidad de formas . . . . .	88
4.3.	Ajuste de los parametros del MEF . . . . .	90
4.3.1.	Numero de particiones sobre el dominio de forma $D_f$ . . . . .	90
4.3.2.	Dimension de los subdominios de forma $S_{Df}$ . . . . .	91
4.3.3.	Vertices y particiones sobre el dominio de forma . . . . .	92
4.4.	Medicion del ajuste de la forma verme . . . . .	92
5.	Conclusiones . . . . .	97
	Bibliografia . . . . .	100
	A. Herramienta de segmentacion manual para hitos de frontera . . . . .	109
	Indice alfabetico . . . . .	110

# Indice de guras

1.1.	Imagen de dos nematodos capturados en un microscopio optico. ....	3
1.2.	Diagrama de bloques del <b>modelo evolutivo de forma</b> . ....	6
1.3.	Diagrama de la estrategia metodologica . ....	8
2.1.	Imagen digital de un nematodo con presencia de detritos y ruido. ....	14
2.2.	Problema de la preimagen. ....	19
2.3.	Clasi cacion de modelos en deformables discretos y continuos. ....	21
2.4.	Clasi cacion de modelos deformables en expl citos e impl citos . ....	23
2.5.	Una forma verme $f_i$ representada por hitos de frontera $h_j$ . ....	25
2.6.	Curva dada por el metodo de interpolacion polinomica parametrica. ....	28
2.7.	Un elemento $S_i$ de un 3-simplex $S_3$ . ....	29
2.8.	Dominancia de Pareto. ....	31
2.9.	Algoritmo del <b>P SO</b> . ....	32
2.10.	Frente de pareto dado por el <b>M OP SO</b> . ....	33
2.11.	Algoritmo del <b>M OP SO</b> . ....	34
2.12.	Esquema de la tecnica de validacion cruzada de $k$ iteraciones. ....	35
3.1.	Diagrama de bloques del <b>modelo evolutivo de forma</b> . ....	37
3.2.	Diagrama de los componentes del <b>modelo evolutivo de forma</b> . ....	38
3.3.	Imagen de un nematodo. ....	39
3.4.	Ancho del contorno de un nematodo en $p$ xeles. ....	40
3.5.	Anotacion manual de hitos secuenciados sobre el contorno de nematodo. .	40
3.6.	Vertebra del esqueleto una instancia de nematodo. ....	41
3.7.	Histograma de longitud de estancias de nematodos. ....	42
3.8.	Diagrama de ujo de la obtencion de la base de datos. ....	42
3.9.	Diagrama de bloques del proceso de normalizacion de la base de datos. . .	43
3.10.	Aplicacion de la etapa I de normalizacion de la base de datos. ....	44
3.11.	Curva interpolante parametrica $C_{spl}(t)$ de un nematodo . ....	45
3.12.	Aplicacion de la etapa II de normalizacion a la base de datos. ....	46
3.13.	Aplicacion de la fase III de la base de datos. ....	47
3.14.	Aplicacion de la normalizacion de simetr a de forma. ....	47
3.15.	Algoritmo de pre-procesamiento de la base de datos de entrenamiento. . .	48
3.16.	Diagrama de ujo del metodo del serpenteo. ....	49
3.17.	Obtencion de $S_{Df}$ a traves del algoritmo de $k$ -medias. ....	50

3.18.	Caminata aleatoria entre $SD_f$ vecinos. ....	51
3.19.	Sucesion de movimientos vermes entre $SD_f$ vecinos. ....	52
3.20.	Algoritmo de distorsion de un nematodo entre $SD_f$ vecinos. ....	52
3.21.	Diagrama de ujo del metodo forrajeo. ....	53
3.22.	Esqueleto de una forma verme $f_i$ . ....	54
3.23.	Aplicacion del la I parte del m <sup>b</sup>	
3.24.	Algoritmo de la I parte del metodo del forrajeo. ....	56
3.25.	Aplicacion del la II parte del metodo del forrajeo. ....	57
3.26.	Algoritmo de la II parte del metodo del forrajeo. ....	57
3.27.	Truncamiento $f_i$ a un $SD_f$ . ....	58
3.28.	Metodo de <b>b</b>	
3.29.	Esqueletizacion de un nematodo segmentado con 40 hitos de frontera. ...	60
3.30.	Extraccion de los vectores tangenciales y gradientes de borde. ....	62
3.31.	Diagrama de ujo del modelo evolutivo de forma. ....	64
3.32.	Mapeo de los pesos $W_j$ para cada hito de $f_i$ usando la funcion gaussiana. .	67
3.33.	Iteraciones de la primera parte del metodo <b>b</b> forrajeo. ....	69
3.34.	Iteraciones de la segunda parte del metodo forrajeo. ....	70
3.35.	Algoritmo del Modelo adaptativo de forma usando M OP SO. ....	71
3.36.	Iteraciones del algoritmo Modelo adaptativo de forma. usando M OP SO ..	72
3.37.	Medida de ajuste a la forma verme. ....	73
4.1.	Diagrama de ujo de evaluacion de las partes del algoritmo MEF. ....	75
4.2.	Siluetas de un nematodo segmentado por numero hitos de anotados. ...	76
4.3.	Distancias de los hitos promedio a la curva trazadora. ....	77
4.4.	Promedio de la evaluacion de la funcion de bordicidad por hito. ....	77
4.5.	Promedio de la evaluacion de la funcion de bordicidad al hito intermedio..	78
4.6.	Reconstruccion de una silueta de un nematodo usando ACP K. ....	80
4.7.	Diagrama del metodo de ACP K para $f_c$ y $f_a$ . ....	81
4.8.	usando la funcion proyectiva <b>b b</b>	
4.9.	ACP K usando la funcion radial gaussiana. ....	83
4.10.	Distancia promedio entre hitos usando la funcion kernel polinomial. ....	84
4.11.	Distancia promedio por hito entre $f_c$ y $f_a$ usando ACP K. ....	85
4.12.	<b>b b</b>	
4.13.	Indice cercan a entre formas calculadas con los metodos ACP K. ....	86
4.14.	Distancia promedio por hito entre $f_c$ y $f_a$ en un $SD_f$ de k nodos. ....	88
4.15.	Distancias promedio por hitos de $f$ y $f + 1$ del metodo serpenteo. ....	89
4.16.	Imagenes de dos formas de <b>b b</b>	
4.17.	Iteraciones del MEF por numero de centroides. ....	91
4.18.	Numero de nodos de cada subdominio de forma. ....	91
4.19.	Variacion del numero de coordenadas baricentricas en el MEF. ....	93
4.20.	Regiones verdadera, calculada y su interseccion en el MEF para $J(A_a; A_c)$ .	94
4.21.	Aplicacion del MEF con su respectivo ndice de Jaccard. ....	95
4.22.	Resultado del aplicacion del MEF por clases. ....	96

---

4.23. Imagenes del resultado nal del MEF de la clase  $a_2$ . . . . . 96 A.1.  
Secuenciacion de hitos en una imagen usando HESEV. . . . . 109

# Indice de tablas

1.1. Aplicaciones de aprendizaje de maquina en la agricultura. . . . .	2
1.2. Tareas de vision por computador en imagenes digitales de nematodos. . . .	4
2.1. Aportes base de otras investigaciones a MEF. . . . .	15
2.2. Ejemplos de kernels para $c = 0; n \in \mathbb{N}$ y $\gamma > 0$ . . . . .	18
3.1. Tabla de distribucion de instancias de representacion por hitos de nematodos segun longitud D del esqueleto. . . . .	41 4.1.
Tabla de particiones para ndice de Jaccard $J(A_a; A_c)$ . . . . .	93

# Capítulo 1

## Introducción

En la actualidad, el mundo avanza hacia una economía global y la agroeconomía es uno de los ejes centrales en países como Costa Rica que depende, en gran parte, de este sector tal y como indica Mora (2019). Los indicadores macroeconómicos mostrados en este estudio, indican que solo las ventas al exterior, de los bienes de cobertura agropecuaria en el año 2019, alcanzaron un monto de 3665.4 millones de dólares, cifra que representa 42.6 % del total exportado por el país.

La supervivencia de esta actividad depende de la mejora continua y aplicación de novedosas estrategias de producción, que permitan alcanzar e innovar los estándares de calidad y cantidad demandados por los mercados locales e internacionales (Pratt y Rivera, 2003).

Debido a lo mencionado anteriormente, las nuevas estrategias deben ser decididas sobre una base de información de los agroecosistemas provenientes de un sumario actualizado de resultados y evidencias científicas durante el quehacer de sus actividades.

Se debe centrarse en el análisis y caracterización de los factores que intervienen en los procesos de producción, y con ello, la mejora de las habilidades sobre las acciones de intervención necesarias a favor de la mitigación y prevención de posibles efectos negativos a corto, mediano y largo plazo que puedan influir en la calidad y cantidad de la productividad agrícola.

Por tanto, se hace menester la incorporación de nuevas estrategias y tomas de decisiones respaldadas a partir de evidencia científica, proveniente de la aplicación de modelos o pa-

trones matemáticos y estadísticos sobre los datos extraídos, que permitan la optimización de los recursos y tiempos en la cadena productiva, en conjunción a los requerimientos y exigencias en competitividad a nivel mundial (Elías, 2014; Suprem et al., 2013).

Actualmente, la inclusión de los métodos de aprendizaje de máquina transforman técnicas manuales de laboratorio como la detección, conteo y clasificación a procesos automatizados para agilizar labores propias de los especialistas, además, ofrece una opción de mejoras del rendimiento usando modelos predictivos, de clasificación y toma de decisiones (Geron, 2019).

Esto permite abrir nuevas posibilidades de innovacion en los agroprocesos, conservando un balance positivo de crecimiento de la cobertura agropecuaria segun Mora (2019). Ejemplos

de tareas, en las cuales hay una aplicacion de metodos de aprendizaje de maquina y reconocimiento en los agroecosistemas para la extraccion de informacion relevante se describen en la tabla 1.1.

**Tabla 1.1:** Ejemplos de aplicaciones de aprendizaje de maquina en la agricultura segun Kamilaris y Prenafeta-Boldu (2018).

Aplicacion	Descripcion
Clasificacion	Enfermedades de hojas de los cultivos Tipos de cobertura terrestre Tipos de cultivo Usos de suelo
Reconocimiento	Fenologia de los estados de las plantas Especies de cultivos Tipos de semillas
Deteccion	Enfermedades de hojas de los cultivos Enfermedades de los cultivos
Segmentacion	Raíces de los cultivos respecto al suelo
Estimaciones	Tamaño de los campos de cultivo Mapeo de la cobertura de vegetacion en invierno
Conteo	Unidades de cultivos
Prediccion	Enfermedades de hojas de los cultivos Humedad de los suelos Crecimiento de animales y cultivos Condiciones atmosfericas

Es por lo tanto necesario potenciar la investigacion y el desarrollo de nuevas herramientas

tecnologicas que apoyen la actividad agropecuaria en cada una de las actividades que intervienen en el proceso productivo, que complementen procesos de mejora en la calidad y produccion en los cultivos, as como la deteccion temprana de enfermedades y pestes, disminucion del impacto ambiental y sus respectivas intervenciones (Liakos et al., 2018).

En los procesos de innovacion basada en la actividad cientifica, en particular la referente a la agropecuaria, es trascendental la calidad y la consistencia de los datos con los que se va a producir conocimiento. En este sentido, una de las fuentes de extraccion de informacion es la microora y microfauna de los suelos (Bongers y Ferris, 1999). Estos los son bioindicadores capaces de proporcionar datos acerca de la perturbacion de los suelos y sedimentos acuaticos, su ciclo de descomposicion y regeneracion, as como de la calidad de los nutrientes, fertilidad, acidez y los efectos provocados en ellos por aplicacion de plaguicidas y otros contaminantes (Esquivel, 2011).



En este particular, se encuentran los nematodos. Estos son organismos vermiformes que pertenecen al lo Nematoda, no segmentados, pseudocelomados, triploblastos que pueden ser hialinos (de vida libre o toparasitos) o no hialinos (parasitos vertebrados) que viven en la mayor a de los habitats ecologicos (Association et al., 2004; Coto, 2007).

Estos microorganismos se alimentan de una amplia variedad de especies, que incluyen plantas, animales y bacterias. Asimismo, se hallan en un orden de millones de individuos de distintas especies por metro cuadrado de suelo o sedimento acuatico. Su rol es proveer la regulacion de los ecosistemas en los suelos, r os y mares, y ademas se caracterizan por ser recicladores de nutrientes (Wilson y Kakouli-Duarte, 2009).

Algunos de estos organismos vivientes debido a su tama-no, no pueden verse a simple vista, por lo que su estudio es posible unicamente por medio de microscopios opticos ( gura 1.1).



Figura 1.1: Imagen de dos nematodos capturados en un microscopio optico.

Ademas en el caso de los nematodos toparasitos, cuya dieta se compone parcial o to-talmente por las ra ces de las plantas, Wilson y Kakouli-Duarte (2009) se-nalan que son causantes de da-nos como:

- A las celulas por accion mecanica o enzimatica.
- Adaptativos por modi cacion de las celulas del hospedero.
- Neoplasicos que inducen a crecimiento de nuevo tejido, provocando un da-no pau-latino que se mani esta en el pobre crecimiento, marchitez generalizada, baja pro-duccion, clorosis, defoliacion, ca da prematura de ores y frutos.

Por estas razones, la sobrepoblacion descontrolada de estos microorganismos en diferen-tes agroecosistemas puede llegar a ser devastador. Los da-nos y perjuicios economicos

atribuibles a los nematelmintos toparasitos supero en el a-no 2018 miles de toneladas de productos equivalentes a unos \$118 billones de perdidas anuales en el mundo (Bernard et al., 2017; Duran-Mora, 2018).

Segun Bongers y Ferris (1999), las perdidas por causa de la accion de nematodos van desde los derivados de origen agr cola hasta los de procedencia animal, ademas del alto costo ambiental por la aplicacion de nematicidas; siendo esto ultimo un problema global que no se ha logrado evitar (Kenney y Eleftherianos, 2016).

El estudio de estos microorganismos proporciona criterios de evaluacion para la toma de decisiones en los procesos de sostenibilidad de los ecosistemas respecto a la conservacion y remediacion de los suelos y mares (Bongers y Ferris, 1999). Aspectos como su abundancia y simple manipulacion, facil muestreo, representatividad segun su habitat y por su respuesta bien de nida segun cambios ambientales, transforman a los nematodos en fuente primaria de informacion (Wilson y Kakouli-Duarte, 2009).

Asimismo, como lo apuntan Esquivel y Peraza (2009), su estudio inicia con su extraccion por tecnicas de muestreo en los campos de cultivo para ser analizados. Posteriormente, en laboratorios especializados, son in ltrados y transferidos a portaobjetos de vidrio (o laminillas de Cobbs) y con ayuda de un microscopio, platos de conteo y maquinas de contador multiple, son cuanti cados y analizados. Aunque las tecnicas de conteo y analisis son procesos efectivos; se tornan lentos por la cantidad de muestras y el tiempo requerido para procesar cada una (Van Bezooijen, 2006).

Los metodos de vision por computador y aprendizaje de maquina dan la posibilidad de apoyar y mejorar las capacidades de trabajo en los laboratorios de investigacion con el proposito de transformar la informacion almacenada en nubes de datos crudos a un conjunto de reglas y conocimientos aplicables a distintas areas del saber (Friedman et al., 2001). En este particular, en la tabla 1.2 se resumen tareas de sistemas expertos de vision por computadora aplicados a objetos estructurales en imagenes digitales de microscop a de nematodos.

Tabla 1.2: Tareas de vision por computador aplicables en imagenes digitales de nematodos segun Geron (2019), Gonzalez y Woods (2008), Jahne (2005).

Medio	Aplicacion
Imágenes digitales	Segmentacion
	Conteo
	Clasi cacion segun su
	lo
	Clasi cacion segun deformacion
	Seguimiento
	Adaptacion de forma

En este trabajo se propone un modelo de forma que se genera a partir de un conjunto de datos de entrenamiento y una forma inicial expresada en hitos de frontera, y logra evolucionar su silueta hasta adoptar y capturar la forma intr nseca del organismo usando informacion de la imagen digital.

Aunado a lo anterior, la captura de la forma intrínseca de los nematodos en imágenes digitales, le permitirá a los especialistas avanzar y complementar en procesos y tareas posteriores de análisis acerca del estado actual de los nematodos respecto a su morfología y la interacción con su entorno. Ejemplos de estas corresponden a:

- Análisis de su locomoción e interacción con el medio ambiente (Bogale et al., 2020; Juhasz y Zelei, 2013).
- Extracción de la forma y locomoción para determinar su estado nutricional (Gallagher et al., 2013).
- Estimación del área de la superficie y volumen a partir de datos morfométricos (Brown et al., 2016).

Además, con la aplicación de este método, un especialista podrá encargarse únicamente de tareas propias de su quehacer profesional, tales como:

- Clasificación de especies de nematodos.
- Diagnóstico de daños ocasionados por nematodos fitoparásitos.
- Evaluación de la efectividad de nematocidas y fertilizantes.

Aunado a lo anterior, este trabajo sirve de base en procesos más generales donde la captura de la forma de objetos estructurales no vivos en imágenes digitales es preponderante. Ejemplos de estos son:

- Análisis de las variaciones o perturbaciones a partir de las formas en los elementos estructurales, en una parte o la totalidad del cuerpo (Costa et al., 2011; Sadriani et al., 2007).
- La captura de las características morfológicas relevantes de los elementos estructurales para evaluación y diagnóstico (Cury, 2015).
- Clasificación de objetos estructurales según características de forma (Nalepa y Ka-wulok, 2014; Wilder et al., 2011).
- Generación de nuevas instancias sintéticas (Arroyo y Alvarado, 2020).

La propuesta en este trabajo se basa en un proceso de optimización asistido por dos métodos de deformación intermedios y una base de datos normalizada de formas no vivas expresadas como hitos de frontera. En la figura 1.2 se ilustra un diagrama de bloques general de la investigación.

Debido a la importancia mencionada en el estudio de los nematodos y al impacto que puedan tener los sistemas automatizados de rastreo y segmentación en imágenes digitales,




Figura 1.2: Diagrama de bloques del modelo evolutivo de forma.

este trabajo propone un modelo de forma adaptativo ajustable a la silueta de un nematodo que sirva de apoyo para las tareas expuestas en la tabla 1.2.

Asimismo, según Berry et al. (2019), este trabajo de investigación se enmarca en el Modelo de aprendizaje de máquina supervisado pues a partir de un conjunto de datos expresado de forma vectorial se logra modelar, a través de un aprendizaje inductivo, la silueta de la forma verme en una imagen digital.

## 1.1. Hipotesis y objetivos de investigación

En el presente trabajo se propone una investigación en la que se analiza, desarrolla y evalúa un nuevo método de ajuste de formas vermes en imágenes digitales. Por lo que se propone demostrar la siguiente hipótesis de investigación:

¿Es posible diseñar un sistema adaptación de formas vermes, a partir de representaciones de hitos de frontera mediante un proceso de optimización multiobjetivo asistido por deformaciones vermes simuladas,.

En relación con la hipótesis anterior, se propone como objetivo principal de este trabajo diseñar un modelo matemático novedoso no lineal basado en instancias de representación de hitos de frontera en dominios de forma verme permitidos, ajustable a cualquier silueta verme en imágenes digitales que sea robusto ante distintas deformaciones y ante el ruido presente en las imágenes digitales.

Asimismo, esta investigación se cimienta en tres objetivos específicos. El primero consiste en diseñar un nuevo modelo matemático de análisis de formas orientado a la descripción e identificación de una silueta vermiforme en imágenes digitales.

El segundo objetivo específico estriba en desarrollar un algoritmo proveniente del modelo propuesto que ajuste la silueta al organismo verme presente en la imagen digital donde el algoritmo debe ser capaz de recopilar la información en la imagen digital, de modo que, a partir de esta le sea posible extraer los parámetros de forma que describen su silueta.

El último, es crear una estrategia de evaluación para modelos y algoritmos de análisis de forma en imágenes digitales, que permita integrar en el proceso de evaluación con el modelo de forma propuesto.

## 1.2. Contribuciones del trabajo propuesto

Las contribuciones de esta investigacion son:

- Un metodo adaptativo a los movimientos corporales de organismos vermes en image-nes digitales por medio de un proceso de optimizacion multiobjetivo usando las fun-ciones de posicionamiento y distancia, asistida por dos metodos de deformaciones vermes.
- Un metodo capaz de simular la locomocion de organismos vermes a traves de un numero limitado de parametros usando caminatas aleatorias entre n-s mplexes en-gendrados por medio de caminatas aleatorias.
- Generacion de conjuntos de datos de entrenamiento de formas vermes, expresadas en hitos de frontera para alimentar sistemas de inteligencia arti cial.
- Un metodo de truncado de siluetas no vermes a formas validas en subdominios, permitidos a traves de n-s mplexes.

Por otro lado, este trabajo se ha cimentado en contribuciones propias que son derivadas de esta investigacion y que coadyuvaron a los resultados obtenidos. Primeramente se hizo un analisis comparativo de los metodos ACP y ACPK divulgado en (Arroyo, 2016), la cual fue complemento para el desarrollo del metodo para el calculo de la preimagen en

ACPK. Este fue publicado en (Arroyo y Alvarado, 2014). Asimismo, otro aporte es el desarrollo del metodo de simulacion de movimientos vermiformes mediante caminatas aleatorias entre n-s mplex vecinos expuesto en (Arroyo y Alvarado, 2020).

## 1.3. Metodolog a

La investigacion se enmarca bajo el paradigma exploratorio y el enfoque inductivo usual del dise~no en ingenier a. Consiste en el establecimiento de enunciados que se desarro-llan a partir de experiencias previas con el problema y soluciones particulares realizadas (Hernandez y Torres, 2018).

La estrategia metodologica del modelo de forma recorre las siguientes fases: En la primera, se seleccionan las bases de datos de imagenes digitales y a partir de esta, se prepara la de formas vermes vectoriales normalizadas. En esta se selecciona para las pruebas a nivel de imagen digital las que cumplen las restricciones descritas en la seccion 3.1. Adem as, se establece una metodolog a que normaliza a la misma escala, rotacion, traslacion y numero de hitos toda la base de datos de formas vermes vectoriales.

En la segunda y tercera fase, de forma paralela, se desarrolla e implementa el modelo de forma. El proceso conlleva etapas iterativas de observacion, analisis y dise~no del modelo, as como la implementacion.

Estas etapas conllevan dos subprocesos bien de nidos:

- A nivel de modelo de forma.
- A nivel de modelo de forma con informacion de imagen digital.

A nivel de modelo de forma, se desarrolla una estrategia que permita la adaptabilidad a distintas siluetas, garantizando la representatividad de cualquier forma verme.

A partir de la evidencia del subproceso anterior, al modelo se le incorpora otras estrategias que permitan la captura de la silueta a nivel de imagen digital.

Finalmente, en la cuarta etapa se realiza las pruebas de validacion y conclusiones que evidencien los resultados nales con los cuales se logra demostrar la hipotesis de investi-gacion. La metodolog a de evaluacion es a nivel de modelo de forma y, a nivel de modelo de forma con informacion de la imagen digital.

En el caso de la evaluacion del modelo de forma, se evalua su capacidad de adaptabilidad a diferentes formas de silueta, y un comparativo de metodos que sigan la linea establecida.

En el caso de de la evaluacion del modelo de forma a nivel de imagen digital, se evalua la cantidad de hitos necesarios de representacion, la adaptabilidad a las formas de nematodo respecto al modelo desarrollado.

Para la evaluacion de los resultados nales, se trabaja con el metodo de validacion cruzada de 10 iteraciones y el ndice de Jaccard.

En la gura 1.3 se muestra un diagrama de ujo con estrategia metodologica propuesta con las fases propias de investigacion, en el orden de aplicacion del modelo.

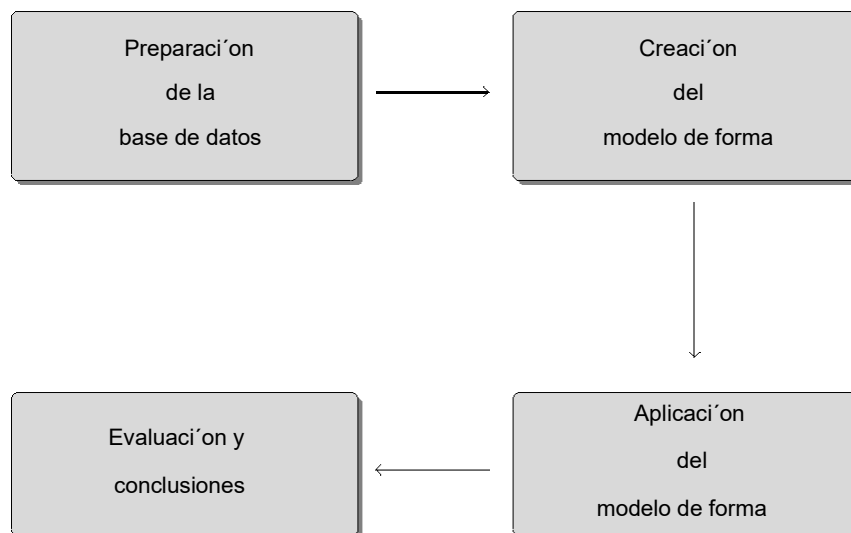


Figura 1.3: Diagrama de la estrategia metodologica de solucion al problema propuesto.

## 1.4. Delimitaciones al alcance de la investigacion

Este trabajo se delimita bajo las siguientes restricciones:

- El alcance de este trabajo es a nivel de propuesta metodologica. No se evaluan los tiempos de respuesta en las pruebas de convergencia y tampoco se realiza un analisis de complejidad algoritmica.
- Los algoritmos se implementan usando el lenguaje **C++**, junto con la biblioteca FLANN (Muja y Lowe, 2009) para el calculo eficiente de los centroides y de busqueda de vecinos cercanos, as como la biblioteca LTI-Lib-2 (Dorer y Alvarado, 2006) como base para el procesamiento digital de imagenes. Asimismo, todos los experimentos se realizaron en una computadora de escritorio con procesador Intel(R) Core(TM) i5-2500 CPU @ 3.30GHz con 8GB de RAM.

## 1.5. Estructura del documento

Este documento se constituye con los siguientes apartados: en el capitulo 2 se describen en detalle los contenidos y conceptos en los que esta investigacion se fundamenta. En el capitulo 3 se detalla el modelo desarrollado y los algoritmos implementados para la solucion al problema propuesto. En el capitulo 4 se exponen los resultados y un analisis de los mismos. Finalmente, en el capitulo 5 se presentan las conclusiones finales y un listado de recomendaciones sobre posibles lineas de trabajo a futuro.

# Capítulo 2

## Marco teórico

En este capítulo se presenta un listado de elementos teóricos resultantes de una búsqueda de estrategias en otras investigaciones ajenas y de hallazgos, los cuales se han adaptado y modificado para la generación de la nueva propuesta y que son necesarios para la demostración de la hipótesis de investigación.

El orden del desarrollo teórico se ha estructurado de acuerdo con las secciones correspondientes donde fueron utilizados. Se inicia haciendo una referencia a los trabajos ajenos a este. Luego, se describen conceptos relativos a imágenes digitales y esqueletización. Seguido a temas como los sistemas complejos geométricos, modelos deformables, interpolación paramétrica y optimización multiobjetivo. Para finalizar, se detallan métodos de evaluación estadística aplicados en esta investigación.

### 2.1. Trabajos relacionados

En investigaciones ajenas se han desarrollado modelos para la detección de estructuras vermiformes en imágenes digitales basadas en el caso particular de los nematodos. Estos se fundamentan en dos áreas: la primera abarca los modelos basados en información de la imagen digital a través de un preprocesado de estas, por medio de operaciones morfológicas y aplicación de filtros (Jahne, 2005); y la segunda corresponde al conjunto de técnicas de aprendizaje de máquina supervisado y no supervisado (Berry et al., 2019). Cabe destacar que ambas áreas no son excluyentes, y que por lo general son utilizadas conjuntamente.

En el área de procesamiento digital de imágenes de nematología existen diversas líneas de trabajo. Por ejemplo, Gómez (2009) trabajó en dos niveles de abstracción para segmentar la imagen digital separando las partes pertenecientes a nematodos y al fondo de la imagen. Aunque en la investigación se aplican dos métodos de segmentación para la detección de las formas vermes, se limita a procesar información a nivel de imagen digital y no se le incorpora la de forma al método. Asimismo, en las conclusiones de ese trabajo se resalta que imágenes digitales ruidosas pueden ser limitantes en la aplicación de los algoritmos que involucren operaciones morfológicas y de filtrado.



En la misma línea de trabajo, Geng et al. (2004) propusieron un sistema de seguimiento automático y extracción de características del nematodo *C. elegans*. Dicho sistema se desarrolló en varios subprocesos con imágenes digitales binarizadas y la aplicación de un algoritmo de esqueletización para la detección de las posiciones de los nematodos. En esta investigación se presentan imágenes digitales con escenas no ruidosas, aspecto por el cual deja la posibilidad que en otros tipos de ambientes con imágenes ruidosas, los resultados no sean los mismos.

Similarmente, una técnica de aprendizaje basada en contorsiones de la cabeza del *C. elegans* se expone en (K.-M. Huang et al., 2008). En dicho método se propuso medir los ángulos de contorsión de la cabeza y cola en sus movimientos exploratorios de locomoción. La información espacio-temporal es aprovechada por Restif y Metaxas (2008) para predecir la posición y ajustar la forma del organismo en procesos de segmentación y rastreo, utilizando para ello la evolución de los ángulos y vértices del esqueleto morfológico.

Por su parte Rizvandi, Pizurica, Philips y Ochoa (2008) presentan una propuesta para la detección y separación de nematodos *C. elegans* con presencia de traslapes. El algoritmo pasa por las fases de pre-procesamiento de escala de grises y operaciones morfológicas. Tomando como base las ideas de la investigación anterior, en (Rizvandi, Pizurica y Philips, 2008) se propone un algoritmo que permite la división y reconstrucción de los cuerpos de los nematodos en el punto de traslape para su identificación por medio de la técnica de esqueletización. Para esto se utiliza el promedio del ángulo que forman los vectores dados en el proceso de esqueletización del espécimen por medio del etiquetado de píxeles de unión, conexión, de cuerpo y extremo del nematodo.

En conjunto, las referencias anteriores se utilizan como base para el desarrollo de los métodos forrajeo y serpenteo en esta investigación (secciones 3.3 y 3.4 respectivamente) permitiendo la simulación de secuencias movimientos laterales de cola y cabeza del nematodo en movimientos continuos.

En la misma línea de investigación, K.-M. Huang et al. (2008) proponen un algoritmo de descripción cuantitativa de los movimientos de alimentación del nematodo *C. elegans* por medio de un sistema de posicionamiento automático de video que detecta los distintos momentos de alimentación y su frecuencia. En la etapa de pre-procesamiento, este algoritmo transforma la imagen digital a escala de grises y utiliza la diferencia de una secuencia nita de marcos de un video para detectar la posición del nematodo. Se umbraliza y utiliza el algoritmo de esqueletización morfológico, y finalmente con operaciones morfológicas

se extrae el contorno del cuerpo del gusano. En la etapa de detección, el algoritmo, a partir de un ciclo de movimientos, detecta las contorsiones de la cabeza y la cola con un sistema de vectores que miden el ángulo de la curvatura de los movimientos del cuerpo con respecto a la cabeza. Para reconocer los momentos de alimentación se tomaron en cuenta parámetros como la amplitud del ángulo, el intervalo del tiempo entre dos eventos de alimentación y la frecuencia de los eventos de alimentación. La amplitud de los ángulos de las contorsiones fueron considerados a la presente propuesta.

Por otro lado, en cuanto a técnicas de aprendizaje automático con información de for-

ma verme, Cootes et al. (1995) desarrollaron los modelos activos de forma usando la tecnica de distribucion de puntos y analisis de componentes principales para la reduccion de dimensionalidad del conglomerado de los datos. A partir de este, se sientan las bases de los metodos capaces de expresar expl citamente formas validas por medio de modelos estad sticos de distribucion de puntos y la reduccion de la dimension de vectores representativos de la formas.

En la misma l nea, Mar n (2009) utilizo modelos activos de forma para detectar la ubi-cacion de los nematodos en imagenes digitales apoyado del modelo de Cootes y Taylor (1993) que describe las siluetas de las formas a traves de estructuras vectoriales de hitos de frontera. Este trabajo aborda siluetas de nematodos adaptandolos a la forma de un objeto seleccionado previamente en la imagen digital.

En este conjunto de investigaciones, se asume la premisa que la distribucion de los datos es normal gaussiana. En caso de no ser verdadero, dicha situacion repercute en la no recuperacion o no construccion de nuevas formas vermes a partir de los datos existentes, y como conclusion, estos modelos son incapaces de restringir las formas representadas a vermes validas y, cabe la posibilidad de adaptacion a siluetas anatomicamente no plau-sibles. A pesar de este inconveniente, la tecnica de expresar vectorialmente formas de nematodos a traves de hitos de frontera como metodo de esbozar su silueta es valida, robusta y representativa de las formas.

Lindenbaum et al. (2018) exponen otro concepto basado en un modelo generativo que aprende la geometr a de una variedad topologica a partir de los datos. En esta se procura ignorar su densidad, utilizando mapas de difusion para establecer la estructura geometrica de la variedad. Sin embargo, un problema asociado a esta es que el etiquetado de los datos es un proceso costoso debido a la cantidad necesaria para que en conjunto se logre cubrir el total de deformaciones.

Por tanto, dicha estrategia no es viable en esta investigacion, pues su aplicabilidad depende de una elevada dimension del espacio muestral. Esto es: el modelo requiere alimentarse de un espacio muestral lo su cientemente representativo para que los mapas de difusion sean robustos y puedan estimar nuevas formas vermes. Esto mismo aplica en los modelos de aprendizaje automatico en los que es necesario abarcar un volumen de datos cuantioso para entrenar estos sistemas de aprendizaje. En ambientes de laboratorio de nematolog a, la obtencion de dichas muestras son procesos costosos en tiempo y recursos por lo que metodos automaticos de este tipo son descartados en esta investigacion (Esquivel, 2011; Van Bezooijen, 2006).

Como alternativa para dar mas peso a la geometr a de la variedad topologica que a la densidad de puntos disponibles de entrenamiento, se utiliza en la presente propuesta una tecnica similar a los k-vecinos mas cercanos expuesta por Nutanong et al. (2010) para un contexto de consultas en bases de datos espaciales. El metodo es similar al presentado en este trabajo, en el hecho de que usa tanto la informacion de la posicion actual en la caminata, como del vecindario para la decision del siguiente paso, pero la estrategia elegida para saltar a la siguiente posicion esta en el presente caso orientada a producir

formas dis miles al punto de partida, pero manteniendo su validez, en vez de procurar la descripcion geometrica de la variedad. Ademas, el uso del metodo de k-vecinos mas cercanos permite una disminucion de la dimensionalidad del conglomerado de los datos tomando como su representante el elemento mas cercano en forma del centroide en cada agrupamiento.

En otra direccion, pero siempre con tecnicas de aprendizaje, se encuentra la simulacion completa del organismo de un nematodo de la especie *C. elegans* en el proyecto OpenWorm (Currie et al., 2014). En ese proyecto se logr generar el movimiento locomotivo de un especimen por medio de la simulacion con 302 neuronas y 95 celulas musculares articiales. Los datos generados en dicha simulacion se acoplaron a renderizadores que generen las siluetas o las imagenes, segun se requiera. Si bien es cierto, esta simulacion de abajo hacia arriba (bottom-up) permite alcanzar altos niveles de realismo anatomico en los detalles, el consumo de recursos computacionales no lo hace viable en contextos donde la generacion de formas sea parte de otros procesos, como la segmentacion de nematodos o su rastreo en imagenes.

En este grupo de metodos tambien aparecen otras alternativas para representar el espacio de formas validas. Por ejemplo Gruner (2015) logra describir una variedad basandose en tecnicas de aprendizaje de diccionarios. En este metodo no se lleva a nivel de imagen digital, sin embargo, se extrae la idea de generacion de otras formas de gusano a partir de coordenadas baricentricas vermes en  $n$ -s mplexes.

Por otra parte, Jimenez (2019) utiliza un modelo de aprendizaje profundo como medio de generacion y segmentacion de nuevas formas vermes. Aunque el metodo es robusto, se necesita de una gran cantidad de datos de entrenamiento y prueba que permita recuperar toda la variedad topologica de formas de gusano. Este aspecto hace que el proceso de investigacion sea costoso en terminos de recursos para la extraccion de los datos as como tiempo de procesamiento de los mismos.

Asimismo, en el proyecto Automated Wormscan Puckering et al. (2017) muestran la utilidad e importancia en la adquisicion rapida de datos por sistemas computacionales usando tecnicas de vision por computador para la deteccion de nematodos *C. elegans* para ensayos de toxicidad, crecimiento y fecundidad. En esta investigacion, se evidencia el aumento del rendimiento y la reduccion de los costos a gran escala, y una mejora de los resultados obtenidos de los metodos manuales y a los automaticos por computador. Al igual que la investigacion anterior, y debido a la manera de adquisicion de datos necesarias usando escaneres de tres dimensiones, hace que esta investigacion no sea considerada.

En general, todas estas investigaciones utilizan un proceso de ltrado en las imagenes digitales para eliminar ruido y realzar las caracter sticas de los nematodos. Luego, de-terminan un sistema de parametros de clasi cacion o normas a partir de los indicadores observados, en algunos casos un proceso de esqueletizacion y nalmente, a traves de algun sistema automatico se entrenan para la deteccion de nematodos en imagenes digitales.

No obstante, se presentan varios problemas sustanciales. Primeramente, el crecimiento

exponencial del volumen de los datos para describir las instancias de las deformaciones de las estructuras vermiformes. La consecuencia directa es que el numero de parametros necesarios para describir la forma es casi el mismo numero que la representacion directa.

Segundo, se parte de la suposicion de que se puede eliminar la redundancia del modelo si los puntos se distribuyen de manera normal en el espacio de formas; de este modo el modelo ser a su ciente para describir la variabilidad de las formas. Sin embargo, si la suposicion no se cumple, entonces la reduccion de dimensiones conduce a la perdida de informacion y obliga a usar mas dimensiones en el espacio proyectado. Es decir, a mayor cantidad y variabilidad de muestras de entrenamiento se pierden las suposiciones de entrada, y por lo que es incapaz de describir las formas de los nematodos.

Tercero, se requiere expl citamente informacion de la forma de organismos para determinar indicadores de interes y su ciente material de entrenamiento, que es en general, costoso de preparar manualmente. La informacion en los laboratorios es limitada debido al tiempo de obtencion.

Cuarto, el uso de ltros de procesamiento de imagenes aplicados a grupos particulares de entrenamiento, tales como deteccion de bordes, reduccion de las variaciones de intensidad entre p xeles vecinos para suavizar la imagen, o el aumento de las variaciones de la inten-sidad con el n de realzar sus caracter sticas, y hasta operaciones morfologicas de imagen digital. O bien, las imagenes presentadas en estos trabajos son limpias sin detritos, y con esto simpli can procesos como la segmentacion o similares, situacion que en muestras reales de laboratorio no sucede ( gura 2.1).



Figura 2.1: Imagen digital de un nematodo con presencia de multiples detritos y ruido.

El problema es que las condiciones aplicadas obedecen a particularidades del dominio espacial del conjunto de imagenes digitales de entrenamiento, y en circunstancias propias de cada experimento, y no a procesos generales aplicables en cualquier escena o situacion. Esta situacion tiene como consecuencia la perdida de generalidad de los procesos descritos para ser aplicables en cualquier proceso similar.

En las referencias cient cas citadas y otras a nes, no se encontr un modelo capaz de describir parametricamente la formas de estos organismos en todos sus estados de crecimiento, sus caracter sticas de movilidad y variabilidad morfologica por medio de un numero limitado de parametros capaces de ajustarse a la informacion existente en la imagen, con presencia de detritos y, que permitan distinguir entre las estructuras vermes y los restantes elementos presentes en las imagenes digitales. Esto limita la aplicacion de los metodos propuestos a tareas de mayor nivel de abstraccion como lo es el conteo y el reconocimiento automatizado.

Sin embargo, de las referencias descritas se extraen aportes base para la investigacion presente. En la tabla 2.1 se resumen un listado de dichas contribuciones.

Tabla 2.1: Aportes base de otras investigaciones a MEF.

Aportes base	Referencias
Modelo de forma por hitos de frontera	(Cootes et al., 1995), (Cootes y Taylor, 1993), (Shlens, 2009), (Mar n, 2009)
Contorsiones vermes de cabeza y cola	(K.-M. Huang et al., 2008), (Geng et al., 2004), (K.-M. Huang et al., 2008)
Proceso de esqueletizacion	(Gomez, 2009), (Rizvandi, Pizurica y Philips, 2008)
k-vecinos mas cercanos para la reduccion de dimensionalidad	(Nutanong et al., 2010)
n-s mplexes como generador de formas vermes	(Gruner, 2015)

## 2.2. Imagenes digitales

Gonzalez y Woods (2008) definen una imagen digital como una función  $I_{x,y}$  de dominio discreto dada por:

$$I : X \times X \rightarrow \mathbb{N} \quad I(x,y) = \begin{pmatrix} r_{x,y} \\ v_{x,y} \\ a_{x,y} \end{pmatrix} \quad (2.1)$$

donde  $X_1 := \{0; 1; \dots; d_1 - 1\}$ , y  $X_2 := \{0; 1; \dots; d_2 - 1\}$  con  $d_1, d_2 \in \mathbb{N}$ . La función  $I_{x,y}$  devuelve la combinación de la composición espectral en los canales de información rojo  $r_{x,y}$ , verde  $v_{x,y}$  y azul  $a_{x,y}$  de un píxel en la posición  $(x,y) \in X_1 \times X_2$ .

Asimismo, Sonka et al. (2014) definen la transformación a escala de grises como una función que mapea los valores resultantes de la composición espectral al intervalo de  $[0; L]$ , donde cada canal realiza un mapeo de  $\mathbb{N}_n^3$  a  $\mathbb{N}_n$ , degradando en tonalidades de grises (denominados niveles de intensidad) de 0 hasta L, donde el 0 corresponde al negro y L al blanco.

Asimismo, el vector  $r_{I_{d;x,y}}$  es la aproximación discreta del gradiente direccional en señales continuas que proporciona la dirección de la mayor variación o cambio entre los niveles de intensidad. Viene dado por:

$$r_{I_{d;x,y}} = \begin{pmatrix} \frac{\partial}{\partial x} T(I_{x,y}) \\ \frac{\partial}{\partial y} T(I_{x,y}) \end{pmatrix} = \begin{pmatrix} S_x \sim T(I_{x,y}) \\ S_y \sim T(I_{x,y}) \end{pmatrix} \quad (2.2)$$

donde  $\sim$  es el operador de convolución dado por:

$$S_x \sim T(I_{x,y}) = \sum_{dx=-a}^a \sum_{dy=-b}^b S_x(dx;dy) T(I_{x+dx,y+dy}) \quad (2.3)$$

$$S_y \sim T(I_{x,y}) = \sum_{dx=-a}^a \sum_{dy=-b}^b S_y(dx;dy) T(I_{x+dx,y+dy}) \quad (2.4)$$

$dx = -a \dots a \quad dy = -b \dots b$

$T$  es la función que transforma la imagen a niveles de gris y,  $S_x$  y  $S_y$  corresponden a las matrices kernel de estimación del gradiente tales como diferencia simple, Sobel, Prewitt, Robinson, Roberts, Kirsch y Ando y derivaciones orientadas de la función Gaussiana (OGD por sus siglas en inglés) (Gonzalez y Woods, 2008; Jahne, 2005). Los rangos  $a = dx$  a  $y = b = dy = b$  dependen del tamaño de las matrices kernel.

## 2.3. Metodos de reduccion de dimensionalidad

Los metodos de reduccion de dimensionalidad (MRD) son procedimientos que transforman el conjunto de datos  $X$  en un nuevo conjunto de datos  $Y$  de menor dimensionalidad, conservando la informacion intrinseca tanto como sea posible (Arroyo, 2016). El objetivo de esta transformacion es evidenciar propiedades no observables en el conglomerado de la informacion de forma significativa sin redundancia (J. A. Lee y Verleysen, 2007; Van Der Maaten et al., 2009).

En las secciones siguientes se abordan los metodos de reduccion de dimensionalidad Analisis de componentes principales y Analisis de componentes principales con kernel respectivamente.

### 2.3.1. Analisis de componentes principales

El analisis de componentes principales (ACP) es una tecnica lineal que se utiliza para la eliminacion de la redundancia de los datos (Shlens, 2009). El metodo de ACP hace un cambio de base a una de menor dimensionalidad a traves de la ecuacion de transformacion:

$$Y = PX \quad (2.5)$$

donde  $P$  es una matriz ortogonal denominada matriz de representacion. El objetivo es calcular una matriz  $P$  que permita proyectar los datos a un espacio de menor dimension de manera que se garantice la no correlacion entre vectores de  $Y$ . Si la correlacion entre las distintas muestras es nula, se elimina la redundancia y el subespacio de datos puede ser descrito por  $P$ .

El algoritmo para el calculo de  $P$  inicia centrando y estandarizando los datos. Luego, se calcula la matriz de covarianza de  $X$  dada por  $C_{COV}$  que es simetrica y diagonalizable, y que cuantifica la covarianza entre las mediciones. Luego, se obtienen los vectores propios de  $C_{COV}$  ordenados de acuerdo al valor propio respectivo y que sirven de nuevas coordenadas del sistema donde se maximiza la varianza de los mismos.

Los vectores propios de  $C_{COV}$ , denominados componentes principales, describen la informacion del conjunto de datos de acuerdo con su coeficiente de inercia.

### 2.3.2. Analisis de componentes principales con kernel

El analisis de componentes principales con kernel (ACP K) es un metodo para la reduccion de dimensionalidad de datos en el que se aplica el metodo de analisis de componentes principales en un espacio  $F$  denominado caracteristico (Scholkopf, Smola et al., 1998).

Para esto, los datos de entrada  $E \in \mathbb{R}^n$ , son mapeados a  $F$  a traves de una funcion de mapeo por  $\phi : E \rightarrow F$ . El calculo de la  $q$  esima componente principal no lineal de un

$x^2 E$  es dado por:

$$V^q(x) = \sum_{i=1}^m \lambda_i^q h(x_i; x) \quad (2.6)$$

donde  $V^q$  es  $q$ -esimo vector propio de la matriz de covarianza de los datos proyectados, los  $\lambda_i$  son entradas del vector normalizado determinado en el eigensistema:

$$m = K \quad (2.7)$$

y  $K$  es una matriz de orden  $m$  con entradas  $K := (k_{ij})$  de nidas por:

$$k_{ij} := k(x_i; x_j) = h(x_i; x_j) \quad (2.8)$$

donde  $k(\cdot; \cdot)$  recibe el nombre de kernel y evita hacer la proyeccion expl cita de los datos. Ejemplos de kernels mas utilizados segun Honeine y Richard (2011) se muestran en la tabla 2.2.

Tabla 2.2: Ejemplos de kernels para  $c \geq 0$ ;  $n \in \mathbb{N}$  y  $\gamma > 0$ .

Funcion kernel	Criterio
Proyectivo polinomial	$(x_i; x_j) := (hx_i; x_j + c)^n$
Proyectivo exponencial	$(x_i; x_j) := \exp(hx_i; x_j) = (2^{-2})$
Proyectivo sigmoide	$(x_i; x_j) := \tanh(hx_i; x_j) = + c$
Radial Gaussiana	$(x_i; x_j) := \exp(-\gamma \ x_i - x_j\ ^2) = (2^{-2})$
Radial Laplaciana	$(x_i; x_j) := \exp(-\gamma \ x_i - x_j\ ) = (2^{-2})$
Radial Multicuadratico	$(x_i; x_j) := \frac{1}{\gamma^p} \sum_{i=1}^p \ x_i - x_j\ ^2 + c$



Calculo de la preimagen en ACP K

Las funciones descritas en la seccion 2.3.2 en general son no lineales, lo que conlleva a que la dimension del espacio F engendrado por las imagenes del conjunto de datos exceda la dimension del espacio de entrada E, y en ese particular, en el ACP K no siempre es posible el calculo directo de los vectores preimagenes de un vector en F (Scholkopf, Mika et al., 1998; Scholkopf, Smola et al., 1998).

Lo anterior se denomina el problema de la preimagen. Mas precisamente, el problema a resolver consiste en determinar la mejor aproximacion para  $x \in E$ , suponga  $x \in E$ , tal que para  $\psi \in F$  que cumpla:

$$\|x - x^*\|_E \leq \inf_{x' \in E} \|x' - \psi\|_F \tag{2.9}$$

para algun  $x \in E$  y que cumpla que  $\|x - x^*\|_E < \epsilon$  En la gura 2.2 se muestra un diagrama que ilustra el problema de la preimagen.




Figura 2.2: Problema de la preimagen. Diagrama de ACP K para  $x \in E$  y su respectiva aproximacion  $x \in E$ . En rojo se colorea el subespacio de proyeccion para  $\psi$ .

Lo anterior se deriva en un problema de optimizacion de distancia minima entre el vector en el espacio de entrada original  $x$  y el vector preimagen  $x$  del vector proyectado correspondiente a  $\psi$  (Arroyo y Alvarado, 2014). Una alternativa para la reconstruccion de las preimagenes  $x$  es dada por una variacion del metodo de Aproximacion por mapeos conformes(AMP)(Honeine y Richard, 2011).

En este metodo se parte de la representacion implcita de a traves de la combinacion lineal de los vectores de entrenamiento proyectados ( $x_j$ ) en F dada por:

$$X_n = \sum_{k=1}^n \alpha_k (X_k) \tag{2.10}$$

O bien, por componentes:

$$x_i = \sum_{k=1}^n k^{(i)} (x_k) \quad (2.11)$$

donde los coeficientes  $k^{(i)}$  se extraen de la solución de (2.7). En esta se asume la existencia de  $x_i$  como imagen de un vector sin ruido generada por  $m$  ( $m < n$ ) vectores propios:

$$x_i = \sum_{j=1}^m h_j(x); \quad j=1, \dots, m \quad (2.12)$$

Si se sustituye (2.11) en (2.12) y se aplica sesquilinealidad en el producto interno, se obtiene:

$$\begin{aligned} & X^m \\ = & \sum_{i=1}^m h(x); \quad j=1, \dots, m \\ = & \sum_{i=1}^m \left( \sum_{l=1}^n l^{(i)} (x_l) \right) + \sum_{k=1}^n k^{(i)} (x_k) \quad ! \\ = & \sum_{i=1}^m \sum_{l=1}^n l^{(i)} h(x); \quad (x_l) l^{(i)} + \sum_{k=1}^n k^{(i)} (x_k) \quad ! \\ = & \sum_{k=1}^n \sum_{i=1}^m \sum_{l=1}^n l^{(i)} h(x); \quad (x_l) l^{(i)} \quad (x_k) \quad !! \\ = & \sum_{k=1}^n k^{(i)} (x_k) \end{aligned} \quad (2.13)$$

de donde se infiere que:

$$k = \sum_{i=1}^m k^{(i)} \sum_{l=1}^n l^{(i)} h(x); \quad (x_l) l^{(i)} \quad ! \quad (2.14)$$

Finalmente, al aplicarle el método de mínimos cuadrados lineales a la ecuación solución sugerida en AMP se obtiene:

$$X^T x = (X^T X K^{-1}) \quad (2.15)$$

y usando (2.13) se logra dar con una solución cerrada al cálculo de la preimagen  $x$  a través de la ecuación:

$$x = (XX^T + \lambda I)^{-1} X^T X^{-1} y \quad (2.16)$$

donde  $\lambda$  es el parametro de regularizacion,  $X = [x_1 \ x_2 \ \dots \ x_n]$  es el conjunto de datos expresados matricialmente,  $y$  es el vector dado por:

$$y = [y_1 \ y_2 \ \dots \ y_n]^T \quad (2.17)$$

en el cual cada  $y_i$  se calcula a traves de la ecuacion (2.14).

En este documento, se utiliza el metodo ACP  $K$  en conjuncion con la variante del metodo AMP propuesta para describir las formas de nematodos a traves de hitos de frontera. El objetivo es reconstruir nuevas formas vermes usando un numero menor de dimensiones al del original sin perdida de informacion en un espacio de caracter sticas para luego ser proyectado al espacio original.

## 2.4. Modelos deformables

Los modelos deformables, introducidos por Terzopoulos et al. (1987), son un grupo de algoritmos que tienen como objetivo modelar la variabilidad de la estructura geometrica de un objeto en curvas de dos dimensiones o superficies de tres dimensiones dado como extension de trazadores generalizados de orden mixto empleados en topicos de vision por computador. Estos comparten la caracter stica de modelar la variabilidad de objetos deformables restringidos a un conjunto de caracter sticas propias determinadas a priori (Albrecht et al., 2009).

Hidalgo et al. (2012) presentan una clasi cacion de modelos deformables para representaciones discretas y continuas ( figura 2.3).

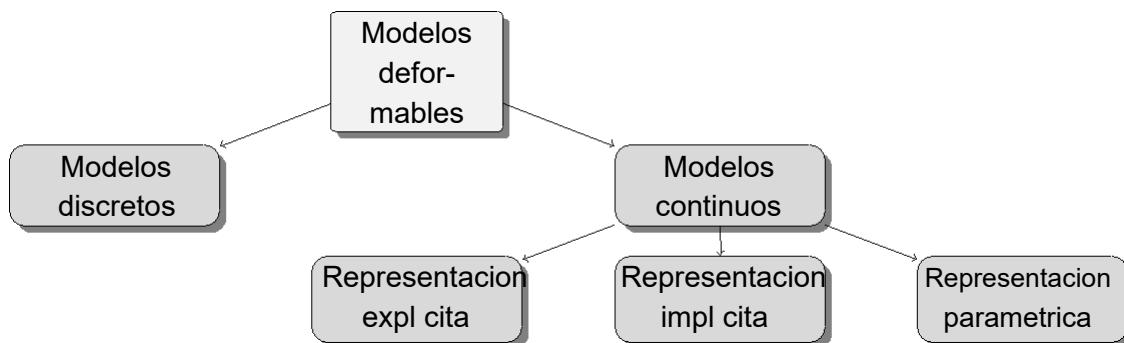


Figura 2.3: Clasi cacion modelos deformables basados en modelos discretos y continuos basado en lo que expresa Hidalgo et al. (2012)

En caso de los modelos discretos, su representacion es inferida a traves de un conjunto nito de hitos que moldean la gura del objeto. En este estadio se hallan algunos modelos como mallas poligonales (Qing et al., 2019), triangulacion de Delaunay (Chew, 1989), mallas por n-s mplexes (Delingette, 1999) y sistemas de particulas orientadas (Szeliski y Tonnesen, 1992).

En los modelos de representacion continua, se asume que su geometria y los parametros que la describen son conocidos. Estos son trifurcados en modelos impl citos, expl citos y parametricos. Los modelos de representacion continua expl citos, en el caso de  $\mathbb{R}^2$ , son descritos desde un vector de parametros de forma  $Q = q_1 \ q_2 \ \dots \ q_{n_q}$  y un espacio

parametrico de objetos de nidos, donde su representacion por objetos

$$S_q : \mathbb{R}^{n_q} \rightarrow \mathbb{R}^2$$

$$S_q(Q; u) = (x(Q;u); y(Q;u)) \quad (2.18)$$

Ejemplos de este son cilindros generalizados, objetos continuos y modelos de contornos activos. En el caso de los modelos impl citos, son representaciones a traves de funciones reales  $f$  que son descritos para el conjunto de valores que los anula:

$$f : \mathbb{R}^2 \rightarrow \mathbb{R}$$

$$S_f := \{p \in \mathbb{R}^2 : f(p) = 0\} \quad (2.19)$$

Algunos ejemplos de modelos de representacion impl cita son las superficies algebraicas (Ponce et al., 1989), isosuperficies (Carr et al., 2010), conjuntos de nivel (Sethian, 1999), y representacion de objetos muestreados (Chen et al., 2007).

Los modelos de representacion parametrica de un objeto estan dadas por una aplicacion  $S$  de nida en un dominio  $\mathbb{R}^2$  donde cada  $(u;v) \in \mathbb{R}^2$  es mapeada a  $\mathbb{R}^2$  como un punto en  $(x(u);y(v))$  dado por:

$$S : \mathbb{R}^2 \rightarrow \mathbb{R}^2$$

$$S(u;v) = (x(u); y(v)) \quad (2.20)$$

El mismo puede ser tambien aplicado en superficies en  $\mathbb{R}^3$  (Hidalgo et al., 2012). En esta clasificacion se encuentran modelos tales como supercuadratico (Terzopoulos y Metaxas, 1991), la descomposicion modal (Q.-X. Huang et al., 2009), la subdivision de superficies (Loop et al., 2009), las curvas de Bezier (Farin, 1983), los B-trazadores (Atkinson, 2008) y las Nurbs (Piegl y Tiller, 1995).

Por otra parte, Mesejo et al. (2016) proveen otra clasificación basada en una representación híbrida entre geométrica-implícita y paramétrica-explícita ( figura 2.4).




Figura 2.4: Clasificación modelos deformables basados en explícitos e implícitos basado en (Mesejo et al., 2016)

Según las clasificaciones anteriores, el presente trabajo enmarca como un modelo continuo-explícito con representación discreta-geométrica. Además, el conjunto de las posibles elongaciones permitidas por un modelo deformable pertenece a una variedad topológica contenida en un espacio euclídeo  $\mathbb{R}^k$ .

#### 2.4.1. Modelos de forma basados en aprendizaje profundo

Según Goodfellow et al. (2016) y Liu et al. (2018), los modelos basados en aprendizaje profundo son técnicas de aprendizaje fundamentadas en conjuntos de parámetros que le permiten ejecutar tareas automatizadas como segmentación, identificación, posicionamiento y clasificación de objetos en imágenes digitales.

Ejemplos de estos sistemas de aprendizaje de estructuras y patrones aplicables son redes neuronales artificiales (Livingstone, 2008), redes profundas prealimentadas (feedforward networks) (Raiko et al., 2012), redes de creencia profunda (H. Lee et al., 2009) y codificadores automáticos apilados (Masci et al., 2011).

Entre las tareas de estos modelos, se halla el aprendizaje de movimientos naturales de organismos vivos, con el objetivo de generar otros nuevos, reconstruir partes ocultas y de adaptación de formas. Por ejemplo, Holden et al. (2016) logran sintetizar los movimientos de una silueta de ser humano producidos a partir de una variedad topológica de movimientos humanos naturales. La variedad es aprendida a través de las unidades ocultas de una red neuronal profunda prealimentada entrenada con un autocodificador variacional (Pu et al., 2016).

Por otra parte, Litany et al. (2018) muestran a través de un autocodificador variacional en espacios latentes el aprendizaje de movimientos de distintas extremidades, tronco y cabeza de guras de seres humanos. A partir de estas, se ejemplifica con la reconstrucción de trozos ocultos o difusos de las siluetas en imágenes digitales obtenidas de escaneres tridimensionales.

Asimismo, Jimenez (2019) describe la estrategia para la segmentacion de nematodos en imagenes de microscopia usando una red de aprendizaje profundo para clasi cacion de p xeles del fondo con los hitos que describen la forma de nematodos.

El exito de estos metodos de aprendizaje automatico se basa en la prealimentacion con su cientos muestras datos por tipo de objeto, o su deformacion pertenecientes a una variedad topologica. En el caso de nematodos en imagenes digitales, se necesita una densa base de datos que le permita al modelo de aprendizaje automatico inferir todas las parti-cularidades de las distorsiones y transformaciones de forma de estos gusanos. Dada esta situacion, se opta por no seguir este tipo de estrategias. Sin embargo, se hace necesario lograr emular en las siluetas una variedad topologica verme pero con cantidad limitada de datos de formas de gusano.

#### 2.4.2. Modelos de forma basados en hitos de frontera

Los modelos de forma basados en hitos de frontera son prototipos deformables capaces de emular variaciones validas de forma de algun objeto de acuerdo a un conjunto de restricciones previamente de nidas (Cootes y Taylor, 1993).

Estos modelos son generados a traves de un conjunto de entrenamiento  $C$  que capta la variabilidad de todas las posibles deformaciones de los objetos representados a traves de descriptores matematicos. El  $i$ -esimo elemento de  $C$  de ne un pol gono de  $n$  vertices o hitos denotados por  $h_j$ . Cada forma se codi ca en un vector de las coordenadas de los hitos:

$$f_i = [x_{i0} \ y_{i0} \ x_{i1} \ y_{i1} \ \dots \ x_{i(n-1)} \ y_{i(n-1)}] \quad (2.21)$$

o alternativamente como vector de hitos:

$$H_i = [h_0 \ h_1 \ h_2 \ \dots \ h_{n-1}] \quad (2.22)$$


donde cada hito  $h_j$  es un vector de coordenadas cartesianas de nido por:

$$h_j = [x_{ij} \ y_{ij}]^T \quad (2.23)$$

Acomodados en secuencia, los hitos  $h_j$  se ubican a lo largo del contorno del objeto para representar la forma ( gura 2.5).

#### Modelos activos de forma

Segun Cootes y Taylor (1993), los modelos activos de forma (MAF ) son tecnicas de ajuste iterativa de las formas de objetos en imagenes digitales, donde los datos de objetos se representan por hitos de frontera. Esta tecnica se basa en modelos de distribucion



1

Figura 2.5: Una forma verme  $f_i$  representada por 20 hitos de frontera  $h_j$ .

de puntos que describen deformaciones de objetos a partir de variaciones inferidas del conjunto de instancias de entrenamiento y de su media geométrica.

Cada instancia de la base de datos de entrenamiento  $C$  de formas  $a$  nes es alineada a una instancia escogida a priori. Esto produce que el vector promedio de este conjunto sea nulo. Así, la ecuación de MAF es dada por:

$$x = \bar{x} + Qb \quad (2.24)$$

donde  $\bar{x}$  es un vector que representa la forma media,  $Q$  es la matriz de los primeros  $t$  vectores propios de la matriz de la covarianza del conjunto de entrenamiento  $C$  de todas

las formas vermes centradas y  $b = [b_1 \ b_2 \ \dots \ b_t]$  es el vector de parámetros de forma.

Para el ajuste a la imagen, se utiliza un procedimiento iterativo que alinea los hitos  $h_j$  de  $H_i$  hacia otra forma de nida anteriormente. El conjunto  $Q$ , que es una base vectorial de las formas, se combina linealmente con pesos  $b$ . Su cálculo es a través del método de análisis de componentes principales (Cootes et al., 1995).

La forma resultante se alinea y se proyecta con  $Q$  al espacio paramétrico  $b$ , en donde se puede evaluar si la forma ajustada es probable (se asume que la distribución de los mismos es normal) y en el caso de no ser se modifica truncando  $b$  para que quede dentro de un rango probable (delimitado en un hiperprisma rectangular en el espacio paramétrico entre un 3 para cada componente principal). Luego, se regenera la forma en el espacio de la imagen y se vuelve a ajustar. El ciclo continúa hasta que se satisfaga algún criterio de convergencia previamente de nido.



## 2.5. Alineamiento de formas vectoriales

El procedimiento de alineamiento de dos formas vectoriales es a través de la ecuación:

$$h_j = T(s; \theta)[h_j] + t \tag{2.25}$$

donde  $T(\theta; s)$  es la función de rotación y escalamiento determinados respectivamente por  $\theta$  y  $s$ , y  $t = [t_x; t_y]^T$ , donde  $t$  es vector de traslación.

El alineamiento de dos formas utilizado en modelos basados en hitos de frontera es una técnica de ajuste de posición que minimiza las distancias entre los  $h_j$  correspondientes de una forma vectorial  $H_1$  a otra  $H_2$ , esto es:

$$\sum_{j=0}^{n-1} w_j \left( x_{1j} - s \cos(\theta) x_{2j} - s \sin(\theta) y_{2j} - t_x \right)^2 + \left( y_{1j} - s \sin(\theta) x_{2j} + s \cos(\theta) y_{2j} - t_y \right)^2 \tag{2.26}$$

donde  $H_1$  y  $H_2$  se definen en (2.22).

Cootes y Taylor (1993) proveen un método de alineamiento de  $H_1$  y  $H_2$  respecto a los parámetros  $s$ ,  $\theta$ ,  $t_x$ ,  $t_y$ . Este consiste en, dados los correspondientes hitos  $h_j = [x_{1j} \ y_{1j}]^T$  de  $H_1$  y los hitos  $h_j = [x_{2j} \ y_{2j}]^T$  de  $H_2$ , minimizar su distancia usando los parámetros de ángulo de rotación  $\theta$ , el factor de escala  $s$  y el vector de traslación  $t = [t_x \ t_y]^T$ .

mediante la ecuación:

$$E = PWP^T \tag{2.27}$$

donde

$$P = \begin{bmatrix} x_{1j} & y_{1j} \\ x_{2j} & y_{2j} \end{bmatrix} \quad M(s; \theta) = \begin{bmatrix} s \cos(\theta) & s \sin(\theta) \\ -s \sin(\theta) & s \cos(\theta) \end{bmatrix} \quad t = \begin{bmatrix} t_x \\ t_y \end{bmatrix} \tag{2.28}$$

$$M(s; \theta) \begin{bmatrix} x_{kj} \\ y_{kj} \end{bmatrix} = s \sin(\theta) x_{kj} + s \cos(\theta) y_{kj} \tag{2.29}$$

$j = 0; \dots; n-1$  y  $W$  es una matriz diagonal de pesos  $w_i$  de cada punto.

Con las sustituciones  $a_x = s \cos(\theta)$  y  $a_y = s \sin(\theta)$  y por el método de mínimos cuadrados (diferenciando respecto a las variables  $a_x$ ,  $a_y$ ,  $t_x$  y  $t_y$ ) se obtiene el siguiente sistema de ecuaciones lineales:

$$\begin{bmatrix} \sum w_j x_{1j} x_{2j} & \sum w_j x_{1j} y_{2j} & \sum w_j x_{1j} & \sum w_j y_{2j} \\ \sum w_j x_{2j} x_{1j} & \sum w_j x_{2j} y_{1j} & \sum w_j x_{2j} & \sum w_j y_{1j} \\ \sum w_j x_{1j} & \sum w_j y_{1j} & \sum w_j & 0 \\ \sum w_j y_{2j} & \sum w_j x_{2j} & 0 & \sum w_j \end{bmatrix} \begin{bmatrix} a_x \\ a_y \\ t_x \\ t_y \end{bmatrix} = \begin{bmatrix} \sum w_j x_{1j} x_{2j} \\ \sum w_j x_{1j} y_{2j} \\ \sum w_j x_{1j} \\ \sum w_j y_{2j} \end{bmatrix} \tag{2.30}$$

y resuelto por el metodo de descomposicion por valores singulares, dando por resultado:

$$X_i = \sum_{k=0}^{n-1} w_k X_{ik} \quad Y_i = \sum_{k=0}^{n-1} w_k y_{ik} \quad (2.31)$$

para  $i = 1; 2$ , y

$$Z = \sum_{k=0}^{n-1} w_k (x_{1k}^2 + x_{2k}^2 + y_{1k}^2 + y_{2k}^2) \quad W = \sum_{k=0}^{n-1} w_k \quad (2.32)$$

$$C_1 = \sum_{k=0}^{n-1} w_k (x_{1k} \ x_{2k} \ + \ y_{1k} \ y_{2k}) \quad C_2 = \sum_{k=0}^{n-1} w_k (y_{1k} \ x_{2k} \ x_{1k} \ y_{2k})$$

El proceso anterior es conocido como analisis de Procrusto.

## 2.6. Curva de interpolacion polinomica parametrica

Foley y Nielson (1989) señalan que el metodo de interpolacion polinomica parametrica permite calcular curvas parametricas, denotadas  $C_{sp}$ , a partir de un conjunto finito de hitos conocidos. Este metodo se basa en el de interpolacion segmentaria polinomica B-trazadores (tambien denominada B-spline) (Atkinson, 2008).

La curva  $C_{sp}$  se determina a partir de un conjunto de  $n$  puntos de control  $c_i$ , polinomios trazadores de grado  $d$ , y una sucesion de numeros reales  $t = (t_i)_{i=1}^{n+d+1}$ . Entonces la curva que pasa por dichos hitos viene dada por:

$$C_{sp}(t) = \sum_{i=d+1}^n c_i B_{i;d}(t) \quad (2.33)$$

donde la base  $B_{i;d}$  se define recursivamente por:

$$B_{i;d}(t) = \frac{t - t_i}{t_{i+d} - t_i} B_{i;d-1}(t) + \frac{t_{i+1+d} - t}{t_{i+1+d} - t_{i+1}} B_{i+1;d-1}(t) \quad (2.34)$$

con

$$B_{i;0}(t) = \begin{cases} 1 & \text{si } t_i \leq t < t_{i+1} \\ 0 & \text{en otro caso} \end{cases} \quad (2.35)$$

con  $t \in \mathbb{R}$ .

En el caso de las curvas parametricas en  $\mathbb{R}^2$  y para el conjunto de n hitos  $h = \tau$ ,

la curva viene dada por:

$$C_{sp}(t) = \sum_{i=1}^n h_i B_{i;d}(t) = \sum_{i=1}^n x_{ij} B_{i;d}(t) \quad \sum_{i=1}^n y_{ij} B_{i;d}(t) \quad \# \quad (2.36)$$

En la gura 2.6 se observa, dada una colocacion arbitraria de 40 hitos o puntos de control coloreados en rojo, una curva  $C_{sp}$  resultante de aplicar el metodo de interpolacion polinomica parametrica.




Figura 2.6: Ejemplo de una curva  $C_{sp}$  calculada por el metodo de interpolacion polinomica parametrica con 40 hitos colocados arbitrariamente coloreados en rojo.

## 2.7. S mplexes geometricos

Para la generacion de nuevas formas vermes a partir de las conocidas en la base de datos de entrenamiento C, se utiliza el concepto de los n-s mplexes geometricos (Boyd y Vandenberghe, 2004). Estos son envolturas convexas determinadas por n + 1 nodos linealmente independientes dados por:

$$v = v_0 \quad v_1 \quad \dots \quad v_n \in \mathbb{R}^n \quad (2.37)$$

La region interna de los n-s mplexes  $S_n$  es un conjunto infinito de puntos de m dimensiones de nidos por:

$$S_n := \left\{ s_i \in \mathbb{R}^m = s_i = \sum_{i=0}^n \alpha_i v_i ; \alpha_i \geq 0 ; \sum_{i=0}^n \alpha_i = 1 \right\} \quad (2.38)$$

con  $\alpha := \alpha_0 \alpha_1 \dots \alpha_{n-1}$  baricentricas de s  $v_i$ . Los valores  $\alpha_i (0 \leq i \leq n-1)$  son denominados coordenadas baricentricas. Además, los nodos del n-s mplex se denominan vertices.

En la figura 2.7 se ilustra un 3-s mplex y un elemento  $s_i$  que pertenece a este.




Figura 2.7: Un elemento  $s_i \in S_3$ .

La generacion de nuevas formas vermes en este trabajo se realiza a traves de caminatas aleatorias entre  $n$ -s mplexes vecinos. Una caminata aleatoria es un proceso aleatorio que describe un camino a traves de una sucesion de pasos aleatorios  $fP_n g_{n \in \mathbb{N}}$  en algun espacio matematico (Jukna, 2011; Lawler y Limic, 2010). En este trabajo, el espacio corresponde a  $\mathbb{R}^{80}$  y cada elemento generado por la caminata aleatoria es una forma verme valida de 80 dimensiones.

En una caminata aleatoria, cada paso es representado como un salto de un  $n$ -s mplex a otro. Ademas, el conjunto de saltos entre  $n$ -s mplexes vecinos forman una ruta y las probabilidades que salte a cada uno de sus vecinos son las mismas. De este modo, la caminata aleatoria se da sobre una variedad topologica de  $m$  dimensiones, aproximada por la estructura de  $n$  s mplexes vecinos.

## 2.8. Optimizacion multiobjetivo

En un problema de decision cuya solucion optima involucra dos o mas funciones es comun aplicar los metodos de optimizacion multiobjetivo. Estos determinan un conjunto de valo-res que son optimizados de forma simultanea a partir del comportamiento de  $m$  funciones de costo o aptitud. Formalmente, se define optimizacion multiobjetivo como:

$$\min_{x \in S} \{F_0(x); F_1(x); F_2(x); \dots; F_m(x)\} \quad (2.39)$$

suje to a  $x \in S$ , que envuelve  $m$  funciones objetivo de costo<sup>1</sup> de nidas por:  $F_i : \mathbb{R}^n \rightarrow \mathbb{R}$  las cuales se desean minimizar (o maximizar para problemas de optimizacion de aptitudes) simultaneamente (Coello et al., 2004).

<sup>1</sup>Sin perdida de generalidad, los conceptos desarrollados son validos para problemas de optimizacion de aptitudes.

El vector decision corresponde a:

$$\tilde{x} = [x_0 \ x_1 \ \dots \ x_n]^T \quad (2.40)$$

y pertenece una region factible  $S \subseteq \mathbb{R}^n$ , donde la region factible esta delimitada por un conjunto de funciones de restriccion previamente determinadas.

El proceso de ajuste de una forma verme  $f_i^b$  a un nematodo en una imagen digital se realiza a traves de un proceso de optimizacion multiobjetivo de costos utilizado en dominancia de Pareto (Marler y Arora, 2004).

### 2.8.1. Dominancia de Pareto

Sea  $F := \{F_1; F_2; \dots; F_m\}$  un conjunto de funciones objetivo y  $S$  una region factible. Se define dominancia de Pareto  $\tilde{x}_1$  sobre  $\tilde{x}_2$ , denotado  $\tilde{x}_1 \succ \tilde{x}_2$ , si un vector  $\tilde{x}_1 \in S$  domina a otro vector  $\tilde{x}_2 \in S$  (Abbass et al., 2001). Esto ocurre si se cumplen a la vez las siguientes condiciones:

- El vector de decision  $\tilde{x}_1$  no es peor que  $\tilde{x}_2$  en todas las funciones objetivo. Es decir:

$$F_i(\tilde{x}_1) \leq F_i(\tilde{x}_2); \forall i; 1 \leq i \leq m$$

- El vector decision  $\tilde{x}_1$  es estrictamente mejor que  $\tilde{x}_2$  en al menos una funcion objetivo. Es decir:

$$F_i(\tilde{x}_1) < F_i(\tilde{x}_2)$$

en al menos un  $i; 1 \leq i \leq m$ .

Por otra parte, un vector  $\tilde{x}_1 \in S$  domina debilmente a  $\tilde{x}_2 \in S$ , denotado  $\tilde{x}_1 \succcurlyeq \tilde{x}_2$ , si y solo si:

- El vector decision  $\tilde{x}_1$  no es peor que  $\tilde{x}_2$  en todos los objetivos. Es decir:

$$F_i(\tilde{x}_1) \leq F_i(\tilde{x}_2); \forall i; 1 \leq i \leq m$$

El conjunto optimo de Pareto, denotado CP, es el conjunto de todos los vectores  $\tilde{x}_1 \in S$  tales que no existe otro vector  $\tilde{x}_2 \in S$  que lo domina. Se define por:

$$CP := \{ \tilde{x}_1 \in S \mid \nexists \tilde{x}_2 \in S \text{ tal que } \tilde{x}_1 \succ \tilde{x}_2 \} \quad (2.41)$$

Los elementos de este conjunto corresponden a los vectores decision asociados a CP.

El frente optimo de Pareto, denotado FP, es el conjunto de todos los vectores que son la imagen de los vectores decision. Se denota por:

$$FP := fF = [F_1(\tilde{x}) \ F_2(\tilde{x}) \ \dots \ F_k(\tilde{x})] \quad \forall \tilde{x} \in CP_g \quad (2.42)$$

Los elementos del conjunto FP se denominan vectores objetivo. En la figura 2.8 se muestra el concepto de dominancia de Pareto.




Figura 2.8: Dominancia de Pareto para dos funciones  $F_1$  y  $F_2$ . Los círculos con relleno de color negro corresponden a partículas no dominadas y los que no tienen relleno corresponden a partículas dominadas. La línea negra continua representa el frente de Pareto.

### 2.8.2. Optimización por enjambre de partículas

Optimización por enjambre de partículas (PSO por sus siglas en inglés) es un método heurístico propuesto por Eberhart y Kennedy (1995) que se basa en la simulación del movimiento de enjambres capaces de localizar un valor óptimo en un espacio de búsqueda  $S \subset \mathbb{R}^n$ .

Cada partícula del enjambre se inicializa aleatoriamente y se mueve en  $S$  para localizar la mejor posición de acuerdo con una función de ajuste  $F$ .

Asumiendo  $m$  partículas en  $S$ , la posición de la  $i$ -ésima partícula se representa por  $x_i$  y su vector velocidad actual es  $v_i$ . Los movimientos de las partículas son controlados por  $F$  hasta localizar la mejor posición local  $x_{pbest}$ , y entre todas las posiciones locales, se localiza la mejor posición global  $x_{gbest}$ .

Cada  $x_i$  es evolucionado hacia su nueva posicion a traves de un proceso iterativo dado por las ecuaciones:

$$v_i(t + 1) := w v_i(t) + c_1 r_{1,t} (x_{pbest} - x_i(t)) + c_2 r_{2,t} (x_{gbest} - x_i(t)) \quad (2.43)$$

y

$$x_i(t + 1) := x_i(t) + v_i(t + 1) \quad (2.44)$$

donde  $t$  es el parametro de iteracion,  $w$  es el factor de inercia sobre  $v_i(t)$ ,  $c_1$  y  $c_2$  factores de aceleracion de las particulas local y global respectivamente y,  $r_{1,t}$  y  $r_{2,t}$  son numeros aleatorios en el intervalo  $]0;1[$  que dependen de la iteracion  $t$ .

La actualizacion de  $x_{pbest}$  es  $x_i(t)$  si se cumple que  $F(x_{pbest}) > F(x_i(t))$ . La actualizacion  $x_{gbest}$  es  $x_{pbest}$  si se cumple que  $F(x_{pbest}) > F(x_{gbest})$ . El ciclo se sigue hasta algun criterio predefinido o un numero de iteraciones  $N_{it}$  predefinido. El algoritmo del PSO se muestra en la figura 2.9.

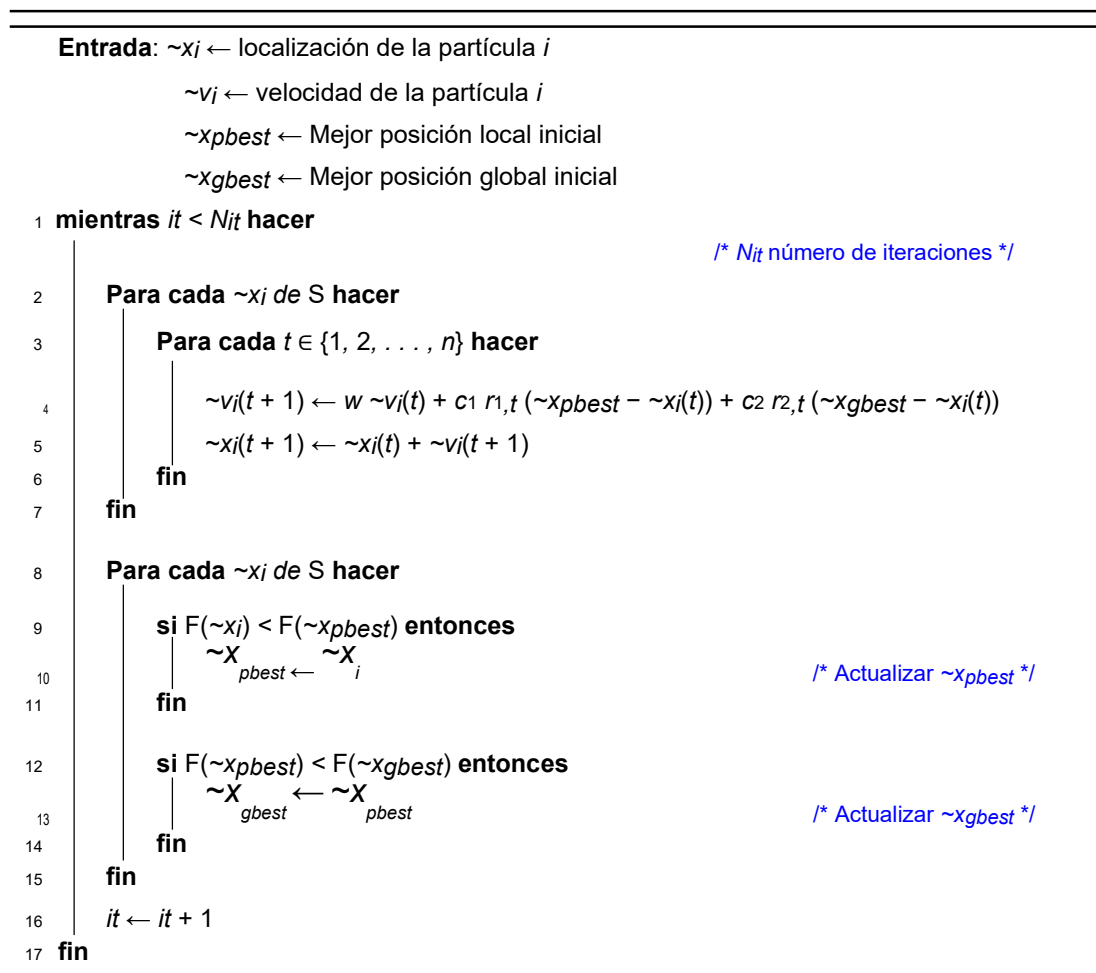


Figura 2.9: Algoritmo del PSO.

### 2.8.3. Optimizacion por enjambre de part culas multiobjetivo

Por otra parte, el metodo de Optimizacion por enjambre de part culas multiobjetivo es una extension del metodo P SO (seccion 2.8.2) con multiples funciones objetivo (Coello et al., 2004), de nido por:

$$F := fF_0 ; F_1 ; \dots ; F_n \quad (2.45)$$

para un enjambre de part culas P.

Este algoritmo denotado M OP SO (por sus siglas en ingles) inicia tomando los conjuntos de part culas P y de velocidades V en forma aleatoria y, almacena en R los elementos no dominados de P que conforman el conjunto del frente Pareto ( gura 2.8).

Luego, se itera para evolucionar las posiciones de las part culas almacenadas en R por otras nuevas usando (2.44) y para las velocidades calculadas se usa (2.43). En cada iteracion, las part culas de P son truncadas en un hipercubo y se reemplazan las part culas por otras no dominadas en R. El ciclo se sigue hasta algun criterio prede nido o un numero  $N_{it}$  de iteraciones prede nido. El algoritmo de este metodo se muestra en la gura 2.11. Asimismo, un frente de Pareto generado por el M OP SO se visualiza en la gura 2.10.




Figura 2.10: Aplicacion del algoritmo del M OP SO para dos funciones de costo. En color rojo se marcan las part culas del conjunto frente de Pareto, y en amarillo las part culas dominadas.



---

```

Entrada:  $P \leftarrow \{\sim x_0, \sim x_1, \dots, \sim x_m\}$  /* Población */
           $V \leftarrow \{\sim v_0, \sim v_1, \dots, \sim v_m\}$  /* velocidades */
           $R \leftarrow \{\}$  /* Repositorio */

1 Para cada  $\sim x_j \in P$  hacer
2   si  $(\sim x_j \sim u, \forall u \in R)$  entonces
3      $R \leftarrow \{\sim u \in R : \sim u \sim x_j\}$  /* Elimina los  $u \sim \in R$  dominados por  $\sim x_j$  */
4      $R \leftarrow R \cup \{\sim x_j\}$  /* Agrega  $\sim x_{gbest}$  al repositorio */
5   fin
6   si  $\sim x_i \sim x_{pbest} \vee (\sim x_j \sim x_{pbest}) \wedge (\sim x_{pbest} \sim x_i)$  entonces
7      $pbest \leftarrow \sim x_i$  /* Actualización del  $pbest$  */
8   fin
9 fin

10 mientras  $it < N_{it}$  hacer /*  $N$  es el número de iteraciones */
11   Para cada  $\sim x_j \in P$  hacer
12     Para cada  $t \in \{1, 2, \dots, n\}$  hacer
13        $\sim v_j(t+1) \leftarrow w \sim v_j(t) + c_1 r_{1,t} (\sim x_{pbest} - \sim x_j(t)) + c_2 r_{2,t} (\sim x_{gbest} - \sim x_j(t))$ 
14        $\sim x_j(t+1) \leftarrow \sim x_j(t) + \sim v_j(t+1)$ 
15     fin
16      $P, V \leftarrow \text{check}(P, V)$  /* Chequear fronteras */
17     si  $(\sim x_j \sim u, \forall u \in R)$  entonces
18        $R \leftarrow \{\sim u \in R : \sim u \sim x_j\}$  /* Elimina los  $u \sim \in R$  dominados por  $\sim x_j$  */
19        $R \leftarrow R \cup \{\sim x_j\}$  /* Agrega  $\sim x_{gbest}$  al repositorio */
20     fin
21      $pbest \leftarrow i$ 
22     si  $\sim x_i \sim x_{pbest} \vee (\sim x_j \sim x_{pbest}) \wedge (\sim x_{pbest} \sim x_i)$  entonces
23        $\sim x \leftarrow \sim x$  /* Actualización del  $\sim x$  */
24     fin
25      $it \rightarrow it + 1$ 
26 fin

```

---

Figura 2.11: Algoritmo del M OP SO.

## 2.9. Metricas de evaluacion

Las metricas de evaluacion son metodos que tienen como objetivo validar de forma estadística el desempeño y habilidad de los algoritmos. En las secciones 2.9.1 y 2.9.2 se aborda la conceptualización de dos métricas asociadas a las áreas de procesamiento digital de imágenes y reconocimiento de patrones: validación cruzada de  $k$ -iteraciones y el índice de Jaccard.

### 2.9.1. Validación cruzada de $k$ -iteraciones

La técnica de validación cruzada de  $k$ -iteraciones es un método estadístico de evaluación de algoritmos que comienza con una partición de la base de datos  $C$  en  $k$  subconjuntos independientes  $C_i$  (Refaeilzadeh et al., 2009). Con ellos se determinan de forma cuantitativa resultados a través de alguna medida estadística como la raíz del error medio cuadrático ( $E_{rr}$ ) (Willmott y Matsuura, 2005). En la figura 2.12 se muestra un esquema de esta técnica de validación.

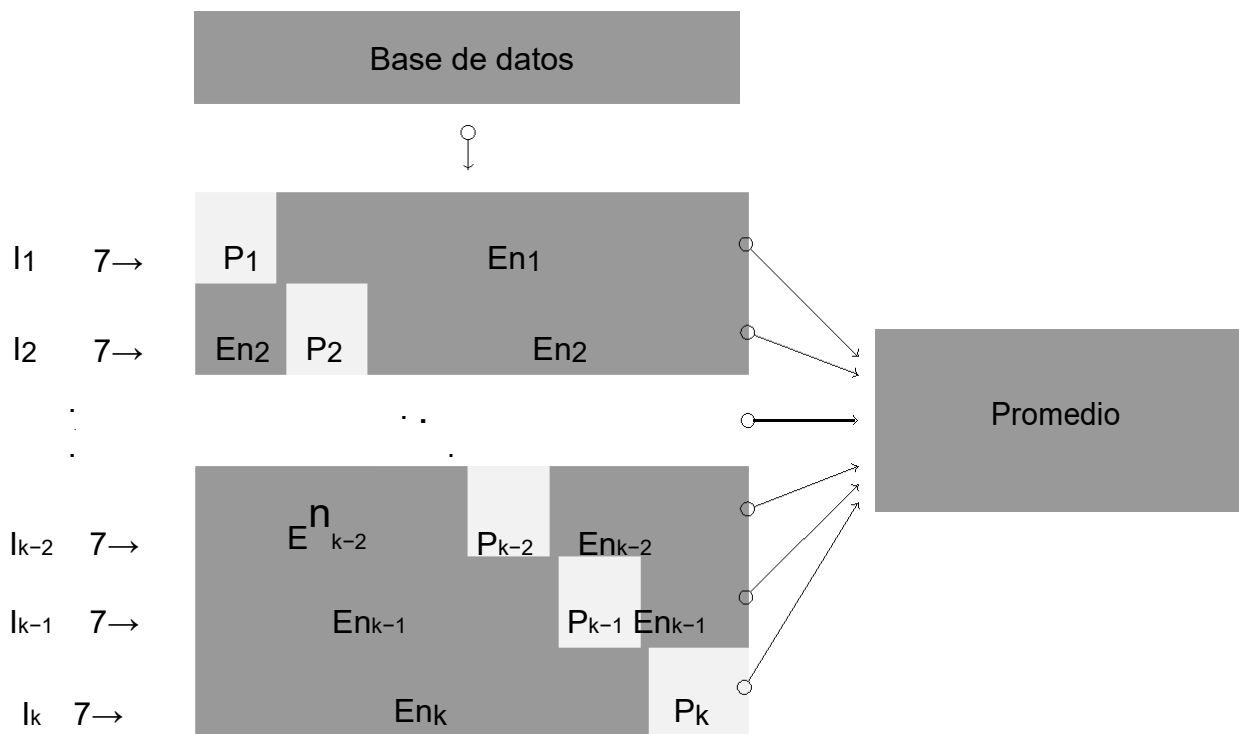


Figura 2.12: Esquema de la técnica de validación cruzada de  $k$  iteraciones.  $E_i$  y  $P_i$  corresponden los  $i$ -ésimos conjuntos de entrenamiento y prueba respectivamente, para la  $i$ -ésima iteración  $l_i$ .

Las  $k$  particiones se utilizan para determinar los  $i$ -ésimos conjuntos de entrenamiento ( $E_{ni}$ ) y pruebas ( $P_i$ ). Para la ejecución de la  $i$ -ésima iteración experimental de este método, se escogen los conjuntos entrenamiento y prueba de la siguiente forma:

$$E_{ni} := fC_1; C_2; \dots; C_k \text{ r } fC_i \text{ g y } P_i := fC_i \text{ g } (1 \leq i \leq k) \quad (2.46)$$

es decir, se utilizan  $k-1$  conjuntos para entrenar  $E_{ni}$  y un conjunto para pruebas  $P_i$ . Las particiones a su vez deben cumplir:

- 
- La unión de todas las particiones resultan la base de datos, es decir,  $C = \bigcup_{i=1}^k C_i$
- Las particiones  $C_i$  poseen la misma cardinalidad.

El proceso se repite  $k$  veces. Finalmente, se obtiene un promedio general de los resultados de todas las iteraciones. La técnica de validación cruzada de  $k$ -iteraciones se utiliza en los casos que se cuenta con un número limitado de datos experimentales.

### 2.9.2. Índice de Jaccard

El índice de Jaccard, denotado  $J(A;B)$ , es una métrica utilizada para determinar la similitud entre muestras de conjuntos finitos  $A$  y  $B$  (Real y Vargas, 1996). Al conjunto  $A$  se le denomina región verdadera y, al conjunto  $B$  se le denomina región calculada. El índice de Jaccard se define por:

$$J(A;B) := \frac{\text{card}(A \cap B)}{\text{card}(A \cup B)} = \frac{\text{card}(A \cap B)}{\text{card}(A) + \text{card}(B) - \text{card}(A \cap B)} \quad (2.47)$$

El índice de Jaccard provee un valor en el intervalo  $[0;1]$ , donde  $J(A;B) = 0:0$  indica que no hay similitud entre los conjuntos dados y  $J(A;B) = 1:0$  expresa que ambos conjuntos son totalmente coincidentes. A esta métrica se le denomina Intersección sobre la unión y se denota IoU (por sus siglas en inglés).

En el área de procesamiento digital de imágenes, el índice de Jaccard se utiliza para medir la efectividad de algoritmos relativos a tareas de posicionamiento, segmentación, detección, seguimiento de objetos, así como evaluación estadística de los algoritmos aplicados a estos (Berman et al., 2018; Rahman y Wang, 2016).

# Capítulo 3

## Modelo evolutivo de forma

El modelo evolutivo de forma (MEF) es una técnica de segmentación adaptativa de objetos basada en un proceso de evolución de forma mediante hitos de frontera, enmarcado en un sistema de representación continua explícita de representación discreta-geométrica según los sistemas de clasificación explicados en la sección 2.4.

En la figura 3.1 se muestra el diagrama de bloques en el que se exhibe la organización del modelo evolutivo de forma. En verde se muestran los procesos que conforman el sistema. En color celeste los subprocesos que apoyan al método de optimización.

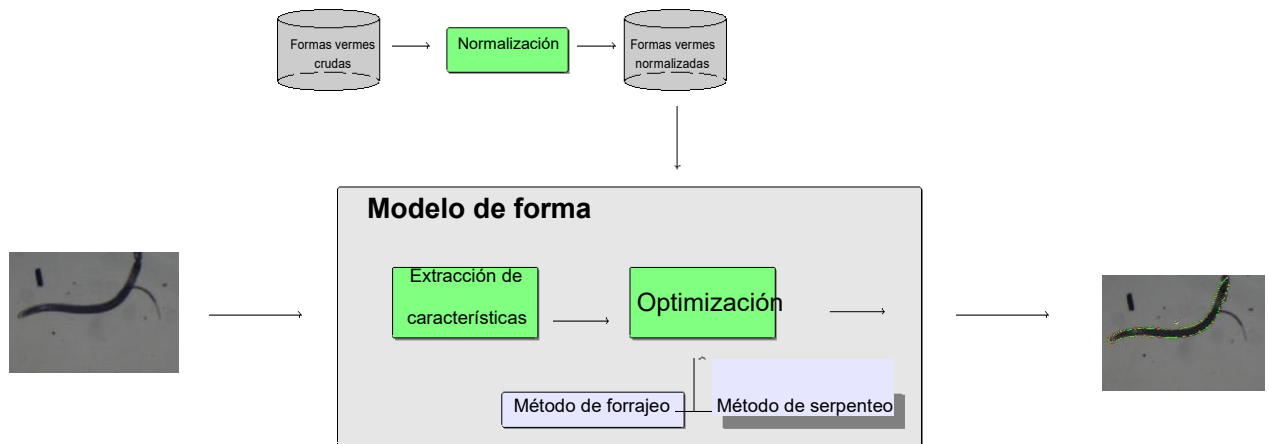


Figura 3.1: Diagrama de bloques del modelo evolutivo de forma.

En concordancia con la estrategia metodológica de la sección 1.3, en este capítulo se describe la propuesta de solución del problema en cuestión fragmentado en tres fases principales. En la primera fase se explica la preparación de las bases de datos de entrenamiento y pruebas de imágenes digitales y de las siluetas vermes de nidas por hitos de frontera (sección 3.2).

En la segunda fase se detallan los métodos de generación de nuevas siluetas a través de caminatas aleatorias entre n-s mplexes. Asimismo, incluye el método de truncamiento de formas vermes a subdominios válidos (sección 3.3.1).

La tercera fase especifica el método del serpiente y forrajeo, así como las funciones de costo usadas en el MOPSO (secciones 3.4 y 3.6). En esta se incluye el proceso completo

de adaptación de las formas verdes a los nematodos en imágenes digitales (sección 3.7).

La última fase se abordará en el capítulo 4.

En la figura 3.2 se muestra un diagrama de flujo con las fases propias de esta investigación en el orden de aplicación del modelo.

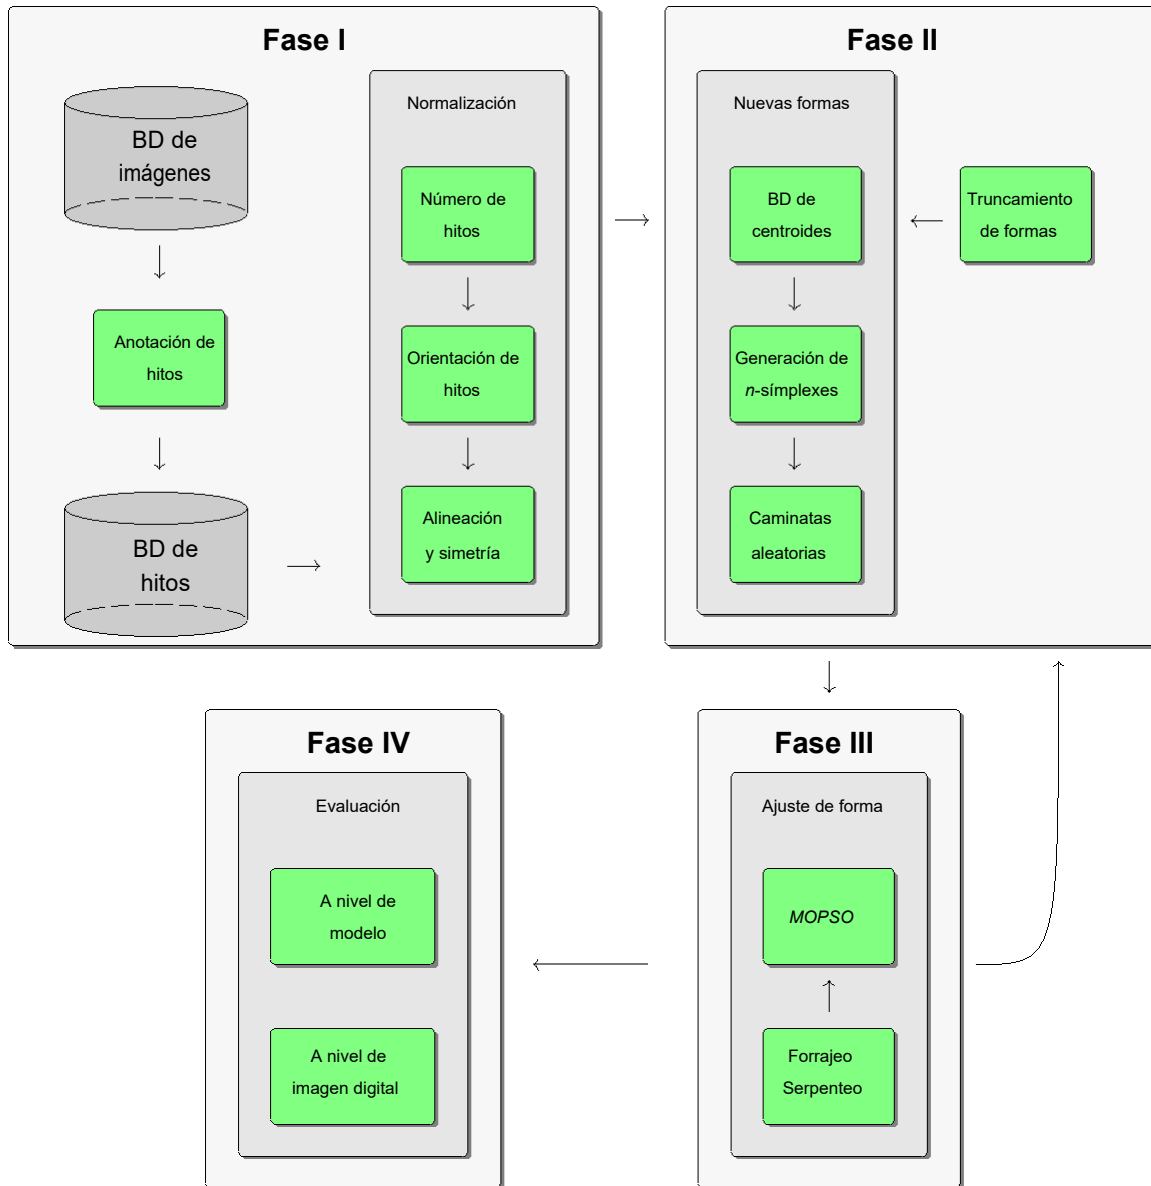


Figura 3.2: Diagrama de los componentes del modelo evolutivo de forma. En este se muestra la secuencia de la solución planteada al ajuste de forma. En verde se representan los subprocesos de cada fase del modelo.

### 3.1. Base de datos de imagenes digitales de nematodos

Para las pruebas de entrenamiento y validacion, se utiliza un conjunto de 667 imagenes digitales de diferentes de muestras de nematodos. El tamaño de cada imagen digital obtenida es 421 301 p xeles. Las imagenes se capturaron con una camara Basler A630f adaptada al ocular de un microscopio Nikon Eclipse E200.

A pesar de que las imagenes digitales contienen organismos vermes con una alta varia-bilidad en sus deformaciones, factores de escala y contrastes para el entrenamiento y validacion del metodo modelo de forma propuesto, estas presentan retos reales en cuanto a mostrar escenas ruidosas producto de la presencia de detritos, residuos y sedimentos provenientes de los procesos respectivos de tamizado, y que en consecuencia, limitan el contraste del contorno y cuerpo de los organismos vermes respecto al fondo de la imagen (ver gura 3.3).



Figura 3.3: Imagen de un nematodo con presencia de multiples de detritos.

Asimismo, las imagenes digitales utilizadas en los experimentos se seleccionaron con base a la siguiente lista de restricciones:

- Los niveles de contraste y ruido deben permitir la deteccion de los bordes de cada organismo, aun cuando estos se confundan con otros elementos.
- El cuerpo de cada nematodo debe estar enfocado de modo que permita distinguir el contorno y su cuerpo. El fondo de las imagenes tendra niveles de intensidad altos cercanos a tonalidades de gris claro, mientras que el cuerpo de los nematodos seran con niveles de intensidad bajos similares a grises oscuros.
- La informacion que proporcione la imagen digital en cuanto a colorimetr a es irrelevante para el analisis de forma, debido a que estas contienen poca informacion cromatica, por lo que unicamente se trabajar con imagenes en escala de grises.
- En cuanto al borde de los nematodos en las imagenes digitales, se tomar como pre-misa que el ancho del contorno del nematodo medira entre 4 y 6 p xeles ( gura 3.4).

Se tomar este como el rango valido de posicionamiento entre hitos con las posiciones calculadas por modelo de forma y anotados manualmente con la herramienta de colocacion de hitos descrita en el apendice A.




Figura 3.4: En la imagen izquierda se presentan dos nematodos y una parte del contorno enmarcado en un recuadro rojo. En la imagen de la derecha, se amplia el sector del recuadro rojo, y se muestra un segmento de un punto A al punto B, que mide aproximadamente 4.3 p xeles correspondiente al ancho del borde del nematodo.

### 3.2. Base de datos de formas vermes expresadas en hitos de frontera

La base de datos de entrenamiento y validacion de formas vermes expresadas en hitos de frontera, denotada C, es un conjunto de m instancias de vectores que representan formas vermes  $f_i$ , con  $i \in \{1, 2, \dots, m\}$ . Los hitos de las estancias vermes se denotan  $h_j$ , con  $j \in \{1, 2, \dots, n\}$ .

La obtencion de forma vectorial  $f_i$  se realiza a partir de la anotacion manual de hitos  $h_j$  sobre el contorno del nematodo, y que en conjunto, moldean su silueta verme de forma secuencial como se muestra en la gura 3.5. El conjunto de hitos se almacena en un vector de datos dado por (2.21).




Figura 3.5: Ejemplo de anotacion manual de 29 hitos en secuenciacion sobre el contorno de nematodo en una imagen digital.

En total se demarcaron, por medio de hitos de frontera, 2744 instancias de nematodos con distintos tamaños que oscilan entre 100 y 800 píxeles de longitud  $D$ . La longitud  $D$  de cada nematodo se aproxima a través de la suma de las distancias euclídeas entre vertebras consecutivas de cola a cabeza. En la sección 3.6.1 se aborda sobre la medida  $D$ . En la figura 3.6 se muestra el esqueleto de un nematodo, los hitos de frontera y las vertebras coloreadas en rojo.




Figura 3.6: Esqueleto de una instancia de nematodo  $f_i$  con las vertebras en color rojo.

En la tabla 3.1 se muestra una clasificación cuantitativa de instancias de vermes de acuerdo a su longitud  $D$  de su esqueleto en píxeles.

Tabla 3.1: Tabla de distribución de instancias de representación por hitos de nematodos según longitud  $D$  del esqueleto.

Clases	Longitud (en píxeles)
$a_1$	100 $D < 200$
$a_2$	200 $D < 300$
$a_3$	300 $D < 400$
$a_4$	400 $D < 500$
$a_5$	500 $D < 600$
$a_6$	600 $D < 700$
$a_7$	700 $D < 800$



Respecto a la tabla 3.1, se construye un histograma ( figura 3.7) que resume la distribución de las longitudes  $D$  de las estancias de nematodos medidos en  $p$  xeles con los que se realiza los procesos de experimentacion.

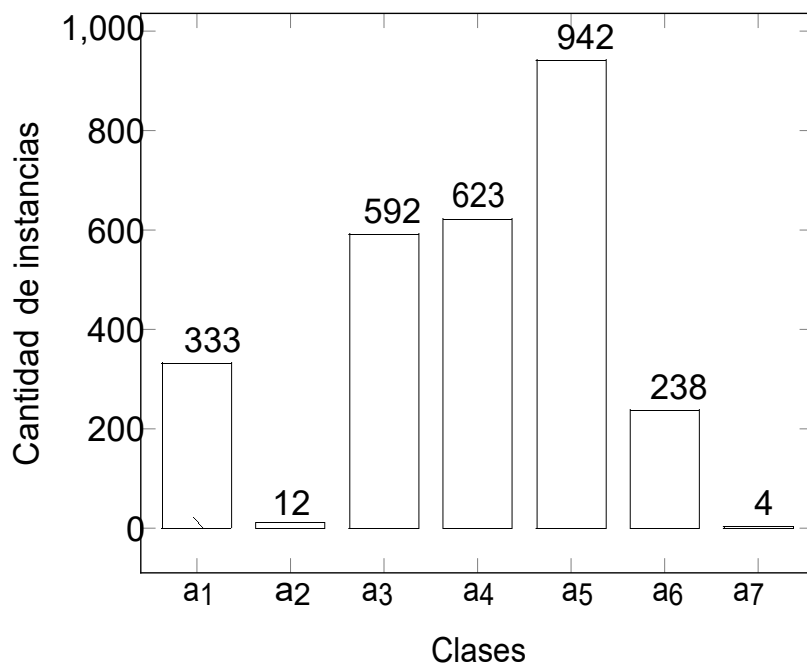


Figura 3.7: Histograma de longitudes  $D$  de los esqueletos de estancias de nematodos de la base de datos.

El proceso de la obtencion de la base de datos nal se da en tres subfases: obtencion de la coleccion de imagenes digitales, anotacion manual de hitos de frontera sobre el contorno del nematodo y nalmente la normalizacion de la base de datos (seccion 3.2.1). En la gura 3.8 se ilustra este proceso.

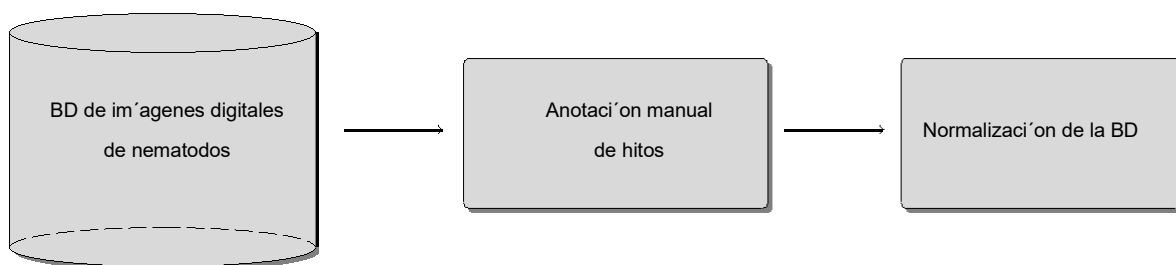


Figura 3.8: Diagrama de flujo de la obtencion de la base de datos.

### 3.2.1. Normalización de la base de datos de hitos de frontera

El proceso de normalización se refiere a un ajuste de las estructuras vermiformes con el fin de minimizar las tendencias particulares de subconjuntos de datos dominantes sobre las características generales de toda la base de datos  $C$ , tales como tamaño de las siluetas, número de hitos de representación y sentido de orientación en la secuencia de posicionamiento de los hitos. Con esto se logra que todos los elementos de  $C$  se proyecten a una escala común.

La normalización se divide en tres etapas ordenadas según su aplicación: orientación de la secuencia de hitos para representar la forma verme, número de hitos y, alineación y escalado de la silueta. El orden de aplicación de cada etapa se visualiza en la figura 3.9.

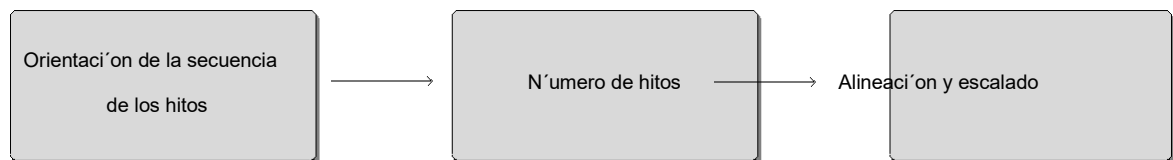


Figura 3.9: Diagrama de bloques de las etapas de normalización de la base de datos de entrenamiento y pruebas.

En las siguientes subsecciones se detallan las etapas de la normalización de la base de datos.

**Etapa 1:** Orientación en la secuencia de los hitos: La primera etapa tiene como tarea normalizar la orientación de la secuencia de hitos de cada instancia vectorial. Esto es posicionar los hitos, en sentido antihorario, en una cadena.

El método se basa en una variación dada en (Garza-Hume et al., 2018; Sedgewick y Wayne, 2011) sobre la interpretación del resultado numérico del área de un polígono irregular dada por el matemático Carl Friedrich Gauss<sup>1</sup>, y consiste en determinar el sentido de secuenciación a través de la constante de orientación ( $f_i$ ).

En el caso que  $(f_i) > 0$  se verifica que la región interna delimitada por una curva, simple y cerrada de  $n$  hitos, se encuentra a la izquierda de la trayectoria de anotación de estos (Levinson y Redheffer, 1975). Dicho trazo se denomina curva de Jordan.

<sup>1</sup>Matemático, astrónomo, geobotánico y físico, nacido en Alemania en el año 1777.

El calculo de  $(f_i)$  es dado por:

$$(f_i) := \det_{i=0}^{2n-2} \begin{pmatrix} x_i & y_i & 1 \\ x_{i+1} & y_{i+1} & 1 \\ \dots & \dots & \dots \\ x_{i+n-1} & y_{i+n-1} & 1 \end{pmatrix} \quad (3.1)$$

En caso que  $(f_i)$  sea negativo, se reacomoda el vector con las coordenadas de los hitos en secuencia inversa ( figura 3.10). El proceso de inversion en el orden de los hitos se denota  $rev(f_i)$  y se aplica cuando  $(f_i) < 0$ , y es tal que:

$$rev(f_i) := (x_{i+n-1} \ y_{i+n-1} \ x_{i+n-2} \ y_{i+n-2} \ \dots \ x_i \ y_i \ 0) \quad (3.2)$$




Figura 3.10: Ejemplo de la aplicacion de la etapa I de normalizacion de la secuenciacion de hitos en sentido positivo y negativo respectivamente.

**Etapa II**: Numero de hitos equidistante: La segunda etapa del proceso consiste en normalizar todas las instancias vectoriales a un mismo numero  $m$  de hitos, equidistantes entre  $s$ , de manera que todas las siluetas puedan ser representadas adecuadamente.

La representacion adecuada de una forma verme es una aproximacion de la curva ideal  $C_r$  del contorno de la silueta del organismo que es muestreada por hitos de frontera. Es dada por:

$$C_r := \frac{h}{h_0} \frac{h}{h_1} \dots \frac{h}{h_{p-1}} \quad (3.3)$$

donde  $\underline{h}_j$  ( $0 \leq j < p$ ) son hitos secuenciados de posicionamiento real. La aproximación de  $C_r$  es una curva de interpolación  $C_{SPL}$  definida por una secuencia de hitos anotados  $h_j$  próximos a los  $\underline{h}_j$  respectivamente. Cada hito anotado  $h_j$  es definido por:

$$h_j := \underline{h}_j + \epsilon_j \quad (3.4)$$

—

y, donde se asume que  $x_{ij}; y_{ij} \sim N(0; \sigma^2)$ . Dicho error se atribuye a la anotación manual de los hitos, y se establece a partir de la diferencia espacial entre las posiciones de los hitos  $h_j$  y  $\underline{h}_j$ .

Asimismo, la curva de aproximación de la silueta es:

$$C_{spl} := C_r + \quad (3.5)$$

con  $t := 0 \dots p-1$ . Para la estructura vectorial original  $f_i$  de  $p$  hitos  $h_j$  anotados y tomados como puntos de control, la curva interpolante parametrica  $C_{spl}$  dada en (2.36) que aproxima la totalidad el contorno de cada forma verme se de ne por:

$$C_{spl}(t) := \sum_{j=0}^{p-1} x_j B_{j;d}(t) + i \sum_{j=0}^{p-1} y_j B_{j;d}(t) \quad \# \quad (3.6)$$

La curva  $C_{spl}$  de una forma verme y sus hitos anotados manualmente se muestran en la figura 3.11.




Figura 3.11: Forma de nematodo representado por  $f_i$  y su curva interpolante parametrica  $C_{spl}(t)$  para 23 hitos.

Luego, el vector normalizado a  $m$  hitos, denotado  $part(C_{spl}(t);m)$ , corresponde a la estancia vectorial de nida en (3.6) que contiene las nuevas posiciones de los hitos consecutivamente equidistantes. Viene dado por:

$$part(C_{spl}(t);m) := x_{b_i 0} y_{b_i 0} x_{b_i 1} y_{b_i 1} \dots x_{b_i m-1} y_{b_i m-1} \quad (3.7)$$

Ademas, el numero  $m$  de hitos a elegir debe proveer informacion de manera que la perdida y redundancia en la informacion que se suministra del contorno del organismo sea minima. Las particiones son calculadas sobre la curva  $C_{spl}$  en  $m-1$  subcurvas dadas por:

$$C_{spl_0} ; C_{spl_1} ; \dots ; C_{spl_{m-1}} \quad (3.8)$$

donde en cada subcurva  $C_{spl_i}$ , los hitos inicial y final corresponden respectivamente a  $b_{x_{ij}} b_{y_{ij}}$  y  $b_{x_{i,j+1}} b_{y_{i,j+1}}$ . La respectiva longitud de arco de cada subcurva viene dada respectivamente por:

$$L_{C_{spl_0}} ; L_{C_{spl_1}} ; \dots ; L_{C_{spl_{m-1}}} \quad (3.9)$$

donde  $C_{spli}$  es dada por el segmento de recta de los hitos inicial y nal de cada subcurva, es decir:

$$C_{spli} = \frac{q}{\sqrt{x_i^2 + y_i^2}} \quad (3.10)$$

b      b

con  $x_{bi j} := x_{bi j+1} - x_{bi j}$  y  $y_{bi} := y_{bi j+1} - y_{bi j}$ .  
 El criterio de particion corresponde a que la longitud de arco entre subcurvas consecutivas sea la misma. Es decir:

$$C_{spl0} = C_{spl1} = \dots = C_{splm-1} = \frac{\sum_{j=0}^{n-1} \sqrt{x_{i j}^2 + y_{i j}^2}}{n-1} \quad (3.11)$$

En la figura 3.12 se ilustra con un ejemplo la segunda etapa. La curva interpolante respecto a sus hitos normalizados en numero y distancia.




Figura 3.12: Ejemplo de la aplicacion de la etapa II. A la izquierda la curva que delinea un nematodo con hitos a diferentes distancias, y a la derecha la curva con  $m = 40$  hitos de una forma verme  $f_i$  aproximadamente equidistantes entre  $s$ .

Etapa III: Alineacion y escalado: La ultima etapa es el proceso de alineacion de todos los elementos  $f_i$  del conjunto de entrenamiento respecto a una forma verme  $f$  usada como referencia.

Este es un metodo que  $\tau$  de traslacion  $t_{xy} = (t_x, t_y)$  de cada forma  $f_i$  de  $C$  de manera que la distancia entre los ver en figura 3.10  
 El proceso es denotado con  $align f_i; f$  y se utiliza el metodo detallado en la seccion 2.5. optimiza el angulo de rotacion  $\theta$ , el factor de escala  $s$  y el vector




Figura 3.13: Ejemplo de la aplicacion de la fase III de alineacion y escalado. A la izquierda dos formas vermes (una ellas es la de referencia en la que se representa sus hitos con circulos con un relleno de color negro), y a la derecha la forma verme alineada a la de referencia respecto a la posicion, escala y tamaño.

### 3.2.2. Aumento de cardinalidad de la base de datos por simetría de forma

Después de la etapa de normalización, el último proceso consiste en reejar cada elemento del conjunto de entrenamiento  $C$  a través de una transformación lineal isométrica  $R$  en la que a cada forma verme  $f_i$  se le asocia otra  $f_i^{(r)}$  de modo que los hitos respectivos se

se ubiquen a igual distancia de un eje simétrico (gura 3.14). El proceso de reexion por

simetría de forma de  $f_i$  es denotado  $\text{sim}$   $f_i^{(r)}$ . Cada instancia nueva  $f_i^{(r)}$  es agregada a  $C$ .




Figura 3.14: Ejemplo de la aplicacion de la normalizacion de simetría de forma de  $f_i$  y  $f_i^{(r)}$  respecto a un eje vertical.

En adelante, una forma verme  $f_i$  tratada bajo las tres etapas se denota  $b f_i$ , y este proceso se denomina **pre-procesamiento de formas vermes**.





En la [gura 3.16](#) se muestra el diagrama de las etapas del metodo del serpenteo.

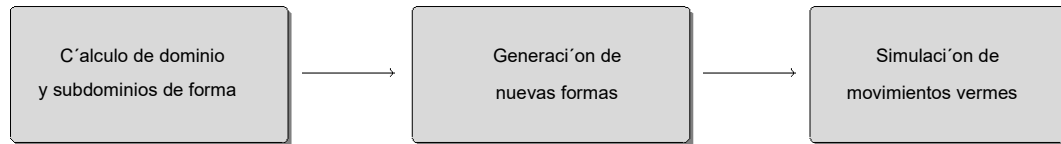


Figura 3.16: Diagrama de flujo del metodo del serpenteo.

### 3.3.1. Dominio y subdominio de formas vermes

El dominio de formas validas vermes, denotado  $D_f$ , se define como un conjunto no vacío de cardinalidad infinita en el que cada elemento  $f_i^b \in D_f$  es una representación de una forma verme valida. Cada elemento  $f_i^b \in D_f$  es un elemento de  $\mathbb{R}^{2m}$ ; además, se asume que un dominio de forma  $D_f$  es una variedad topológica  $n$  dimensional embebida en el conjunto  $\mathbb{R}^{2m}$  con  $n < 2m$ .

Asimismo, un subdominio de formas permitidas, denotado  $S_{D_f}$ , es un conjunto de individuos  $f_i^b$  de una partición del dominio de formas vermes  $D_f$  que, por medio de algun estado de proximidad o distancia, se agrupan por similitud de forma. Así, una forma particular de aproximar subdominios de forma es por medio de hipervolumenes delimitados por  $n$ -simplexes (sección 2.7) donde los nodos que engendran dicho conjunto son formas vermes ajenas en su silueta. La region interna de los subdominios contienen infinitas instancias vermes validas generadas a traves de los nodos.

Los nodos  $f_i^b$  de los subdominios de forma se obtienen usando el algoritmo de  $k$ -medias dado por (Wagsta et al., 2001). Cada nodo  $f_i^b$  es un centroide  $c_i$  de una partición realizada sobre el dominio de forma  $D_f$ . Además, cada  $c_i$  representa una forma significativamente distinta sobre los restantes de las otras particiones del dominio de formas  $D_f$ .

En la [gura 3.17](#) se muestra el proceso de obtención de los subdominios de forma  $S_{D_f}$ . La primera parte muestra un conglomerado de puntos, cada uno representa una forma verme  $f_i^b$ . Luego, se calculan los centroides de los agrupamientos dados por la partición, y finalmente, con estos se construyen los  $S_{D_f}$  que representan  $n$ -simplexes en el espacio de datos.

Cabe destacar que todas las formas  $f_i^b$  que engendran los subdominios de forma  $S_{D_f}$  son alineados a una forma verme  $f$  segun el metodo descrito en la sección 2.5. Además, si dos o más subdominios al menos poseen un vertice en comun, se les denomina subdominios vecinos.




Figura 3.17: Proceso de obtencion de  $SD_f$  a traves del algoritmo de k-medias. La primera parte del proceso (a la izquierda) muestra el conglomerado de datos, la segunda exhibe los centroides, y la ultima los subdominios de forma.

### 3.3.2. Generacion de nuevas formas vermes en un $SD_f$

Una nueva forma verme  $f^{b(i)}$  pertenece en un subdominio  $SD_f$  de nido por un hipervolumen delimitado por un  $n$  s mplex de  $n + 1$  nodos a traves de:

$$f^{(i)} \in SD_f, f^{(i)} = \sum_{j=0}^n f_j b_j = \sum_{j=0}^n f_j b_j \quad (3.13)$$

donde los  $f_0^b; f_1^b; \dots; f_n^b$  son vertices del  $n$  s mplex dados por los centroides que generan el subdominio  $SD$  (Arroyo y Alvarado, 2020). Ademas, las coordenadas baricentricas  $f_0; f_1; \dots; f_n$  son coeficientes reales tales que  $\sum_{j=0}^n f_j = 1$ .

$j=0$

### 3.3.3. Simulacion de movimientos aleatorios vermes

El metodo del serpenteo consiste en movimientos vermes simulados por medio de una caminata aleatoria (Woess, 2000) a traves de una sucesion de pasos aleatorios

$$(P_0; P_1; \dots; P_n)_{n \geq 1} \quad (3.14)$$

entre subdominios vecinos que deforman gradualmente la silueta original. Cada paso  $P_j$  representa un cambio de subdominio (gura 3.18).

El recorrido entre subdominios vecinos posibilita que cada elemento generado  $f^{b(i)}$  conserve informacion de forma de al menos uno de los vertices en comun permitiendo que la sucesion de las  $p + 1$  nuevas siluetas vermes:

$$f^{b(0)}; f^{b(1)}; f^{b(2)}; \dots; f^{b(p)} \quad (3.15)$$

cambien de forma paulatina.




Figura 3.18: Caminata aleatoria entre  $S_{Df}$  vecinos. En rojo se muestran las formas  $f^{(i)}$  para los diferentes subdominios vecinos.

El metodo es un heurístico que parte de una forma verme inicial  $f^{(0)}$  para algun  $S^{(0)}$  elegido aleatoriamente. Los vertices del nuevo subdominio  $S^{(0)}$  corresponden al conjunto  $V^{(0)}$  de los  $q$  vecinos mas cercanos a una forma  $f_i$  elegida aleatoriamente o previamente de nidas. La siguiente forma  $f^{(1)}$  de esta simulacion se calcula en un nuevo subdominio  $S^{(1)}$  que se determina por el conjunto de los  $q$  centroides mas proximos  $V^{(1)}$  de algun nodo  $f$  seleccionado aleatoriamente en  $S^{(0)}$ . Esta forma  $f^{(1)}$  se calcula en  $S^{(1)}$  a traves del metodo descrito en la seccion 3.3.2. El nuevo subdominio  $S^{(1)}$  es un n-s mplex vecino del anterior.

El proceso se repite iterativamente hasta satisfacer un criterio de paro, por ejemplo un numero de iteraciones previamente de nidas. Cabe señalar que los centroides se calculan eficientemente con el metodo aproximado expuesto en (Muja y Lowe, 2009).

El procedimiento propuesto permite que las deformaciones se simulen a partir de una instancia inicial y continuen de manera natural conservando informacion de forma entre las iteraciones y logrando el efecto de deformaciones vermes continuas validas.

En la gura 3.19, se muestra un ejemplo del movimiento generado por el calculo iterativo de formas aleatorias entre cambio de  $S_{D_f}$  vecinos. Se parte de una forma  $f^{(0)}$  y se muestra para todas las iteraciones la deformacion verme valida. En esta se usa 10 nodos y 200 centroides y se aprecia que en la sucesion hay un cambio de la forma gradual no abrupto.




Figura 3.19: Sucesion de movimientos vermes continuos entre  $S_{D_f}$  vecinos. El nematodo que se distorsiona esta representado con hitos dibujados con c rculos de relleno negro. En rojo se colorea el borde de la silueta original. Para esta simulacion se utiliza 10 nodos y 200 centroides.

El algoritmo de la simulacion de movimientos aleatorios vermes se presenta en la gura 3.20.

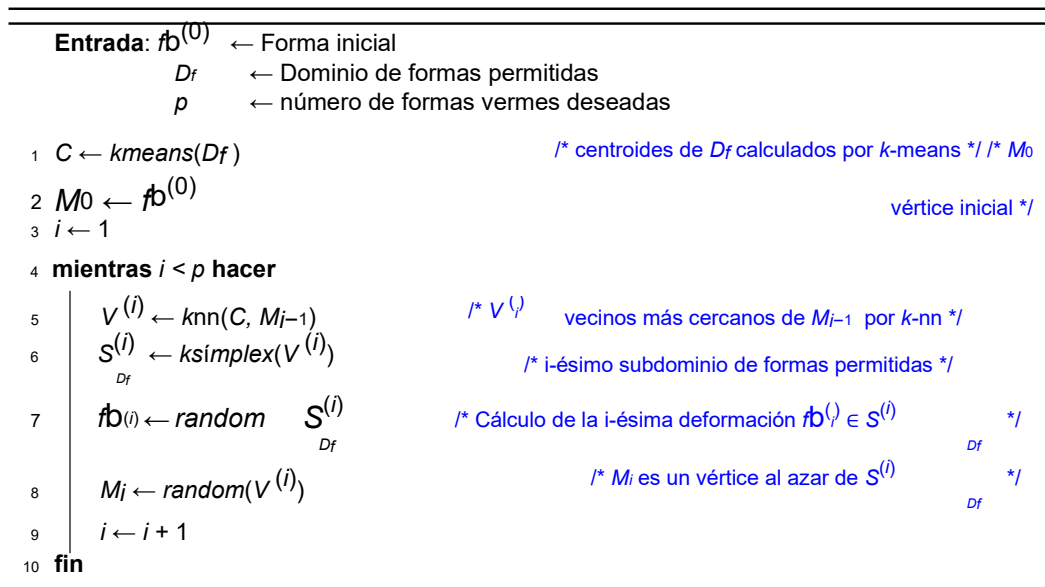


Figura 3.20: Algoritmo de distorsion de un nematodo entre  $S_{D_f}$  vecinos.

El algoritmo permite buscar nuevas siluetas de nematodos, s miles en forma, que permitan cambiar las part culas del frente de Pareto por otras que se ajusten mejor. En adelante, la funcion serpenteo se denota snk.

### 3.4. Metodo de deformacion de nematodos: forrajeo

El metodo de deformacion de nematodos denominado forrajeo es una tecnica de simulacion de la deformacion de organismos vermiformes sobre la superficie terrestre en su desplazamiento. Este consiste en continuas ondulaciones sinusoidales a traves de contracciones del cuerpo, cola y cabeza, y alargamiento.

Con este se logra una sucesion de formas continuas que simulan la locomocion de los nematodos, permitiendo, en primera instancia, generar nuevas formas vermes a partir de cada instancia del conjunto de entrenamiento  $C^b$  y, la evolucion de la silueta aplicada en el modelo evolutivo de forma.

En la figura 3.21 se muestra el proceso general que se detalla en las secciones 3.4.1, 3.4.2 y 3.4.3.

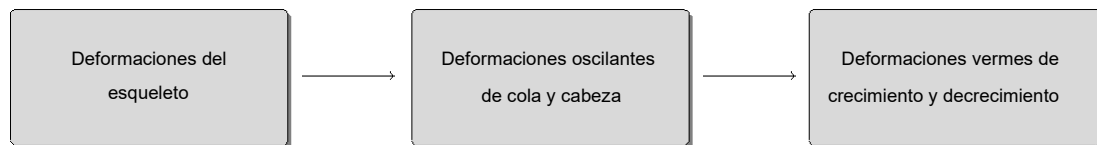


Figura 3.21: Diagrama de flujo del metodo forrajeo.

Cabe destacar cada elemento del conjunto de entrenamiento  $C^b$  es previamente preprocesado segun la seccion 3.2.1.

#### 3.4.1. Deformaciones del esqueleto

Las nuevas formas de nematodo  $f_i^b$  son logradas a traves del movimiento del esqueleto  $E_i$  (figura 3.22), de nido como el vector compuesto por las posiciones de las vertebrae, cada una dada por el promedio de los dos hitos correspondientes diametralmente opuestos  $h_{ij}$  y  $h_{i(m-j)}$ .

El conjunto de todos los esqueletos  $E_i$  de  $f_i^b$  de  $D_f$  se denota  $E$ , y cada uno se expresa vectorialmente por:

$$E_i := \begin{bmatrix} E_{i0x} & E_{i0y} & E_{i1x} & E_{i1y} & \dots & E_{iux} & E_{iuy} \end{bmatrix}^T \quad (3.16)$$

donde la posicion de cada vertebra se define por:

$$E_{ijx} := \frac{x_{ij} + x_{i(m-j)}}{2} \quad E_{ijy} := \frac{y_{ij} + y_{i(m-j)}}{2} \quad \text{para } 0 < j < u: \quad (3.17)$$

y  $u := m/2$  con  $m$  es el numero de hitos de  $f_i^b$ .

Ademas, los hitos sobre la cabeza y cola de la forma verme son elegidos respectivamente como la primera vertebra:

$$V_{i0} := (E_{i0x} ; E_{i0y}) := (x_{i0}; y_{i0}) \quad (3.18)$$

y ultima vertebra

$$V_{iu} := (E_{iux} ; E_{iuy}) = (x_{iu}; y_{iu}) \quad (3.19)$$

La distorsion de la forma de la silueta verme se concentra en dos fragmentos del esqueleto, de nidos por las  $u_0$  vertebrae mas cercanas a la cabeza y a la cola de  $f_i$ . Para las vertebrae  $V_{ij} = (E_{ijx} ; E_{ijy})$  del fragmento de la cabeza se cumple  $1 \leq j < u_0$ , y para el fragmento de cola  $u_0 - j < u$ .




Figura 3.22: Esqueleto de una forma verme  $f_i$ . En círculos con relleno de color negro se visualizan las vertebrae. Los círculos con relleno color rojo corresponden a los hitos de frontera de la forma verme. La forma verme posee 40 hitos de frontera con  $u = 20$ .

El proceso de forrajeo esta dado por dos movimientos: oscilaciones laterales y expansion y contraccion de cola y cabeza. Ambos se explican en la secciones 3.4.2 y 3.4.3 respecti-vamente.

### 3.4.2. Deformaciones vermes oscilantes de cola y cabeza

La primera parte del metodo del forrajeo es una deformacion del cuerpo del nematodo inspirada en el trabajo de K.-M. Huang et al. (2008), que consiste en oscilaciones laterales de cabeza y cola.

Para realizar estos movimientos, se toman los fragmentos con un numero  $u^0$  vertebrae de cola y cabeza, y se manipulan (junto a los hitos correspondientes a cada vertebra) como una cadena cinematica directa (Harary y Yan, 1990). En dicha cadena, cada vertebra cuenta con un grado de libertad rotacional con un angulo de rotacion .

Dado el número  $u^0$  de vertebras a modificar y un ángulo inicial  $\theta$ , el algoritmo toma la vertebra del fragmento de cabeza  $V_{i^0} := (t_x; t_y)$  como  $j_a$  y aplica la transformación de rigidez por:

$$M_{v_{yij}}^x := \begin{pmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{pmatrix} \begin{pmatrix} (t_x \cos \theta + t_y \sin \theta) + t_x \\ (t_y \cos \theta - t_x \sin \theta) + t_y \end{pmatrix} \quad (3.20)$$

al resto de vertebras e hitos en la cadena cinemática. Luego, dada la nueva posición de la vertebra  $V_{i^0+1}$  se le aplica  $M_v$  al resto de elementos de la subcadena cinemática hacia la cabeza. Posteriormente se repite el proceso a partir de la vertebra  $V_{i^0+2}$  y así sucesivamente hasta llegar al hito de la cabeza.

Lo anterior provoca una rotación en secuencia de las vertebras y sus respectivos hitos, que en conjunto, logra una rotación natural del fragmento cabeza. De forma análoga, se sigue el procedimiento desde la vertebra colocada en la posición  $u^0 + 1$  hacia la cola. En ambos fragmentos, el método se aplica individualmente.

Un ejemplo de esta deformación se ilustra en la figura 3.23.

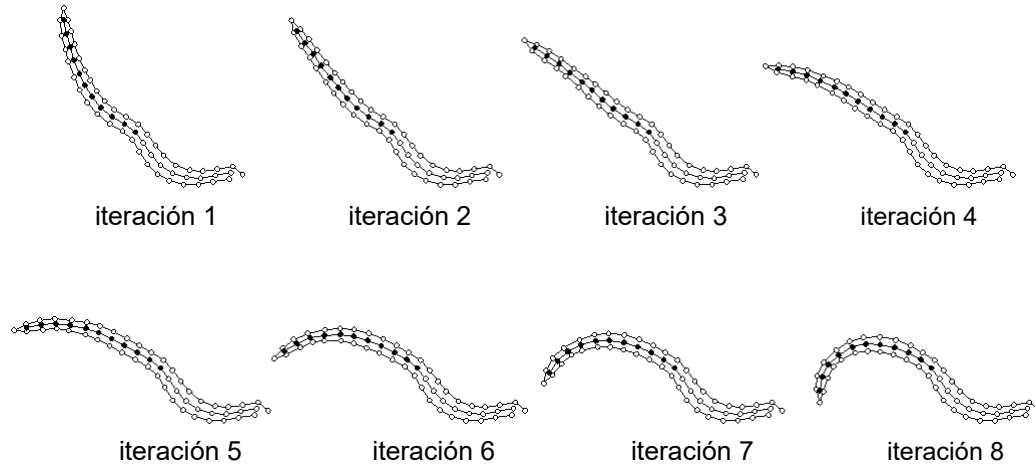


Figura 3.23: Ejemplo del método del forrajeo (parte I) para la cola de  $f_i^b$  para  $v^0 = 11$  y  $\theta = 0.2$  rad. En la figura se muestran algunas iteraciones de las deformaciones.

En la figura 3.24 se muestra el algoritmo del método del forrajeo que distorsiona de la vertebra  $u$  al hito cola.



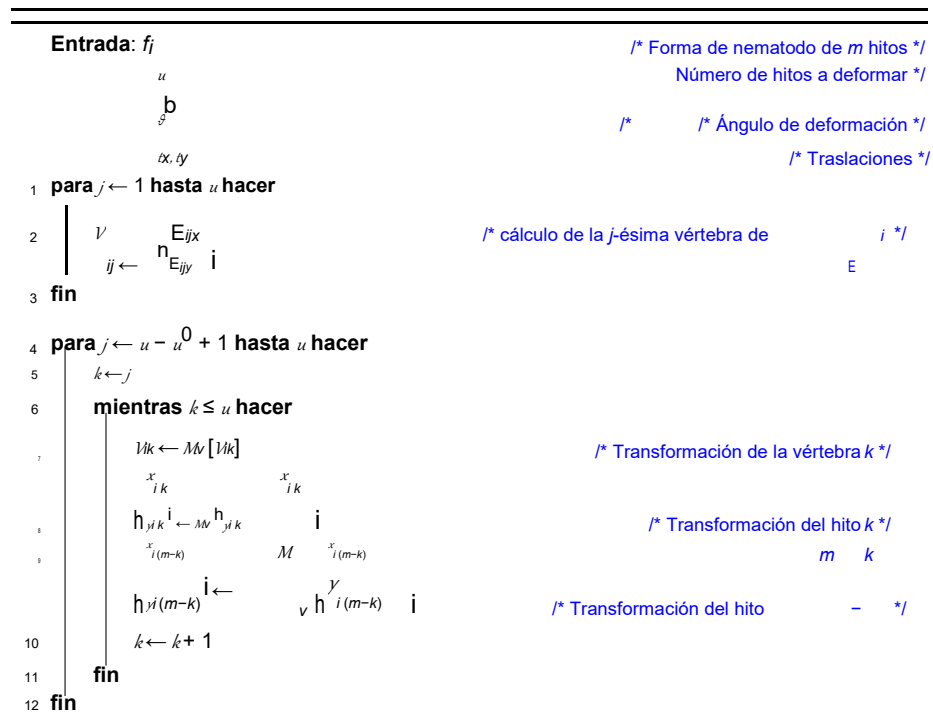


Figura 3.24: Algoritmo del metodo de forrajeo (parte I) usando la transformacion  $M_V$  para el fragmento cola para la vertebra  $u$ . La matriz  $M_V$  corresponde a (3.20).

### 3.4.3. Deformaciones vermes de crecimiento y decrecimiento

La segunda parte del movimiento del forrajeo corresponde a una contraccion o extraccion del fragmento cola y/o fragmento cabeza manteniendo la escala y la forma de la silueta original.

El alargamiento del fragmento cabeza se de ne como el desplazamiento  $d$  de los hitos  $h_{ij}$  y  $h_{i m j}$  que determinan la vertebra  $V_{ij} := (E_{ijx} ; E_{ijy} )$  dado por:

$$h_{ij} := h_{ij} + d \quad h_{i m j} := h_{i m j} + d \quad (3.21)$$

donde  $d := (d_x ; d_y)$  se calcula por:

$$d_x := (E_{ijx} E_{ij+1x})(s - 1) \quad d_y = (E_{ijy} E_{ij+1y})(s - 1) \quad (3.22)$$

con  $s \in \mathbb{R}$  y  $1 \leq j < u^0$ .

Si  $s > 1$ , el nematodo crece en el mismo sentido del vector  $V_{ij+1} V_{ij}$ , en caso contrario, se contrae a nivel de cabeza. En caso que  $0 < s < 1$ , el fragmento cabeza decrece. Con el mismo razonamiento, es calculado el crecimiento y decrecimiento del fragmento de la cola.



Figura 3.25: Ejemplo del metodo forrajeo (parte II) para el crecimiento de la silueta del fragmento de la cabeza del nematodo usando  $u^0 = 5$  y  $s = 1:3$  en cada iteracion.

Luego de cada alargamiento o encogimiento, se equidistan el numero de hitos que moldean la silueta el organismo vermiforme usando el metodo descrito en la segunda fase de la seccion 3.2.1. El algoritmo se presenta en la gura 3.26.

---

```

Entrada:  $\mathbb{R}^2$  /* Forma de nematodo de  $m$  hitos */ /* Escala de
            $s$  contracción-dilatación */ /* Número de vértebras a
            $u^0$  dilatar-contrair */

1 para  $j \leftarrow 1$  hasta  $u_0 + 1$  hacer
   |
   |   
$$E_{ij} \leftarrow \begin{matrix} x_{ij} + x_{i(m-j)} \\ y_{ij} + y_{i(m-j)} \end{matrix} \frac{1}{2}$$
 /* Cálculo de la  $j$ -ésima vértebra de  $E_j$  */
   |
2
3 fin
4  $i \leftarrow u^0$ 
5 mientras  $i > 0$  hacer
6   |
6   |   
$$d \leftarrow (E_{ijx} - E_{i+1jx}) (s - 1) (E_{ijy} - E_{i+1jy}) (s - 1)$$
 /* Cálculo de los desplazamientos  $d$  */
6   |
7   |    $h_{ij} \leftarrow h_{ij} + d$  /* Actualización de las posiciones de los hitos */
7   |
8   |    $h_{i(m-j)} \leftarrow h_{i(m-j)} + d$ 
8   |
9   |    $i \leftarrow i - 1$ 
9   |
10 fin

```

---

Figura 3.26: Segunda parte del algoritmo del metodo de forrajeo de crecimiento del fragmento de la cabeza.

Cabe destacar que este metodo no corresponde al escalamiento que se detalla en la seccion 2.5. Se diferencia en que este sufre de un alargamiento o encogimiento fragmento cola y no fragmento cabeza manteniendo el ancho de la silueta de gusano, el otro es un escalamiento de tamaño de la silueta. En adelante, la funcion de forrajeo se denota forrg.

### 3.5. Truncamiento a un $S_{Df}$

Una representación vectorial  $f_i^b$  es vermiformemente válida si existe algún subdominio al que pertenezca. En caso contrario, se dice que no es vermiformemente válida y se denota  $f_i^e$ . El método de truncamiento de partículas a un subdominio  $S_{Df}$  consiste en una aproximación numérica para  $f_i^e$ , denotado  $\text{trun}(f_i^e)$ , que calcula una representación vectorial  $f_i^b$  proyectada en un subdominio engendrado por los vértices más cercanos a su forma. En la figura 3.27 se muestra  $f_i^b$  truncado a un  $S_{Df}$ .




Figura 3.27: Truncamiento  $f_i^b$  a un  $S_{Df}$ .

El proceso consiste en hallar un  $S_{Df}$  generado por los vértices  $f_0^b; f_1^b; \dots; f_q^b$  más cercanos en forma y los respectivos los coeficientes  $\alpha_0; \dots; \alpha_q$  que cumplan las restricciones de n-s mplexes y que la distancia entre los hitos correspondientes de  $f_i^b$  y  $f_i^e$  sea mínima. Esto es:

$$\min_{\alpha_0, \dots, \alpha_q} \sum_{i=1}^n \|f_i^b - f_i^e\|^2 \quad (3.23)$$

Así,  $f_i^b$  es el elemento truncado que pertenece a  $S_{Df}$  y es más próximo en distancia a  $f_i^e$  (figura 3.28). Esto es:

$$\text{trun}(f_i^e) = f_i^b \quad (3.24)$$




Figura 3.28: Ejemplos del método de truncamiento de formas no vermes. En negro se colorea una forma no verme y en rojo su respectivo truncamiento en un  $S_{Df}$  de 10 nodos.

### 3.6. Funciones objetivo

El modelo evolutivo de forma es un proceso basado en optimización multiobjetivo de dos funciones que permiten el ajuste de una forma verme a la imagen digital. La primera es una función que mide la longitud del esqueleto de  $f_i^b$ . La segunda función obtiene una métrica de posicionamiento de  $f_i^b$  sobre el borde del nematodo en la imagen digital. Ambas funciones se normalizan en una escala común a través de la función de sigmoide que se denota  $F_{Sig}$  y se define por:

$$F_{Sig}(x) := \frac{L}{1 + e^{-k(x - x_0)}} \quad (3.25)$$

donde  $L$  es el máximo valor de la función,  $k$  es la tasa de crecimiento de la curva y  $x_0$  es el punto medio de la curva sigmoide. En las secciones 3.6.1 y 3.6.2 se detallan ambas funciones.

#### 3.6.1. Función verme de distancia

Para regular el crecimiento de la forma verme  $f_i^b$  al aplicar el modelo evolutivo de forma, se recurre a una función que permita evaluar su tamaño. El objetivo es proveer al optimizador información de la extensión o longitud de la silueta para que coadyuve en su ajuste.

El tamaño del nematodo  $f_i^b$  se define como longitud de su esqueleto dado en (3.16). Esta es dada por una función que calcula la suma de las distancias entre vertebras consecutivas. Esto se denomina función verme de distancia, se denota  $F_D$  y se define por  $F_D : E \rightarrow \mathbb{R}$  con:

$$F_D(E_i) := D_{real} \quad (3.26)$$

donde  $D_{real}$  es la medida ideal o exacta del esqueleto. La aproximación de esta métrica es dada por:

$$D_{real} \approx D_{aprox} \quad (3.27)$$

con

$$D_{aprox} = \sum_{j=0}^{\frac{m}{2}-1} \sqrt{(E_{ijx} - E_{i(j+1)x})^2 + (E_{ijy} - E_{i(j+1)y})^2} \quad (3.28)$$

con  $m$  es el número de hitos y  $\frac{m}{2}$  el número de vertebras. Un máximo local de  $F_D$  es

dado si la silueta de  $f_i^b$  se ajusta completamente al nematodo en la imagen digital, en consecuencia, es obtenido su longitud real de su esqueleto.

El máximo local es determinado por:

$$jD_{\text{aprox}} - D_{\text{real}j} < \quad (3.29)$$

para un previamente de nido. En la gura 3.29 se muestra el esqueleto de una forma verme ajustado al nematodo en una imagen digital.




Figura 3.29: Ejemplo de esqueletización de un nematodo a partir de los hitos de frontera.

Para usarla en el modelo evolutivo de forma, la función  $F_D$  es normalizada al intervalo de  $[0 ; L]$  usando la función sigmoide dada en (3.25) dando como resultado:

$$F_D(E_i) := 1 + e^{-\frac{L}{k}(E_i - x_0)} \quad (3.30)$$

para algún  $k \in \mathbb{R}$  determinado previamente. En los experimentos siguientes se toma empíricamente  $k = 0.2 \cdot 10^4$  con el fin de coadyuvar al M P SO en la determinación de las particulas del frente de Pareto.

### 3.6.2. Función verme de contorno

Para determinar el ajuste de la silueta  $f_i^b$  sobre en la imagen digital, y en particular, el amojonamiento de los hitos a lo largo del contorno del nematodo, se propone la función denominada función verme de borde denotada  $F_B$ . Esta función provee una métrica de ubicación de la silueta verme  $f_i^b$  a partir del conjunto de hitos que la conforman.

La función  $F_B$  se calcula a partir de los vectores tangenciales de borde, ortogonales de borde y los gradientes. En las siguientes secciones se describen estos vectores y la función  $F_B$ .

### Vectores tangenciales de borde

Los vectores tangenciales de borde, denotados  $V_B$ , son vectores tangentes a la curva  $C_{spl}$

determinada por los puntos de control  $h_j$  de  $f_i^c$ .

El conjunto de los vectores tangenciales de borde de  $f_i^c$  se denota  $V_{Bj}$  y vectorialmente son

definidos por:

$$V_B := \begin{bmatrix} h_1 & h_2 & \dots & h_n \end{bmatrix} \quad b \quad i \quad c$$

Cada componente  $V_{Bj}$  de  $V_B$  corresponde al  $j$ -ésimo vector tangente en el hito  $h_j$ , de nido

por:

$$V_{Bj} := \begin{bmatrix} V_{Bjx} \\ V_{Bjy} \end{bmatrix} = \frac{1}{m_{xy}} \begin{bmatrix} V_{Bjx} \\ V_{Bjy} \end{bmatrix} \quad (3.32)$$

$$d \quad \frac{6}{4} V_{Bjy} \quad \frac{7}{5} \quad \frac{6}{m_{xy} V} \quad \frac{Byj}{7} \quad \frac{6}{4} \quad \frac{7}{5}$$

donde  $x_j$  y  $y_j$  son las coordenadas  $h_j$ ,  $m_{xy} = \sqrt{V_{Bjx}^2 + V_{Bjy}^2}$  es la magnitud del vector  $y$ ,  $V_{Bjx}$  y  $V_{Bjy}$  son las componentes normalizadas de

Para lograr que los vectores tangenciales de borde  $V_{Bj}$  suavicen el sentido hacia el contorno de la curva  $C_{spl}$  de  $f_i^c$ , se deriva parcialmente el resultado de la convolucion entre cada hito de  $H_j$  y la funcion  $G$  Gaussiana para la aproximacion del gradiente en la imagen digital. En este se indica la direccion del gradiente en la que ocurre el mayor cambio que ocurre en el borde del nematodo. Es dada por:

$$G(x; ; ) := \frac{1}{\sqrt{2\pi}} e^{-\frac{(x)^2}{2}} \quad (3.33)$$

El resultado de este calculo es:

$$V_{Bjx} := \frac{\partial}{\partial x} (H_j \sim G) = H_j \sim \frac{\partial G}{\partial x} \quad (3.34)$$

$$V_{Bjy} := \frac{\partial}{\partial y} (H_j \sim G) = H_j \sim \frac{\partial G}{\partial y} \quad (3.35)$$

donde  $\sim$  denota la operacion de convolucion. Las componentes  $\frac{\partial G}{\partial x}$  y  $\frac{\partial G}{\partial y}$  se denominan las derivaciones orientadas de la funcion Gaussiana (OGD por sus siglas en ingles) en  $x$  y

en y (Alvarado et al., 2001). La gura 3.30 muestra el calculo de los vectores tangenciales de borde sobre el contorno nematodo en una imagen digital.

### Vectores ortogonales de borde


Los vectores ortogonales de borde de cada  $f_i$ , denotados  $V_{Oj}$ , son el conjunto de vectores perpendiculares a cada  $V_{Bj}$  en cada hito de  $H_j$ .

$$V_{Oj} := \begin{matrix} \text{Vectorialmente,} \\ \text{se expresa por:} \end{matrix} \begin{matrix} V_{Bj} \\ \vdots \\ V_{Bj} \end{matrix} \quad (3.36)$$


Cada vector  $V_{Oj}$  de  $V_O$  se calcula por:

$$V_{Oj} := \nabla_{Bj} \quad (3.37)$$

En la figura 3.30 se muestra los vectores ortogonales de borde.



(a) Imagen de un nematodo con los vectores tangenciales y ortogonales de borde coloreados en verde y rojo respectivamente.



Vectores gradientes →  
 Vectores ortogonales de borde →  
 Vectores tangentes de borde →

(b) Extraccion de los vectores.

Figura 3.30: En verde se representan los vectores tangenciales, en rojo se representa los vectores gradiente de borde, y en azul se representan ortogonales de borde de un nematodo y su respectiva silueta conformada por 20 hitos de frontera  $H_j$ .



Funcion verme de borde  $F_B$

La funcion verme de borde  $F_B$  provee una metrica de posicionamiento de las formas  $f_i^b$  sobre los nematodos en las imagenes digitales.

Si se toman los hitos como puntos de anclaje de los vectores ortogonales de borde y gradiente, entonces se garantiza que entre mayor sea la suma de sus productos escalares de los vectores  $V_{Oj}$  (3.37) y los  $rl(x_j;y_j)$  (2.2) respectivamente, entonces todos los hitos en conjunto estan ubicados con mayor proximidad a los bordes del nematodos en las imagenes digitales.

La funcion  $F_B : D_f \rightarrow \mathbb{R}$  viene dada por:

$$F_B = \sum_{j=1}^{m-1} \frac{B_{xj}}{V_{Byj}} T \left( \begin{matrix} |x_j;y_j| \\ |y_j;x_j| \end{matrix} \right) \quad (3.38)$$

donde  $T$  es la funcion que ltra la imagen a niveles de gris. Para determinar el maximo local de  $F_B$ , el conjunto de vectores tangentes sobre  $h_j$  de  $f_i^b$  deben seguir la trayectoria del contorno de la forma verme, y el conjunto de vectores ortogonales a cada vector tangente en  $h_j$  de  $f_i^b$  debe tener el mismo sentido que el vector gradiente.

Si el vector ortogonal de borde y el vector gradiente de la imagen tienen el mismo sentido, se asegura que:

- El producto escalar de los vectores ortogonales de borde y gradiente es maximo.
- En los  $h_j$  y  $h_{m-j}$  de  $f_i^b$ , sus vectores ortogonales de borde respectivos tienen sentido aproximadamente opuesto. Lo que garantiza que estos hitos se ubiquen en puntos sobre el borde que sean opuestos en su silueta y, en conjunto, cubran la totalidad del nematodo.

Para usarla en el modelo evolutivo de forma, la funcion  $F_B$  se normaliza al intervalo de  $[0 ; L]$  empleando la funcion sigmoide dada en (3.25) dando como resultado:

$$F_B = \frac{b}{1 + e^{-k(F_B(f_i))}} \quad (3.39)$$

para algun  $k \in \mathbb{R}$  previamente dado.

### 3.7. Modelo evolutivo de forma

En esta seccion se desarrolla el modelo evolutivo de forma (MEF) parametrico basado en hitos de frontera. Este metodo es capaz de adoptar, a partir de un conjunto de particulas  $f^b$ , la silueta del nematodo en la imagen digital atendiendo simultaneamente un doble criterio de decision: forma y tama~no. El modelo propuesto es iterativo y se inicializa con:

- Un conjunto de datos entrenamiento  $C^b$  normalizado (segun la seccion 3.2.1).
- Una imagen digital que contenga un nematodo.
- Una forma  $f_0^b$  seleccionada aleatoriamente del conjunto de entrenamiento  $C^b$ . Esta puede ser generada de manera sintetica usando los resultados de la seccion 3.3.2.
- Una base datos vermes  $BD_0$  generada a partir de  $f_0^b \in C^b$  expresada por (3.12).

Para la aplicacion del modelo, se elimina la forma de inicio  $f_{b0}$ . Redefiniendo  $C^b$  de la forma:

$$C := C \setminus f_{b0}$$

En esta fase, la base de datos  $BD_0$  se calcula por el metodo de caminatas aleatorias para un numero  $v$  de individuos. Cada subdominio de forma  $S_{Df}$  esta constituido por un numero  $w$  de vertices cercanos en forma. El modelo sigue las fases que se describen en la figura 3.31 para un numero  $N_{iter}$  de iteraciones predefinidas. En la seccion 3.7.1 se describen cada una de estas etapas.

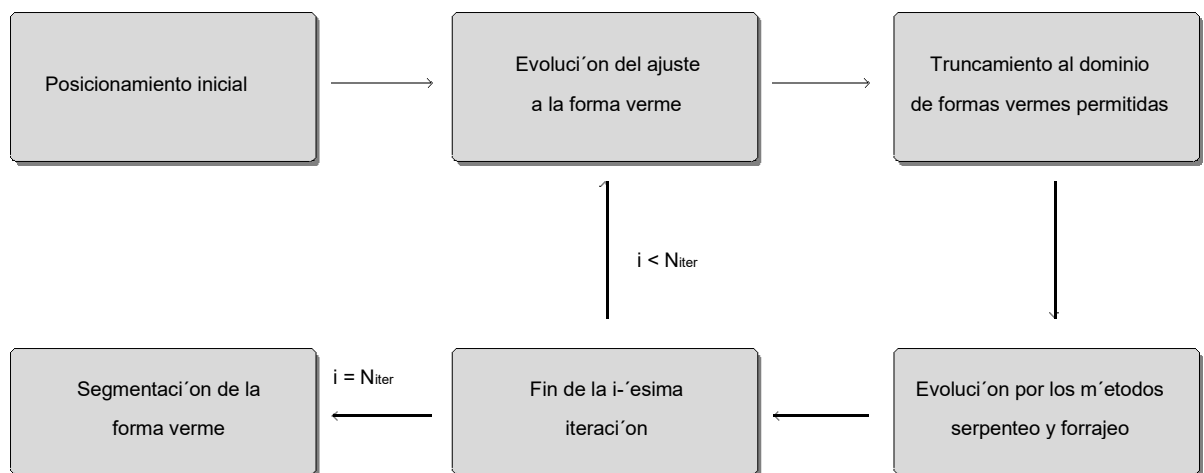


Figura 3.31: Diagrama de flujo del modelo evolutivo de forma para  $N_{iter}$  iteraciones.

La forma verme de inicio  $f_0^b$  se alinea respecto al centro de masa de la imagen digital. Además, es escalada para que la longitud del esqueleto  $E$  no exceda la mitad del mínimo entre las dimensiones de la imagen digital.

Cabe destacar que el MEF es invariante durante todo el proceso de su ejecución. Lo anterior se debe a que el algoritmo trabaja en un sistema de coordenadas determinado previamente por los centroides calculados de  $C^b$ . Estos, que conforman los subdominios de forma, no varían en traslación, tamaño y rotación durante la ejecución del algoritmo.

Asimismo, las partículas del frente de Pareto se alinean a dicho sistema coordenado cuando pasan por los procesos del serpenteo y truncamiento. Después de finalizado, se recalculan las nuevas formas correspondientes a la escala previa. Las alineaciones son realizadas utilizando el método de Procrusto explicado en la sección 2.5.

Por otro lado, a nivel de imagen digital, los elementos del frente de Pareto se alinean a  $f_0^b$  para ser aplicados en el MOPSO y el método del forrajeo. Posteriormente, evolucionan en forma y tamaño según el ajuste correspondiente.

### 3.7.1. Ajuste de forma usando MOPSO

En la primera etapa del modelo, se inicia el ajuste por medio del método de optimización multiobjetivo MOPSO (descrito en la sección 2.8) en un espacio de búsqueda dado por el dominio de formas permitidas  $D_f$ .

En cada iteración, los hitos de las formas  $f_i^b$  son ajustados individualmente dando al modelo un criterio de decisión para aproximarlas a las siluetas en las imágenes digitales. Este criterio se denominará en adelante la medida óptima de borde-longitud y se refiere a que todos los hitos  $h_j$  de la forma vectorial  $f_i^b$  estén ubicados sobre el borde del nematodo cubriendo su silueta. El criterio satisface si se cumplen las siguientes dos premisas:

- Todos los hitos son equidistantes y correspondan a los puntos de anclaje de los vectores ortogonales de borde  $V_{Bj}$  de un nematodo en la imagen digital.
- La longitud del esqueleto del nematodo en la imagen digital debe corresponder a la longitud del esqueleto de la forma  $f_i^b$ .

Numericamente, las premisas borde-longitud se satisfacen con las funciones  $F_D$  y  $F_B$  dadas por las ecuaciones (3.30) y (3.39) respectivamente. Además, a través de dicho criterio y MOPSO se logra determinar el  $j$ -ésimo conjunto óptimo de Pareto que está dado por:

$$M_j := p_{0j} \ p_{1j} \ \dots \ p_{q-1j}^T \quad (3.40)$$

que corresponde a las  $q$  partículas  $f_i^b$  que compiten por el mejor ajuste en longitud y en borde respecto al nematodo en la imagen digital.

Cabe señalar que la forma media inicial  $f_0^b$  se conserva durante todo el proceso para usarse en la normalización de los elementos del frente de Pareto usados en los métodos de truncamiento y serpenteo. En el MOPSO y el método del forrajeo, las formas vermes evolucionan en tamaño y forma.

La metodología de adaptación de la silueta  $f_i^b$  a la del nematodo en la imagen digital tiene dos estadios: el de posicionamiento inicial y la evolución de ajuste. Ambas se describen a continuación.

Etapa de posicionamiento inicial

La etapa de posicionamiento inicial requiere que las primeras iteraciones del modelo evolutivo de forma se enfoquen en hallar la mejor ubicación de la forma  $f_0^b$  respecto al nematodo en la imagen digital usando MOPSO. Las formas vermes del frente de Pareto se escalan al tamaño de la forma verme inicial, y evolucionan de acuerdo al tamaño del nematodo presente en la imagen digital.

La mejor ubicación inicial se refiere a que el área de la silueta descrita por  $f_i^b$  se traslape con la mayor parte del nematodo en la imagen digital. Además, que la mayor cantidad de hitos del fragmento central de  $f_i^b$  se ubiquen en el contorno del nematodo.

Para esto, se utiliza la estrategia de darle un peso  $w_j$  distinto a la evaluación en (3.39) de los hitos localizados en la parte central de la silueta en relación con los fragmentos cola y cabeza en las primeras  $M$  iteraciones del MEF.

Esto permite al MOPSO decidirse por incluir en el conjunto óptimo de Pareto las siluetas que se han adaptado en su parte central primeramente, sin dejar de lado la evolución de la forma a la existente en las trozos cabeza y cola en la imagen digital, para posteriormente, darle paso al método del serpenteo.

Para una forma verme  $f_i^b$  normalizada a  $m$  hitos, la asignación los pesos  $w_j$  se hace a través de un mapeo lineal del  $j$ ésimo hito  $h_j$  al intervalo  $[a;a]$ , evaluados en la función gaussiana  $G(x; \mu, \sigma)$  (ver 3.32), dada por:

$$w_j := \begin{cases} G\left(\frac{4a_j - a}{2a - a}; 1; 0\right) & \text{si } 0 \leq j < \frac{m-1}{2} \\ G\left(\frac{2a_j - 2a_m}{m-1}; a; 1; 0\right) & \text{si } \frac{m-1}{2} \leq j \leq m-1 \end{cases} \quad (3.41)$$

Así de (3.38), las evaluaciones para hitos para las primeras  $i$  iteraciones se ponderan con  $w_j$  de la forma:

$$F_B f_i := \sum_{j=0}^{m-1} w_j V_{oj} r_l(x_j; y_j) \quad (3.42)$$

Etapa de evolución de ajuste a la forma verme

El proceso de reemplazo interno o actualización de partículas contenidas en el conjunto óptimo de Pareto  $M_j$  permite que se deformen hacia la del nematodo presente en la




Figura 3.32: Mapeo de los pesos  $w_j$  para cada hito de  $f_i$  usando la función gaussiana en el intervalo de  $[-3, 3]$ . La gráfica presenta un degradado de colores, en la cual la parte coloreada en rojo de la silueta se le asigna un máximo  $w_j$ , y que se degrada hasta los hitos en azules a los cuales se les asigna un peso menor según corresponda.

imagen digital. El número de partículas  $q$  que contiene el frente de Pareto puede variar de acuerdo al resultado o salida del algoritmo.

Asimismo, las nuevas soluciones del conjunto óptimo de Pareto contienen formas no dominadas por todos los miembros del enjambre y las partículas dominadas son eliminadas de dicho conjunto.

Cada iteración del modelo evolutivo de forma, genera una sucesión de conjuntos óptimos de Pareto que se aproximan a la solución, y que representan un subdominio de formas permitidas.

### Truncamiento a un dominio de formas permitidas

Después de cada iteración del MOPSO y debido al desplazamiento independiente de cada hito  $h_j$ , existe la posibilidad de que algunas partículas  $p_{ij}$  del conjunto óptimo de Pareto puedan perder su vermiformidad. Esto es, que no pertenezcan al dominio de forma permitido  $D_f$ , o en otras palabras, que son siluetas vermiformemente no válidas.

Para subsanar esta situación, al subconjunto de elementos de  $M_i$  que no pertenezcan a un dominio  $D_f$ , es decir los  $e$  se les calcula una forma proyectada  $f_i^b$  en el  $S_{D_f}$  más cercana en forma ( figura 3.28).

Cabe destacar que para aplicar este proceso, los elementos actuales del frente de Pareto son normalizados a la misma escala, rotación y traslación a los centroides. Luego de ser truncados, se devuelven a la escala original.

El proceso de obtención de la nueva forma verme (dada en la sección 3.5) es tal que:

$$\text{trun } f_i^e = f_i^b \quad \text{con } f_i^b \in S_{D_f} \quad (3.43)$$

Cada forma truncada se encuentra en un  $n$ -simplex de  $p$  centroides más cercanos en forma a  $p_{ij}$ . El conjunto total de centroides que determina el subdominio de formas permitido es dado a priori. Con el cambio propuesto en (3.43), se garantiza que el conjunto  $M_i$  posea únicamente elementos pertenecientes a  $D_f$  dados por:

$$M_i := \{ h_{f_{0j}}^b, f_{1j}^b, \dots, f_{q-1j}^b \} \quad (3.44)$$

De igual forma, si la forma resultante tiene mejor la evaluación tanto en longitud y en posicionamiento sobre la original de siluetas, se sustituye por la original, inclusive si la que se sustituyó es forma válida. Las partículas sustituidas son desechadas por el método y esto hace que el modelo no dependa de una cantidad exponencial de datos.

Después de la aplicación de MOPSO, cada forma  $f_i^b$  del frente de Pareto ha mejorado su posicionamiento y la forma respecto a la del nematodo en la imagen digital.

### Evolución del ajuste de la forma a través del método del forrajeo

Subsiguientemente, a cada partícula  $f_i^b$  del frente de Pareto  $M_i$  se aplica el método del forrajeo con el objetivo de mejorar las respectivas posturas de ajuste respecto al nematodo en la imagen digital.

A partir de la aplicación de este método, se le permite a la siguiente iteración del MOPSO buscar en un subdominio restringido de formas vermes o espacio muestral más próximo a la forma verme buscada en la imagen digital.

Luego, a cada elemento de este conjunto se le aplican las dos partes del algoritmo del forrajeo (la búsqueda lateral y el crecimiento), a los fragmentos cola y cabeza de manera

independiente un numero de veces predeterminado.

La primera parte del metodo del forrajeo, ajusta las formas del frente de Pareto por las torsiones laterales independientes de los fragmentos de la cabeza y la cola de  $f_i^b$  (detallado en la seccion 3.4.2).

Con estos movimientos, se genera una sucesion de q formas vermes ( gura 3.33), de las cuales es elegida la que posea mejor metrica de posicionamiento, esto es:

$$\max_{f_i^b} \{ F_{FB}^c f_0^b ; F_{FB}^c f_1^b ; \dots ; F_{FB}^c f_{q-1}^b \} \quad (3.45)$$

para luego reemplazar a  $f_i^b$  en el frente de Pareto.

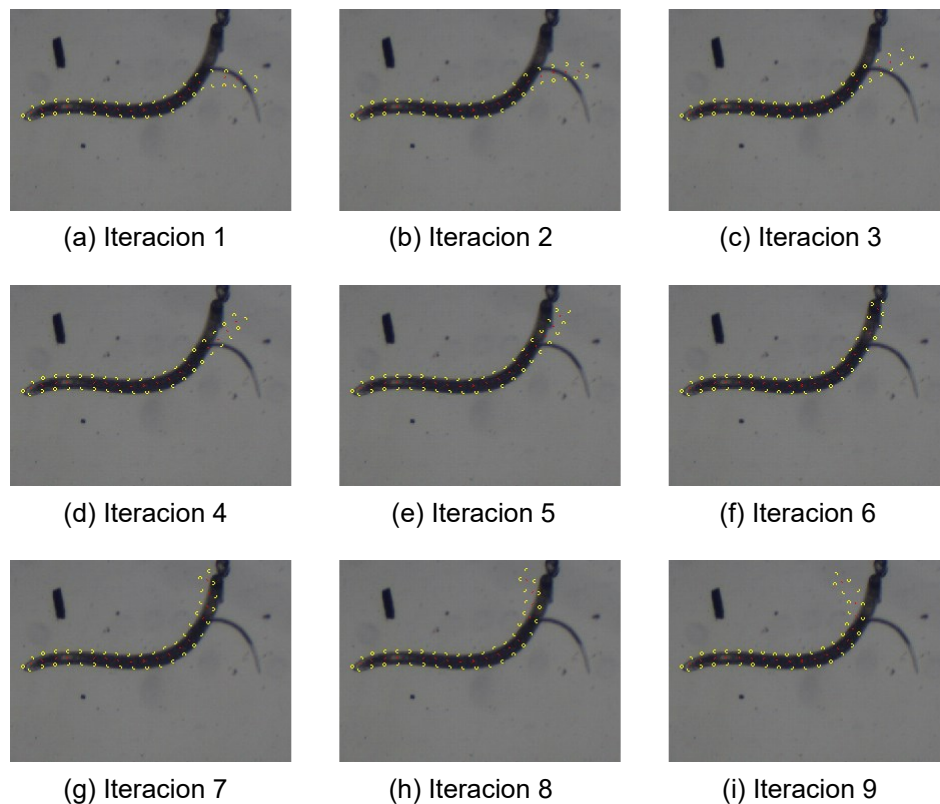


Figura 3.33: Iteraciones de la primera parte del metodo forrajeo para el fragmento cabeza con torsiones laterales. En la iteracion 6, se aprecia que la forma  $f_i^b$  posee mejor metrica de posicionamiento.

La segunda fase del forrajeo es el crecimiento o decrecimiento de la forma  $f_i^b$  dado por el algoritmo que se presenta en la seccion 3.4.3. Para determinar si  $f_i^b$  crece en el fragmento cabeza o cola, se calcula el valor de intensidad del p xel segun la posicion de los hitos y respectivas las vertebras<sup>2</sup>

Posteriormente, se comparan contra un umbral dado a priori que determine un valor

<sup>2</sup>El valor de intensidad del p xel determina si un hito  $h_j$  se ubica en la region interna del cuerpo del nematodo, en el borde o no esta dentro de esta region.

El mite promedio entre el fondo de la imagen digital y cuerpo del objeto a segmentar. Este corresponde a un número real asociado al nivel de intensidad del píxel que provee un valor límite entre el fondo de la imagen y el cuerpo del nematodo, y depende del conjunto de imágenes de entrenamiento y experimentación. En este documento se toma  $\alpha = 0.3$ , en el rango de  $[0;1]$ , como valor promedio de los píxeles del fondo y el cuerpo del nematodo.

Si el valor de intensidad de al menos alguno de los hitos o la vertebras del fragmento es menor al umbral, significa que  $f^b$  se ubica en la región interna del cuerpo del nematodo o en su contorno, por lo que se debe crecer. En caso contrario, no está en la región interna del cuerpo del nematodo, y debería decrecer.




Figura 3.34: Iteraciones de la segunda parte del método forrajeo para el crecimiento del fragmento de la cabeza. Se observa que a partir de la iteración 6, hay un ajuste de forma ideal respecto al crecimiento.

Fin de la  $i$ -ésima iteración del modelo evolutivo de forma

El algoritmo inicia la segunda iteración, al seleccionar al azar algunas partículas  $M_i$  y se construye una base de datos vermes  $BD_2$ . Luego, se reinicia el proceso con  $M_{OPSO}$  y hasta un número de iteraciones  $N_{iter}$  de nido previamente, en la que el método haga converger la deformación de la silueta al nematodo en la imagen digital.

El algoritmo final del proceso completo de modelo evolutivo de forma usando  $M_{OPSO}$  se muestra en la figura 3.35.

La siguiente iteración de modelo evolutivo de forma, elige del conjunto óptimo de Pareto una forma  $f^b_i$  aleatoria para generar una nueva base de datos vermes por medio del método del serpenteo. Los nodos de los subdominios son las instancias vermes contenidas en el frente de Pareto, garantizando que los elementos resultantes en la caminata aleatoria








Figura 3.36: Iteraciones del algoritmo Modelo adaptativo de forma usando M OP SO.

### 3.8. Medida de ajuste a la forma verme

Para medir el ajuste de la silueta  $f_i^b$  al nematodo en la imagen digital, se utiliza el promedio de las distancias  $\delta_2$  entre los hitos de forma verme calculado por MEF y el hito más cercano de la curva interpolante  $C_{Sp}$  generada por los hitos anotados originalmente. Se selecciona como el hito referencia el más cercano perteneciente a la curva trazadora interpolante  $C_{Sp}$  de los  $f_i$  originales, excepto para los hitos numerados 0 y  $n_2$  (correspondiente a cabeza y cola) de la forma obtenida  $f_i^b$ , a los cuales se les calcula la distancia a los hitos numerados 0 y  $n_2$  (correspondiente a cabeza y cola) o  $n_2$  y 0 (correspondiente a cola y cabeza) respectivamente de  $f_i$  original, elegidos según su cercanía: los más próximos (ver figura 3.37).




Figura 3.37: Representación de la medición de los hitos más cercanos al  $f_i^b$  a la silueta original para 40 hitos anotados. Los segmentos coloreados en rojo proveen la distancia entre la curva interpolante dada por los hitos originales y los hitos calculados por MEF (Medida de ajuste a la forma verme).

Cabe destacar que el criterio de cercanía está dado por la menor distancia  $\delta_2$ . En adelante, a esta métrica se le denominará medida de ajuste a la forma verme.

## Capítulo 4

# Resultados experimentales y análisis

En este capítulo se presentan los resultados del método propuesto. En primera instancia, se describen los datos experimentales. Luego, a través de la experimentación con distintas variantes del modelo, se valida el comportamiento del modelo de ajuste de la forma a través de los parámetros de configuración del MEF (número de coordenadas baricéntricas, número de centroides, número de hitos por instancia, adaptabilidad y variabilidad de nuevas formas y número de iteraciones del algoritmo) por medio de la técnica de validación cruzada para  $k$ -iteraciones para  $k = 10$  en todos los casos, y el índice de Jaccard.

Asimismo, la métrica dada en la sección 3.8 se aplica para la evaluación del ajuste de las formas vectoriales versus a las contenidas en las imágenes digitales. En los experimentos referentes a las distancias, estas se miden tomando el píxel como unidad básica de medida. Las bases de datos de imágenes utilizadas con nematodos se detallan en la sección 3.1, y la de formas versus expresadas vectorialmente en hitos se pre-procesaron de acuerdo a los métodos explicados en la sección 3.2. En esta misma sección se detalla la distribución de las longitudes originales de las formas versus.

Además, en todas las fases experimentales, la forma inicial  $f_0^b$  es generada de forma sintética y centrada respecto al centro de masa de la imagen digital. Por consiguiente,  $f_0^b$  se escala a un tamaño de manera que su longitud de esqueleto  $E$  no exceda la mitad del mínimo entre las dimensiones (largo y ancho) de la imagen digital del nematodo a la que se le aplicó el algoritmo.

La evaluación del algoritmo se presenta en cuatro fases: primeramente, en la sección 4.1 se analiza el número de hitos óptimo para la representación vectorial de las formas versus. En la sección 4.2 se analiza el alcance del algoritmo propuesto para generar y emular nuevas formas versus. En la sección 4.3 se explora el número de centroides del dominio de formas y el número de coordenadas baricéntricas necesarias para engendrar los subdominios de forma. Finalmente, en la sección 4.4 se determina la eficacia del algoritmo a través del índice de Jaccard, donde se provee el porcentaje de éxito del algoritmo propuesto. La secuencia del proceso evaluativo se ilustra en la figura 4.1.

Cabe destacar que las pruebas realizadas a nivel de modelo de forma se hicieron con

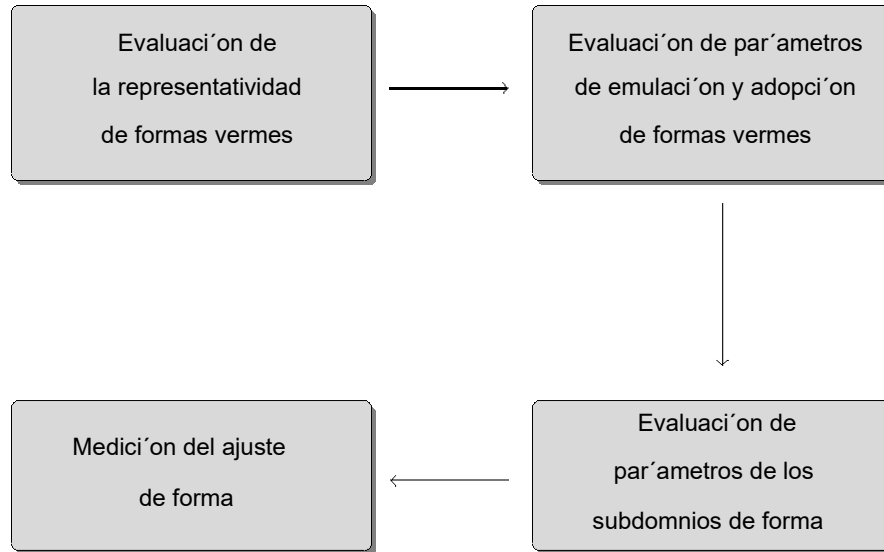


Figura 4.1: Diagrama de flujo de evaluación de las partes del algoritmo MEF.

una base de datos normalizadas de 2744 instancias de nematodos expresadas en hitos de frontera. Asimismo, las pruebas del modelo a nivel de imagen se ejecutaron con una base de datos de 667 imagenes digitales que cumplen las restricciones explicadas en la seccion 3.1.

#### 4.1. Representación vectorial de la forma verme a través de hitos

A partir del proceso de anotación de los hitos en las 667 imagenes digitales, se obtuvieron las siluetas dadas por los  $b_{f_i}$ . Cada una de estas se caracteriza por tener la misma orientación en la secuencia de su anotación (sentido contrario a las manecillas del reloj) y su respectiva forma simétrica.

Para las fases experimentales del MEF, y con el fin de satisfacer las premisas de representatividad propuestas en la seccion 3.2.1, se debe determinar el número mínimo de hitos que en conjunto cubran la totalidad de la silueta y extraigan la mayor información posible del contorno del nematodo.

Para determinar dicho número, se usa la base de datos de formas vermes y la base de datos de imagenes digitales. Se particiona la curva de las silueta vermes en 10, 20, 30, 40, 50 y 60 hitos equidistantes usando el método de trazadores cúbicos interpolantes  $C_{sp}$  para los hitos anotados manualmente. Un ejemplo de las diferentes particiones se aprecia en la figura 4.2.

Para determinar dicho número, se usa la base de datos de formas vermes y la base de datos de imagenes digitales. Se particiona la curva de las silueta vermes en 10, 20, 30, 40, 50 y 60 hitos equidistantes usando el método de trazadores cúbicos interpolantes  $C_{sp}$  para los hitos anotados manualmente. Un ejemplo de las diferentes particiones se aprecia en la figura 4.2.

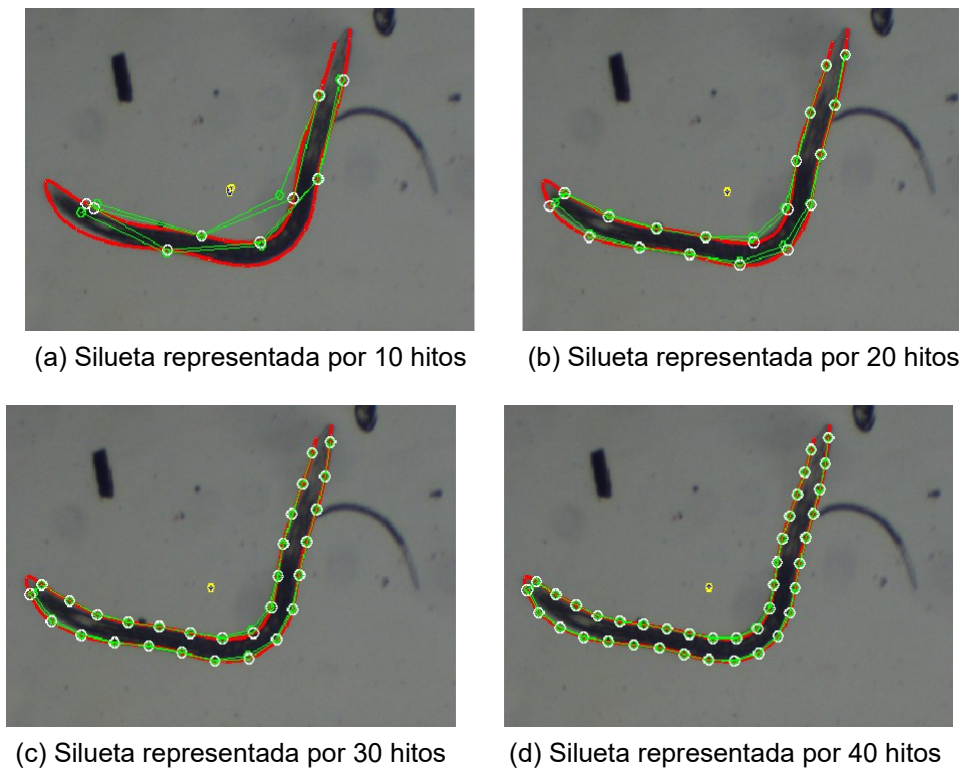


Figura 4.2: Siluetas de un nematodo segmentado por numero de hitos anotados en color verde y su respectiva curva de representacion en color rojo dada por  $C_{sp}$ .

El numero de hitos de  $f_i^b$  ideal se mide a través dos pruebas y tomando como referencia el punto intermedio de cada dos hitos consecutivos  $h_j$  y  $h_{j+1}$  anotados manualmente. En la primera prueba, se promedia la medida de ajuste a la forma verme a cada hito intermedio. En la segunda, se aplica la metrica de bordicidad  $F_B$  con el  $n$  de determinar el mejor ajuste de acuerdo con el numero de hitos. Con estas medidas se determina la cercan a de los hitos intermedios al borde del nematodo en la imagen digital, y en consecuencia, toda la silueta original de  $f_i^b$ .

Los resultados en la gura 4.3 muestran que a menor cantidad de hitos anotados, la distancia entre los hitos intermedio y la curva de representacion verme es en promedio mayor.

Es decir, las representaciones vermes vectoriales con 10, 20, 30 hitos muestran un descenso en la curva de error medio cuadratico de las distancias promedios entre los hitos de la curva  $C_{sp}$  y los calculados. A partir de los 30, se estabiliza la curva y para 40, la distancia promedio es aproximadamente menor que 1 p xel por hito.

En la gura 4.4 se muestran los resultados de la segunda prueba, dejando en evidencia que para 30 hitos o menos, hay perdida de informacion de bordicidad. A partir de los 40 hitos de representacion de la forma verme, la informacion obtenida del contorno es la misma. Para un numero mayor a 40 hitos, proporcionar a informacion redundante.




Figura 4.3: Distancias de los hitos promedio a la curva trazadora. La barra vertical denota la desviación estándar de cada medición promedio.




Figura 4.4: Promedio de la evaluación de la función de bordicida por hito. La barra vertical denota la desviación estándar de cada medición promedio.

De ambas pruebas, se evidencia que con 40 hitos se logra una representación verne de contorno de compromiso aceptable y sin redundancia (gura 4.5). Para las pruebas experimentales subsiguientes, sera tomado dicho numero de hitos por ser el que provee mejor representatividad sin perdida o exceso de informacion.

Cabe destacar el costo asociado al recurso computacional de memoria y complejidad algor tmica crece al menos de forma lineal con el numero de hitos seleccionado. Es decir, a mayor cantidad de hitos se tiene un mayor costo computacional. En consecuencia y segun los resultados obtenidos, la leve mejora que se obtiene para 60 hitos por silueta no justifica su uso, aspecto por el cual se decide trabajar con 40 hitos.




Figura 4.5: Promedio de la evaluación de la función de bordicidad por hito y medida de ajuste a la forma verme al hito intermedio.



## 4.2. Emulacion y adopcion de nuevas formas vermes usando ACP K y MEF

En este apartado, se busca determinar la capacidad del MEF de emular o adoptar cualquier forma de gusano en un dominio de formas validas. El experimento se divide en dos partes.

En la primera se realiza un comparativo entre el modelo ACP K y estimaciones de las coordenadas baricentricas dentro de un n-s mplex a traves del metodo del serpenteo. El objetivo es analizar la capacidad de los metodos de adoptar cualquier deformacion de gusano y mantener su vermiformidad. El proceso se explica en la seccion 4.2.1.

Ademas, El numero de hitos por silueta es 40 debido a los resultados obtenidos en la seccion 4.1.

En la seccion 4.2.2 se detalla la segunda parte de este experimento donde el objetivo es determinar valores espec cos de los parametros del metodo de simulacion de movimientos aleatorios vermes para generar nuevas siluetas vermes a traves de caminatas aleatorias, calculadas a traves de sucesiones de saltos aleatorios entre subdominios vecinos  $S_{Df}$ .

En ambas partes de la experimentacion se utiliza una medida de similitud entre siluetas vermes denominada ndice de cercan a denotado . Esta mide la distancia '2 promedio entre el desplazamiento de hitos respectivos de dos formas vermes  $f_p^b$  y  $f_q^b$ . Viene dada por:

con

$$d(f_p^b, f_q^b) = \frac{1}{n} \sum_{j=0}^{n-1} \|h_{pj} - h_{qj}\|^2 \quad (4.1)$$

$$d(f_p^b, f_q^b) := \frac{1}{n} \sum_{j=0}^{n-1} \|h_{pj} - h_{qj}\|^2 \quad (4.2)$$

En este índice de cercanía se asume que  $f_p^b$  y  $f_q^b$  son previamente normalizadas según el método dado en la sección 3.2.1.

#### 4.2.1. Aproximación de siluetas vermes

El objetivo de esta sección es evaluar la capacidad del modelo de adoptar cualquier silueta de nematodo. Para esta prueba, se parte de la premisa que  $f_a^b$  es próxima o cercana a la forma de la silueta  $f_c^b$  si su índice de cercanía dada en (4.1) es menor a un previamente dado. En los experimentos de esta sección se tomará como 1 por ciento. Para este experimento, se realiza un comparativo entre dos modelos de reconstrucción de formas. La primera es mediante métodos de reducción de dimensionalidad, y la segunda

es mediante combinaciones baricentricas en  $s$  mplexes geometricos por medio del metodo del serpenteo.

Para los metodos de reduccion de dimensionalidad, se analiza la cantidad de componentes principales necesarios para reconstruir una silueta verme usando **ACP** y **ACP K**. En el caso de las combinaciones baricentricas en  $s$  mplexes geometricos, se hace la reconstruccion de las siluetas vermes en subdominios de forma engendrados por nodos calculados por el metodo de los  $K$  vecinos mas cercanos.

En ambos experimentos, se utiliza una muestra de 1000 formas vermes  $f_a^b$  generadas aleatoriamente usando el metodo del serpenteo descrito en la seccion 3.4, normalizadas segun el metodo descrito en 3.2.1, independientes a los individuos que conforman la base de datos de entrenamiento. Los resultados se muestran en las siguientes subsecciones.

### Aproximacion de siluetas vermes usando ACP y ACP K

La reconstruccion de siluetas vermes usando los metodos de reduccion de dimensionalidad explicados en la seccion 2.3 permiten que en un dominio de formas permitidas se pueda reconstruir las siluetas vermes usando una cantidad menor de parametros que moldean su forma dados por los componentes principales. En la gura 4.6 se muestra la reconstruccion de una forma verme usando el metodo **ACP K** para un numero de componentes principales diferente en cada iteracion.

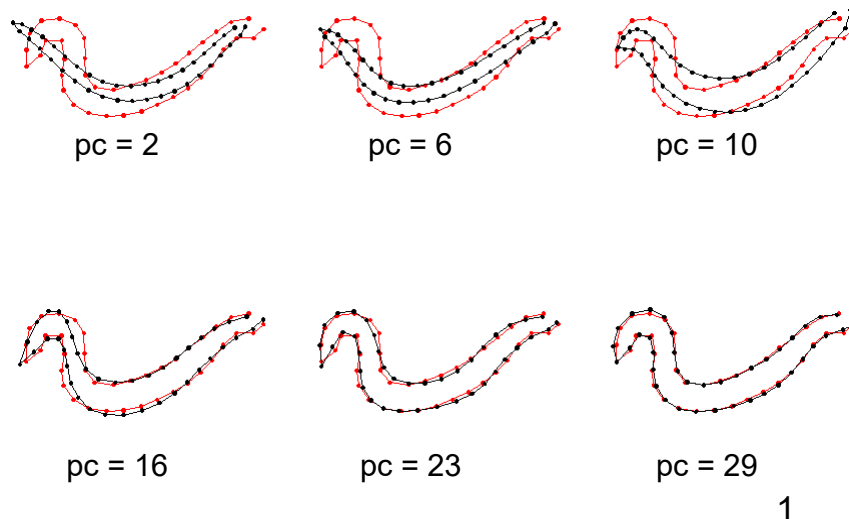


Figura 4.6: Ejemplo de reconstruccion de una silueta de un nematodo usando ACP K con una funcion kernel radial gaussiana. En negro se dibujan las siluetas calculadas en relacion con la cantidad de componentes principales (pc), respecto a la silueta roja.

Cabe resaltar que para la reconstruccion de las siluetas de gusano es necesario que a lo sumo se logre un  $p$  xel de distancia promedio por hitos correspondiente para que el modelo evolutivo de forma no se vea inuenciado por error en el desplazamiento.

En el caso de ACP, se reconstruye la silueta  $f_c^b$  utilizando  $n$  componentes principales obtenidos de la matriz de representacion de la transformacion lineal ortogonal dada por (2.5).

Para el metodo de ACP K, una silueta verme  $f_c^b$  se mapea al espacio caracteristico  $F$  a traves de una funcion kernel dada por  $(f_c^b)$ . Esta a su vez se proyecta a un espacio de menor dimension. El vector  $(f_c^b)$  corresponde al vector proyectado en el espacio de menor dimension.

La preimagen de  $(f_c^b)$  en el espacio de entrada es  $f_a^b$ . Esta se calcula a traves de la variacion del metodo por mapeos conformes explicado en la seccion 2.3.2. El proceso completo del ACP K para las siluetas  $f_c^b$  y  $f_a^b$  se ilustra en la gura 4.7.




Figura 4.7: Diagrama del metodo de ACP K para  $f_c$  y  $f_a$ . En verde se colorea el hiperplano

de proyeccion para  $(f_c^b)$  para un numero  $n$  de componentes principales.  $(f_c^b)$

corresponde al valor proyectado en el dicho hiperplano correspondiente a  $(f_c^b)$ .

Para realizar el analisis comparativo de ambos metodos, es menester primeramente indagar sobre los resultados producidos por las variantes de hiperparametros y funciones kernel en el ACP K. En las funciones kernel polinomial, se estudia el efecto de los hiperparametros como el grado del polinomio  $n$  y el sesgo  $c$ , en el caso de las funciones radial gaussiana y exponencial se hizo con diferentes valores de .

En la gura 4.8 se muestran los resultados de la reconstruccion de las formas respecto a la cantidad de componentes principales y el valor de la funcion kernel proyectiva exponencial. Segun los resultados de la gra ca, la reconstruccion de las formas vermes mejoran con el aumento de la cantidad de componentes principales y del valor . A partir de los 25 componentes principales y  $> 4 \cdot 10^3$ , se logra reconstruir la forma verme con una distancia menor a  $2 p$  xeles promedio entre hitos correspondientes de las formas calculadas y aproximada.

En la gura 4.9 se muestran los resultados del metodo ACP K con la funcion kernel radial gaussiana. Al igual que el caso anterior, se muestra una tendencia de reconstruccion

menor a un pixel de distancia entre hitos correspondientes a partir de los 23 componentes principales y para  $> 3:5 \cdot 10^3$ .

En el caso de las funciones kernel polinomiales, se evalua el comportamiento de la reconstruccion de las siluetas vermes para los hiperparametros  $c$  y  $n$  respecto al numero de las componentes principales. Los resultados mostrados en 4.10 indican que el polinomio con  $n = 1$  aproxima mejor que el caso de  $n = 2$ . El valor de  $c$  no presenta variacion.




Figura 4.8: Medicion de los componentes principales usando como kernel la funcion proyectiva exponencial  $\exp(hx_j; x_{ji}=(2^2))$  para valores de .

Para todas la variantes del ACP K analizadas, se logra una reconstruccion de la forma verme a partir de 23 componentes principales. El mejor resultado se obtuvo para la fun-cion kernel polinomial usando  $n = 1$ , con menos de dos p xeles de distancia entre hitos respectivos.

Consiguientemente, los resultados de la aplicacion de los metodos ACP y ACP K para la reconstruccion de la forma verme se muestran en la gura 4.11. En esta se muestra el metodo ACP tiene un leve mejor a que el ACP K para la reconstruccion de las formas vermes cuando  $p_c < 10$ ; sin embargo, la distancia entre sus hitos respectivos es mayor que 4 p xeles.

Por otra parte, tanto para ACP como para ACP K se necesitan al menos 20 componentes principales para reconstruir la silueta con al menos 1 p xel de distancia entre sus hitos, es decir, al menos un 25 % de los componentes principales son necesarias para reconstruir las siluetas en forma de gusano.

En este mismo analisis, es preciso resaltar que a partir de los 20 componentes principales no hay diferencias signi cativas entre ambos metodos pues aproximadamente hay un p xel de diferencia entre los hitos respectivos, haciendo que los metodos se comporten de manera similar sin diferencias signi cativas.




Figura 4.9: Medicion de los componentes principales usando como kernel la funcion radial gaussiana  $\exp(-kx_i x_j k^2 = (2^2))$  para valores de .

Asimismo, tanto en ACP como ACP K, la reconstruccion de la silueta depende de un numero de componentes principales. Esto es, que entre mayor sea el numero de componentes entonces mejor sera el numero su reconstruccion.

Por otra parte, para el ACP K se experimenta sobre el efecto que produce el error intrinseco inducido por la busqueda de la preimagen en el proceso iterativo de ajuste respecto al cambio en la forma del nematodo o la perdida de la vermiformidad. El objetivo es analizar la estabilidad del metodo. Para esto se mide la distancia promedio por hito de una forma inicial  $f_c^b$  a cada elemento de la sucesion  $f_0^b; f_1^b; \dots; f_m^b$ .

La sucesion de formas vermes es obtenida a traves un proceso iterativo del ACP K. El proceso inicia eligiendo una forma verme calculada  $f_c^b$  la cual corresponde al primer termino de la sucesion  $f_0^b$ . A esta se le calcula su imagen en el espacio caracteristico  $F$  a traves de la funcion kernel polinomial. Luego, se proyecta al espacio de menor dimension y posteriormente se calcula su preimagen  $f_a^b$  en el espacio de entrada para  $n$  componentes principales.

La forma  $f_a^b$  se asigna a  $f_1^b$  que corresponde al segundo termino de la sucesion. El proceso se repite sustituyendo  $f_1^b$  por  $f_c^b$ , por  $n$  iteraciones hasta obtener la sucesion deseada. Los resultados se exhiben en la gura 4.12 y muestran el promedio de las distancias entre hitos correspondientes para  $f_i^b$  por  $f_c^b$  con  $1 \leq i \leq 7$ .

Los resultados muestran que el indice de cercan a de la forma calculada y cada una de las formas aproximadas de la sucesion generada por el ACP K tienen un aumento abrupto.



(a)  $n = 1$ .(b)  $n = 2$ .

Figura 4.10: Distancia promedio entre hitos respectivos usando la función kernel polinomial  $(hx_j; x_{ji} + c)^n$  para valores de  $c$ .

Es decir, en la sexta iteración para 25 componentes principales la distancia entre hitos se ha degenerado por más de 34 pxeles. Un efecto similar sucede para las otras mediciones de componentes principales mostradas en la gráfica. Lo anterior permite concluir con el ACP K, que el error derivado del cálculo de la preimagen provoca una pérdida de forma




Figura 4.11: Distancia promedio por hito entre f




Figura 4.12: Iteraciones continuas del ACP K para componentes principales con el kernel polinomial. Cada iteracion corresponde a una forma verme calculada.

de la silueta original.

Finalmente, se evaluo respecto el metodo del ACP K y del serpenteo sucesiones de formas y su ndice de cercan a respecto al nematodo mas cercano contenido en el subdominio de forma mas cercano. Se utilizo el ndice de cercan a para la forma calculada y la pertenece-ciente al dominio de forma mas cercano. Los resultados se muestran en la gura 4.13.

En este se muestra que el metodo del serpenteo promedia entre 3 y 5 p xeles de ndice de cercan a a partir de la quinta iteracion. Contrariamente, el metodo de ACP K aumenta la distancia promedio a mas de 30 p xeles entre hitos respectivos. En consecuencia, muchas de las part culas no son vermiformemente validas.



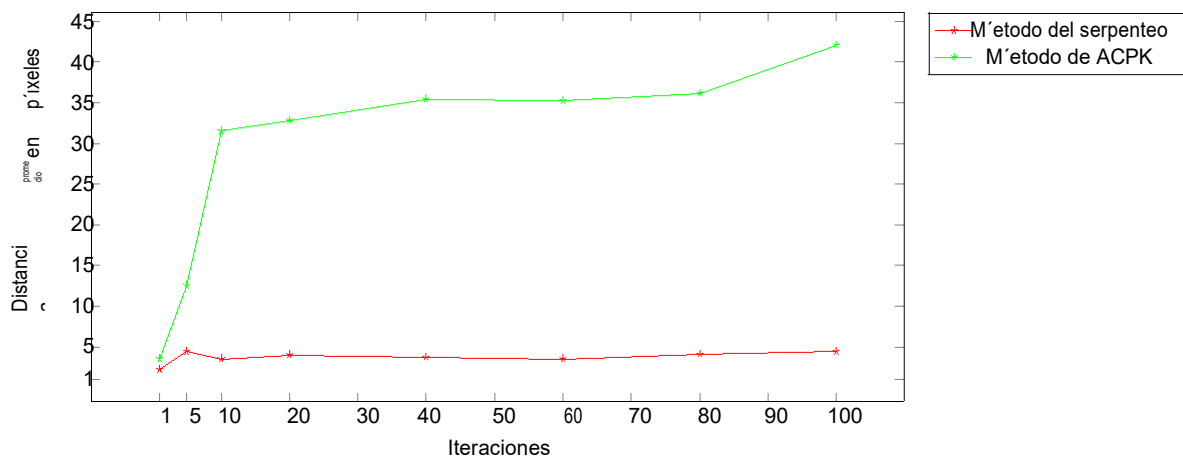


Figura 4.13: Promedio del índice de cercanía entre formas calculadas con los métodos ACPK con kernel polinomial y el método del serpiente, respecto a la forma vermiculada calculada perteneciente al subdominio de forma más cercano. Los subdominios de forma se calcularon con 10 nodos.

Finalmente, se concluye que el método del serpiente logra conservar la vermiformidad entre sucesiones a través de caminatas aleatorias. En la aplicación sucesiva del método ACPK, se degrada la vermiformidad de las siluetas llegando a perderla.

#### Aproximación de siluetas vermes a través del método Serpiente

La segunda prueba muestra que cualquier forma vermiculada  $f_a^b$  puede ser aproximada en algún subdominio  $SD_f$ . Se parte de la premisa que  $f_a^b$  es vermiformemente válida si existen  $f_0; f_1; \dots; f_k$  tales que la engendran o la aproximan a un  $SD_f$  como una combinación lineal baricéntrica basada en la ecuación de los simplex geométricos dada en (2.38).

El experimento de aproximación de cualquier forma vermiculada  $f_a^b$  se divide en dos etapas. En la primera, se determina el  $SD_f$  al cual pertenece. Y la segunda etapa calcula las coordenadas baricéntricas que mejor aproximan la forma en dicho subdominio.

El proceso se inicia calculando el conjunto de los vecinos más cercanos  $f_0^b; f_1^b; \dots; f_{k+1}^b$  a  $f_a^b$  utilizando FLANN (Muja y Lowe, 2009), ordenados según su lejanía. Luego, se centra el conjunto sobre  $f_0^b$  donde  $f_0^b$  es un elemento de la forma:

$$f_i^b := f_i^b - f_0^b \quad (8i; 0 \leq i \leq n+1) \quad (4.3)$$

El  $SD_f$  es generado por los  $k$  vecinos resultantes:

$$\{f_1^b; f_2^b; \dots; f_{k+1}^b\} \quad (4.4)$$

La segunda parte es fundamentada por una variación del método dado por matching pursuit usado en este contexto (Donoho et al., 2012). En esta se aproximan las coordenadas

baricentricas:

$$= [1; 2; \dots; k+1] \quad (4.5)$$

que determinan el  $S_{Df}$  a través de la ecuación:

$$f_a^b = 1f_1^b + 2f_2^b + \dots + kf_k^b + (k+1)f_{k+1}^b = f_c^b \quad (4.6)$$

donde cada coordenada baricentrica se trunca al intervalo  $[0;1[$  mediante:

$$i = \min(1; \max(0; i)) \quad (4.7)$$

bajo la restricción:

$$\sum_{i=1}^{k+1} i = 1 \quad (4.8)$$

Además, para la caracterización de las formas  $f_c^b$  y las respectivas  $f_a^b$  se utiliza la distancia '2' resultante del promedio entre las de los hitos respectivos de ambas siluetas.

Esta caracterización mide las distancias de similitud entre  $f_c^b$  y  $f_a^b$ . Se evalúa la distancia promedio en función de la cantidad de centroides con el  $n$  de analizar la mejora en la aproximación de la silueta. Los resultados se muestran en la figura 4.14.

En el caso de 100 centroides para 1000 formas vermes, la curva muestra que el ajuste presenta un comportamiento errático: la curva no sigue una tendencia de nida entre creciente y decreciente. Esto indica que en algunos casos se ajusto mejor y en otros no, independientemente del número de nodos que conforman el  $n$  s mplex.

Lo anterior se debe a que en esta iteración se cuenta con una menor cantidad de centroides, haciendo que cada  $f_a^b$  sea engendrada por nodos más lejanos entre sí. Si los nodos son más lejanos, serán menos similares en su forma, y por lo tanto, se provoca que la forma aproximada dependa de que tan cercano sean a uno o varios nodos del  $n$  s mplex.

Asimismo, hay una tendencia de mejora en la aproximación  $f_c^b$  sobre  $f_a^b$  cuando aumenta el número de centroides que determinan los  $S_{Df}$ . Desde una partición con 300 centroides del  $D_f$  para formar los  $S_{Df}$ , se muestra que aproximadamente la distancia por hito entre las siluetas original y calculada es menor a 1 píxel promedio. Así, si hay un número mayor de nodos, estos serán más cercanos en forma, y por lo tanto, mejorar el cálculo de su aproximación.

Se concluye que, es posible aproximar cualquier silueta verme a través de este método, usando un número de centroides representativo con 10 nodos para engendrar los subdominios de forma.




Figura 4.14: Distancia promedio por hito entre  $f_c^b$  y  $f_a^b$  en un  $S_{Df}$  de  $k$  nodos.

Por otro lado, aunque ambos metodos: por reduccion de dimensionalidad (ACP y ACP K) y por aproximacion de siluetas vermes en un subdominio de forma, logran reconstruir las formas vermes, este ultimo reconstruye la forma con errores de aproximadamente 1 pixel por hito para al menos 100 centroides y 10 nodos para la generacion de subdominios de forma.

#### 4.2.2. Variabilidad de formas

En la aplicacion del metodo de emulacion y adopcion de nuevas formas vermes se logran conseguir nuevos conjuntos de siluetas de gusano de  $n$  individuos cercanos en forma y pertenecientes a subdominios  $S_{Df}$  que pueden competir contra otros no dominados por el frente de Pareto en el MEF.

Para obtener un nuevo conjunto de siluetas vermes con dicha caracteristicas, se analiza la generacion de nuevas formas vermes a traves de cambios de la forma entre saltos sucesivos de subdominios  $S_{Df}$  para un numero de centroides y nodos dados, con el indice de cercania dado en (4.1).

Tanto el numero de centroides, nodos y el intervalo de restriccion  $I$ , se obtienen de los resultados de la gura 4.15. En esta se usa  $N_{iter} = 1000$  iteraciones del algoritmo dado en la gura 3.20 para  $S_{Df}$  de nidos para  $k = 5; 10; 20; ; 100$  vertices de dimension de la variedad topologica 80 dimensiones y centroides de nidos para un numero total de multiplos de 100 calculados sobre la base de datos de 2744 formas vermes usando el metodo  $k$  vecinos mas cercanos.

El resultado con rma la correlacion existente entre el numero de vertices que conforman los  $S_{Df}$  y los cambios de forma, es decir, a mayor numero de nodos las deformaciones son mayores.

Entre mayor es la cantidad de vertices que pueda seleccionar el algoritmo en forma aleatoria para construir el siguiente subdominio  $S_{Df}$ , entonces la distancia entre los hitos correspondientes a dos deformaciones sucesivas es en promedio mayor.

Cj \ Nodos	5	10	20	30	40	50	60	70	80	90	100
200	9.234	10.912	12.290	14.024	13.299	14.149	15.740	14.748	16.111	17.904	16.833
300	9.772	11.263	12.270	12.142	13.477	15.999	16.252	16.175	17.001	17.576	18.475
400	8.734	10.261	11.417	12.571	13.813	13.415	15.108	15.911	16.614	17.124	17.395
500	8.870	10.999	11.530	11.955	12.223	13.122	14.145	14.925	16.685	18.693	18.583
600	7.647	9.9830	11.314	12.416	13.591	14.164	14.560	15.969	16.823	19.612	20.405
700	7.683	9.5160	11.193	12.497	12.639	13.226	12.569	14.097	15.279	16.482	19.400
800	6.232	9.0780	10.791	12.318	12.559	13.558	13.182	13.921	14.517	14.568	17.801
900	6.283	9.3140	11.217	12.206	13.095	14.642	14.992	15.347	15.927	16.359	19.029
1000	6.483	9.2060	10.794	12.207	13.324	14.218	15.074	15.902	16.522	16.791	18.385

Figura 4.15: Distancias promedio de hitos respectivos entre  $f_i$  y  $f_{i+1}$  de una serie simulada de movimientos vermes segun los  $C_j$  y nodos del  $S_{Df}$ , usando 1000 iteraciones.

Aunado a esto, si el numero de vertices del  $S_{Df}$  es 5, el desplazamiento de los hitos es menor a 8 p xeles en promedio, lo que exhibe baja variabilidad promedio de cambios independientemente del numero de centroides.

Si se elige un numero mayor a 40 nodos para formar los  $S_{Df}$ , las deformaciones seran abruptas y se perdera la nocion de continuidad de la simulacion, pues se puede llegar a un desplazamiento aproximado de 13 o mas p xeles por hito, independientes del numero de centroides.

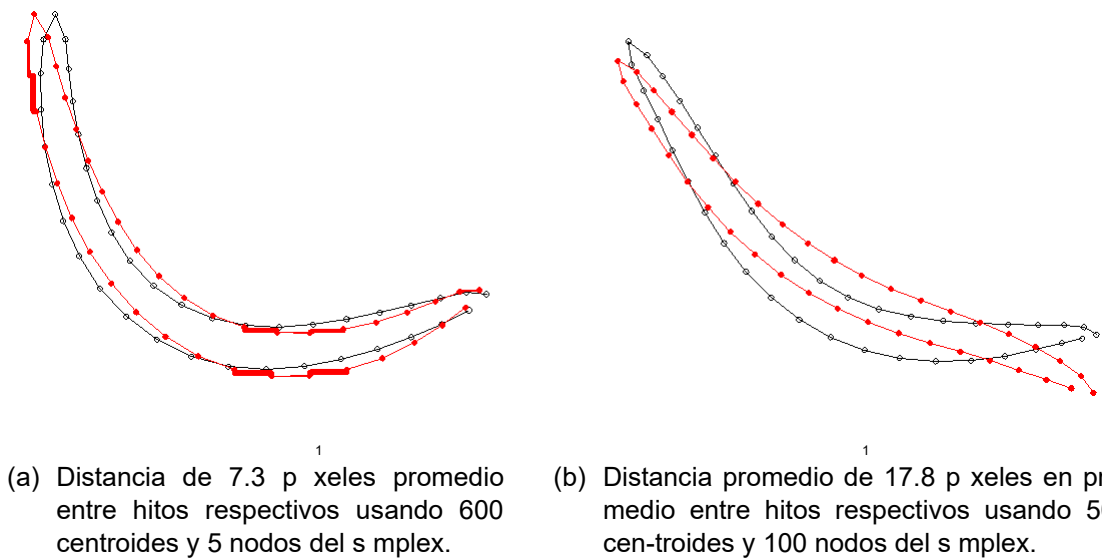


Figura 4.16: En la imagen se presenta la silueta de dos formas de gusano de dos iteraciones se-guidas extra das de una sucesion simulada de formas vermes. Se mide la distancia entre los hitos respectivos.

Un conjunto de deformaciones recorridas en secuencia y que permitan la simulacion en tiempo real oscila entre 10 y 30 nodos por  $S_{Df}$  cuya distancia entre hitos sera aproxi-madamente de 10 a 12 p xeles en promedio, por lo que  $l = [10;12]$ .

### 4.3. Ajuste de los parametros del MEF

A partir de la forma inicial  $f_0^b$ , MEF aproxima las siluetas pertenecientes al conjunto optimo de Pareto a la forma verme deseada en el  $D_f$ . Dicha convergencia es determinada por dos variables asociadas a la constitucion de los subdominios de formas:

- Numero de centroides del dominio de formas  $D_f$ .
- Numero de nodos que determinan cada subdominio  $S_{Df}$ .

Ambas variables en conjunto, determinan la variabilidad de las formas en los subdominios, y por ende, la generacion de nuevas formas vermes dadas por el modelo. Las secciones 4.3.1 y 4.3.2 muestran el efecto de la distancia entre los vertices que determinan cada subdominio, y el numero de nodos que los generan.

Primeramente, se analiza cada una de las variables dejando ja la otra variable, para determinar el efecto aislado de cada una en el modelo. En la seccion 4.3.3 se explora de manera conjunta el efecto de ambas variables.

En todos los experimentos de esta seccion, se utilizo la tecnica de validacion cruzada para  $k = 10$  particiones (seccion 2.9.1).

#### 4.3.1. Numero de particiones sobre el dominio de forma $D_f$

En este experimento, se evalua el efecto en el MEF cuando se aumenta o disminuye la cantidad de centroides calculados sobre el dominio  $D_f$ , con los cuales se obtienen los nodos de los n-s mplexes.

Se desea determinar un numero adecuado de centroides optimo sobre el dominio de formas vermes para ser aplicados en los metodos de truncamiento (ver seccion 3.5) y serpenteo (ver seccion 3.4). En el MEF, se experimenta con un numero jo de 10 nodos por subdominio de forma  $S_{Df}$  y para 50, 100, 150, 250 y 300 centroides que engendran el dominio de forma.

Se tom el promedio de las distancias de la medida de ajuste a la forma verme entre los hitos calculados y anotados. Los resultados se muestran en la gura 4.17.

Los resultados muestran que a partir de 8 iteraciones del MEF, el modelo converge a un promedio entre 4 y 6 p xeles aproximadamente de la silueta calculada respecto a la que pertenece la imagen digital.

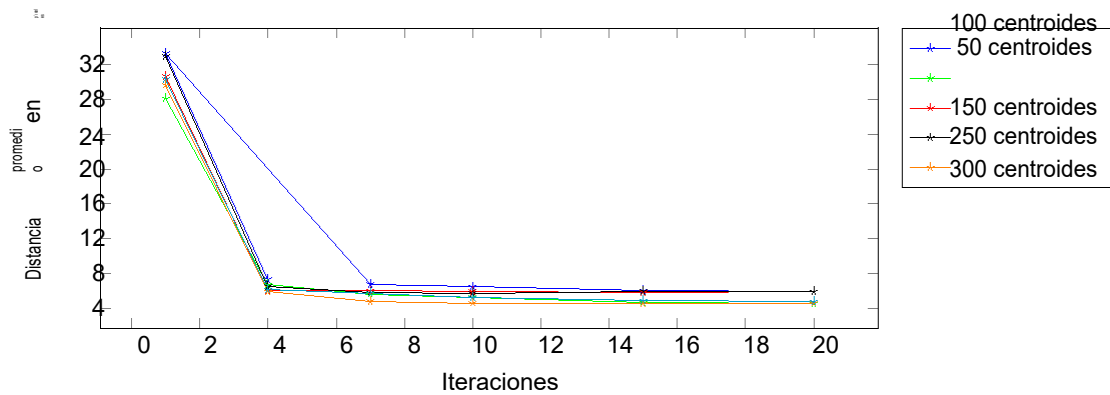


Figura 4.17: Iteraciones del MEF por numero de centroides para engendrar subdominios de  $n = 10$  nodos en cada subdominio de forma. La distancia promedio por hito es menor que 8 a partir de 10 iteraciones.

Debido a lo anterior, el algoritmo muestra que para 10 iteraciones del MEF y 100 centroides, el algoritmo provee una distancia promedio entre los hitos dados y calculados dentro del rango posicionamiento valido.

#### 4.3.2. Dimension de los subdominios de forma $SD_f$

En este apartado se evalua el numero optimo de nodos que conforman los subdominios de forma  $SD_f$  para ser aplicados en el MEF.

Para este experimento se utiliza un numero  $j_0$  de 100 centroides y se analiza el comportamiento para subdominios conformados por 5, 10, 15, 20 y 25 nodos. Ademas, se usa la medida de ajuste a la forma verne dada en la seccion 3.8 entre las distancias entre los hitos de las siluetas de formas vernes calculadas por el MEF y las anotadas respectivamente de manera manual. Asimismo, se calcula la ra z del error medio cuadratico (REMC) de las medidas obtenidas para este analisis. Los resultados se muestran en la gura 4.18 con un numero  $j_0$  de 10 iteraciones del MEF.




Figura 4.18: Numero de nodos de cada subdominio de forma.

Los resultados muestran que para subdominios conformados por 10 nodos disminuye el

promedio hasta alcanzar el mínimo de las distancias por hito entre la silueta calculada y la curva de representación.

Además, estos mismos reejan que si se disminuye o aumenta el número de coordenadas baricentricas que conforman cada subdominio  $S_{Df}$  aumenta dicho promedio, y por lo tanto, el ajuste a la forma verme empeora.

Lo anterior se explica debido a que, al utilizar un número menor de nodos, estos son más cercanos en forma entre sí, con lo cual en el espacio de conformación de nuevas formas vermes se generan siluetas de mayor similitud, o bien, el subdominio tiende a disminuir el rango de variabilidad, aspecto por el cual, los métodos de truncamiento y serpenteo trabajaran con espacios de menor variabilidad y no logran alcanzar el objetivo de ajuste.

En caso contrario, si la cantidad de nodos de cada subdominio de forma es un número mayor a 10, entonces aumenta el promedio de las distancias entre las formas generadas en dichos subdominios. Por consiguiente, los subdominios están conformados por los nodos más lejanos entre sí, aumentando la variabilidad en la generación de formas vermes.

Una consecuencia directa de estos resultados en el MEF, es que los métodos del serpenteo y truncamiento trabajaran en espacios de mayor variación, lo que desemboca en una mayor cantidad de iteraciones de búsqueda y ajuste para lograr el objetivo  $n_{iter}$ .

En ambos casos con 10 iteraciones del MEF y con un número mayor o menor a 10 coordenadas baricentricas no se alcanza el objetivo de ajuste.

### 4.3.3. Vertices y particiones sobre el dominio de forma

Para analizar el efecto en conjunto sobre el número de centroides del dominio de formas

y número de nodos que determinan cada subdominio, respecto a los resultados obtenidos en las secciones 4.3.2 y 4.3.1, se ejecuta MEF para medir el ajuste a la forma verme de los nematodos en las imágenes digitales.

Se mide la distancia entre la curva de representación verme y los hitos calculados usando 10 iteraciones y el método validación cruzada. Los resultados se exhiben la figura 4.19.

Los resultados con  $n_{man}$  que la mejor asignación es 10 coordenadas baricentricas para conformar los subdominios de forma  $S_{Df}$  y una partición de 100 centroides, pues se logra que en promedio haya una distancia de ajuste sobre la curva de representación verme de aproximadamente 6 píxeles por hito que está dentro del rango de ajuste óptimo.

## 4.4. Medición del ajuste de la forma verme

La medición del ajuste de la forma verme al nematodo en la imagen digital se realizó mediante el índice de Jaccard (sección 2.9.2). Este coeficiente permite determinar una




Figura 4.19: Resultado de 10 iteraciones, variando el numero de coordenadas baricentricas que determinan los subdominios de forma y el numero de centroides de particion del dominio de forma. Se midio la distancia entre la curva de representacion y los hitos calculados por el MEF.

metrica de acierto sobre ajuste de las siluetas  $f_i^b$  respecto a las referencias dadas. Se denota  $J(A_a; A_c)$  y se calcula como el cociente de las cardinalidades de los conjuntos de las areas de interseccion y union de  $A_a$  y  $A_c$ , dada por:

$$J_{a c} = \frac{\text{card}(A_a \cap A_c)}{\text{card}(A_a \cup A_c)} \tag{4.9}$$

Para realizar dicha medicion, se tom como region verdadera y calculada las areas de las siluetas de las formas vermes delimitadas por los hitos anotados  $A_a$  ( gura 4.20b), y la de los hitos calculados  $A_c$  ( gura 4.20c). Se resalta que el area de cada region corresponde a la cantidad de p xeles que contiene. Los resultados obtenidos se promediaron y clasificaron segun el coe ciente  $J(A_a; A_c)$  en clases segun la tabla 4.1.

Asimismo, los resultados obtenidos en las secciones 4.3 y 4.1 fueron aplicados: siluetas formadas por 40 hitos de frontera, particion de 100 centroides del  $C^b$  para engendrar los subdominios  $S_{Df}$ , 10 vertices o nodos para generar  $S_{Df}$  y  $N_{iter} = 10$  iteraciones del algoritmo del MEF.

Tabla 4.1: Tabla de particiones para ndice de Jaccard  $J(A_a; A_c)$ .



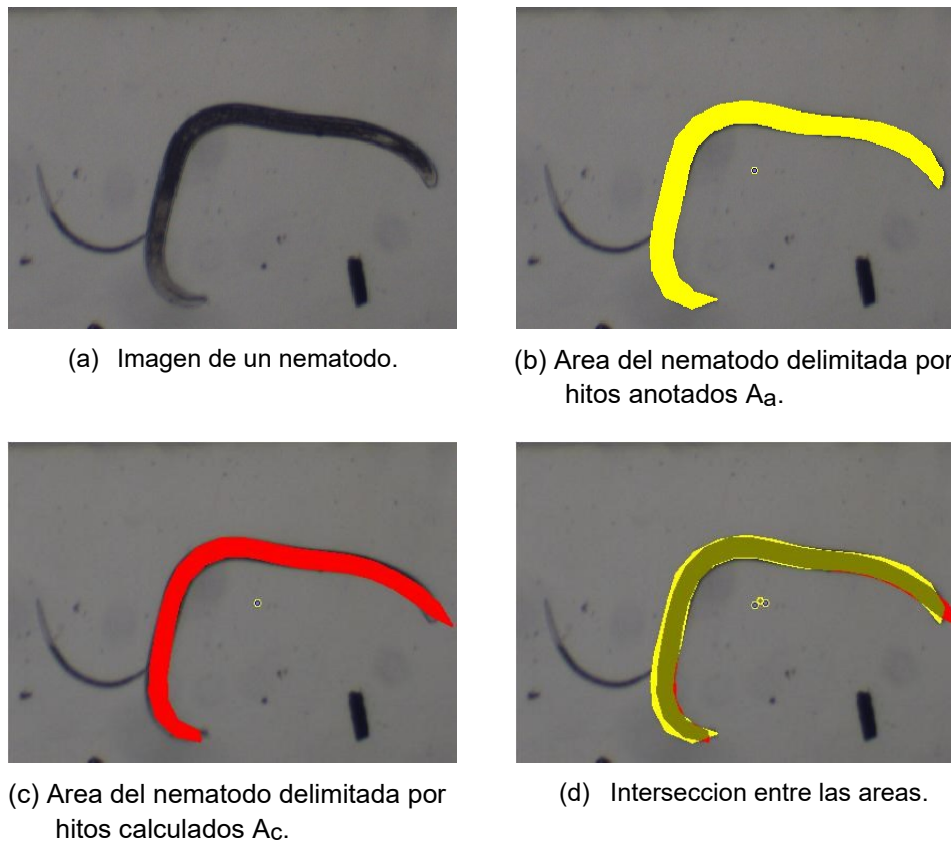


Figura 4.20: Regiones verdadera, calculada y su interseccion segun el resultado final de la aplicacion del MEF utilizadas para el calculo del  $J (A_a;A_c)$ .

Clases	$J (A_a;A_c)$
$a_1$	$J < 0:2$
$a_2$	$0:2 \quad J < 0:4$
$a_3$	$0:4 \quad J < 0:6$
$a_4$	$0:6 \quad J < 0:8$
$a_5$	$0:8 \quad J$

En la gura 4.21 se ilustran los resultados con imagenes de las areas resaltadas y sus respectivos ndices de Jaccard. Se observa tambien que a partir de de la clase  $a_3$ , el MEF ajusta de forma verme similar a la silueta de nematodo a la que se encuentra en la imagen digital.

Los resultados obtenidos en este experimento se muestran en el histograma normalizado de la gura 4.22. Las muestras clasi cadas en las clases  $a_4$  y  $a_5$  muestran un ajuste aceptable respecto a la silueta del nematodo, aunque de igual forma es afectada por el posicionamiento de los hitos anotados. No obstante, las formas vermes contenidas en la clase  $a_2$  en su mayor a recuperan parte de la forma del nematodo que son afectadas por detritos presentes en la imagen digital, aunque parcialmente se recupera su forma. Las formas vermes pertenecientes a la  $c_1$  son fracasos del algoritmo ( gura 4.23).

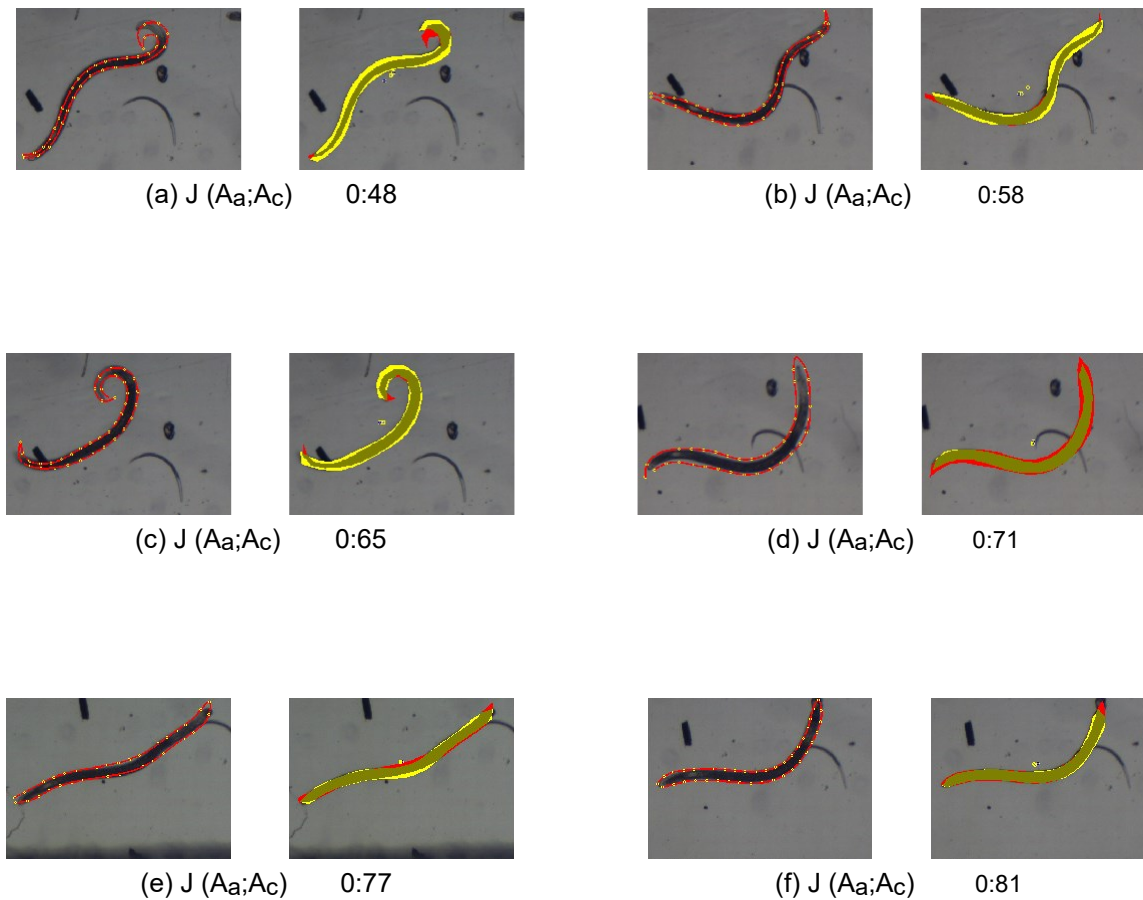


Figura 4.21: Ejemplos de la aplicacion del MEF con su respectivo ndice de Jaccard. En cada caso, la imagen digital de la izquierda muestra el resultado nal del MEF y, en la de la derecha se resalta en amarillo el area de la forma verme de hitos anotados as como con rojo el area de la forma obtenida por el modelo propuesto. En el color verde musgo se muestran las intersecciones entre las areas resaltadas por rojo y amarillo.

Cabe destacar que los hitos anotados que forman las siluetas vermes de la base de datos de entrenamiento se ubican en el rango de posicionamiento valido de nido en la seccion 4.1 el cual indica que puede existir hasta 6 p xeles de diferencia entre posiciones dadas por el algoritmo MEF y la manual. Ademas, existe un error de posicionamiento asociado al error humano.

El modelo elige otras posiciones de los hitos af n en ubicacion pero no coincidente con la de la base de datos de entrenamiento. Debido a esto, los resultados son afectados por dicha diferencia a nivel de contorno. En la sub guras 4.21a y 4.21b se observan estos errores, aunque los resultados nales coinciden con la silueta del nematodo en la imagen digital.

Finalmente, del modelo evolutivo de forma constituido por el M OP SO y los metodos del forrajeo y serpenteo logran un porcentaje de exito para el ndice de Jaccard sobre las clases a3, a4 y a5 del 90.56 %. Las instancias que parcialmente capturan su forma asciende





Figura 4.22: Resultado del aplicacion del MEF por clases segun la tabla 4.1.



(a) J (A<sub>a</sub>;A<sub>c</sub>) 0:28

Figura 4.23: Imagenes del resultado nal del MEF de la clase a2.

a un 4.29 % del total. El algoritmo no logra su cometido en un 5.15 % de las instancias vermes utilizadas.

Aunque los tiempos de respuesta no se evaluaron, como referencia en promedio un ajuste de forma del MEF con 5 iteraciones dura aproximadamente 72.2 segundos con una desviacion estandar de 6.83.

# Capítulo 5

## Conclusiones

Este trabajo propone un metodología de ajuste de formas vermes expresadas en vectores de hitos en imágenes digitales. Consiste en un proceso de optimización multiobjetivo apoyado de dos procesos intermedios de deformación: serpeo y forrajeo. El serpeo emula formas vermes usando caminatas aleatorias entre subdominios de forma válidos y el forrajeo contorsiona los fragmentos cola y cabeza de las siluetas de los nematodos. Estos procesos permiten un aceleramiento de búsqueda de las partículas del frente de Pareto que son determinados por dos funciones objetivo: una ajuste de forma y otra de tamaño de la silueta. Ambas normalizadas con una función sigmoide. Finalmente, se utiliza los métodos de validación cruzada e índice de Jaccard para la evaluación del método propuesto.

La principal contribución de este trabajo es la propuesta de una estrategia de ajuste de siluetas vermes basado en un proceso iterativo de optimización que permite hallar, en el dominio de formas permitidas vermes, la mejor adaptación de la silueta del nematodo en las imágenes digitales.

Asimismo, la estrategia utilizada se fundamenta en dos criterios de adaptación de las formas. El primer criterio de mejor adaptación es referido a la obtención de la forma a través de un método adaptativo de movimientos corporales vermes. Este fue logrado mediante el método de optimización MOPSO asistido por dos subfases: el método del serpeo y el método del forrajeo.

El segundo criterio es dado el truncamiento de las formas vermes resultantes a dominios de forma permitidos. El modelo de optimización se encarga de ajustar en forma y en posición las partículas de forma de gusano. La decisión es guiada por las funciones de bordicidad y longitud verme que evalúan y determinan la mejor posición y postura de cada una de las partículas del frente de Pareto.

Asimismo, el método del forrajeo interviene después de cada iteración del MOPSO como ayudante en el ajuste de forma a las partículas. Los trozos cabeza y cola son tratados en este método individualmente permitiendo un mejor ajuste. Las elongaciones y deformaciones laterales son evaluadas también por la función de bordicidad. De forma paralela, el método de truncamiento no permite la pérdida de la vermiformidad en el proceso evolutivo

de ajuste de forma.

En este mismo criterio, se enfatiza que la descripción y deformación de las siluetas debe ser a través de un conjunto limitado de parámetros de forma. Aquí el objetivo es cumplido, primeramente por la estrategia de representación y luego por el método de emulación de nuevas formas vermes.

Cada nematodo es representado ecientemente por un conjunto reducido de 40 hitos de frontera que, en conjunto, moldean su silueta y logran extraer toda la información a nivel de contorno requerida para el modelo.

Asimismo se comprueba que, a través de la selección de caminatas aleatorias entre  $S_{Df}$

vecinos y un número adecuado de coordenadas baricéntricas dado por el método del serpiente, se logra emular cualquier secuencia de movimientos vermiformes de forma aleatoria, permitiendo y generando representaciones de nuevas formas vermes.

De igual manera, este método permite generar, e inclusive, describir de forma paramétrica formas vermes permitidas en  $S_{Df}$  no determinados por centroides de la base de datos.

Otra contribución de este trabajo es el método del serpiente. Este permite la generación de movimientos vermes simulados y continuos a través de secuencias de siluetas de nematodos creados artificialmente por medio de caminatas aleatorias entre subdominios de forma.

El tercer criterio de mejor adaptación indica que el modelo sea capaz de ajustarse a la información presente en la imagen digital. Bajo las restricciones dadas, y por el método-log a empleada en el MEF, se logra que la influencia de todo el ruido presente no fuera determinante en el modelo. A pesar de que en este trabajo, las imágenes digitales con las que se experimento contienen escenas ruidosas, llenas de artefactos e incluso presencia de múltiples individuos vermes en algunos casos, se logra ajustar la silueta al nematodo en imágenes digitales. Aunado a esto, la única operación de imágenes empleada es el cálculo

del gradiente por medio del método OGD que determina la razón de cambio entre el fondo de la imagen digital y el cuerpo del nematodo. La evaluación de la medida óptima de borde-longitud permite al MOPSO el posicionamiento y adopción de la silueta de ajuste natural de la forma de nematodo.

Es preciso destacar que no se utilizó ninguna operación morfológica de imágenes digitales ni operaciones asociadas a los canales de colorimetría. Esto permite que el modelo sea adaptable a casi cualquier tipo de imagen digital que cumpla con las restricciones mencionadas.

Finalmente, el cuarto criterio se refiere a que el algoritmo sea capaz de discernir si la silueta ajustada a la imagen digital corresponde efectivamente a un nematodo. Para esto, se evaluaron todas las partes y procedimientos asociados al algoritmo MEF dando certeza del cumplimiento de este en todos los objetivos planteados inicialmente.

Además, esta etapa permitió ajustar los criterios sobre los valores parametrizables, tales como el número de coordenadas baricéntricas que determinan los subdominios de forma, número de centroides, número de coordenadas que representan cada deformación verme.

Por ultimo, la evaluacion realizada sobre los conjuntos de entrenamiento y validacion de 667 imagenes digitales determinan un 90.56 % de exito en el ajuste de la forma, asegurando que el desarrollado es robusto y ajustable a cualquier silueta verme en una imagen digital segun las restricciones a lo largo de esta investigacion. Lo anterior, es sujeto a la distribucion de formas que se describieron en la seccion 3.2.

Como resultado nal del MEF, se favorece la compresion de los datos permitiendo describir de forma parametrica un nematodo a traves de sus hitos de frontera. Ademas, este modelo logra eliminar la redundancia del conjunto de datos y permite mejorar procesos de visualizacion de los datos a un menor costo computacional.

Finalmente, la evaluacion del algoritmo evidencia de manera objetiva, que la solucion propuesta es satisfactoria ante el problema en cuestion, y con esto, se logra demostrar la hipotesis de investigacion as como el cumplimiento a cabalidad de los objetivos principal y secundarios planteados.

#### Trabajo futuro

A futuro, se recomienda continuar el trabajo en otro tipo de deformaciones ajustables para clasi cacion y posicionamiento en v deo digital, y con imagenes digitales con diferentes tipos de resoluciones. Asimismo, queda como trabajo venidero, modi car el metodo con otros procesos de optimizacion multiobjetivo con el n de comparar cual se ajusta mejor a la metodolog a empleada en esta investigacion.

Ademas, por la forma de trabajo empleada en el modelo evolutivo de forma, este puede ser replicado a otros tipos de elementos estructurales en imagenes digitales cuyas deformaciones no sigan distribuciones normales con el n de robustecer y ampliar el espectro de este metodo. Ademas, aplicarle el metodo con otras distribuciones de longitudes de nematodos diferentes a las que se realizaron en este trabajo.

Aunque el objetivo principal de este trabajo es la elaboracion del modelo de forma, ser a importante replicar el MEF con otros conjuntos de imagenes digitales que se incluyan diferentes resoluciones de las imagenes digitales de nematodos con el n ejempli car y profundizar el analisis de los resultados.

Por otra parte, el metodo de trabajo de simulacion de movimientos vermiformes mediante traslado aleatorio entre  $S_{Df}$  vecinos funciona como generador de formas, por lo que puede ser replicado, integrado y hasta extendido a distintos escenarios y modelos aplicados a la segmentacion y clasi cacion de cuerpos que son alterados por transformaciones continuas en espacios topologicos.

# Bibliografía

- Abbass, H. A., Sarker, R. & Newton, C. (2001). PDE: a Pareto-frontier differential evolution approach for multi-objective optimization problems, En **Proceedings of the 2001 Congress on Evolutionary Computation (IEEE Cat. No. 01TH8546)**. IEEE.
- Albrecht, T., Luthi, M. & Vetter, T. (2009). Deformable Models. En **Encyclopedia of Biometrics** (pp. 210-215). Boston, MA, Springer US. [https://doi.org/10.1007/978-0-387-73003-5\\_88](https://doi.org/10.1007/978-0-387-73003-5_88)
- Alvarado, P., Doerer, P. & Wickel, J. (2001). Axon2{a visual object recognition system for non-rigid objects, En **Proceedings International Conference on Signal Processing, Pattern Recognition and Applications (SPPRA)**.
- Arroyo, J. (2016). Dimensionality Reduction Methods: Comparative Analysis of methods PCA, PPCA and KPCA. **Uniciencia**, 30 (1), 115-122. <https://doi.org/10.15359/ru.30-1.7>
- Arroyo, J. & Alvarado, J. (2020). Simulación de movimientos vermiformes mediante caminatas aleatorias entre n-s mplex vecinos. **Revista Tecnología En Marcha**, 33 (2), 54-66.
- Arroyo, J. & Alvarado, J. (2014). A new variant of Conformal Map Approach method for computing the preimage in Input Space. **Recent Advances in Computer Engineering, Communications and Information Technology**, 301-304.
- Association, A. W. W. Et al. (2004). **Problem Organisms in Water: Identification and Treatment**{Manual of Water Supply Practices M7. American Water Works Association, Denver.
- Atkinson, K. E. (2008). **An introduction to numerical analysis**. John Wiley & Sons.
- Berman, M., Rannen Triki, A. & Blaschko, M. B. (2018). The lovasz-softmax loss: a tractable surrogate for the optimization of the intersection-over-union measure in neural networks, En **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**.

- Bernard, G. C., Egnin, M. & Bonsi, C. (2017). The Impact of Plant-Parasitic Nematodes on Agriculture and Methods of Control. En *Nematology-Concepts, Diagnosis and Control*. Intechopen.
- Berry, M. W., Mohamed, A. & Yap, B. W. (2019). *Supervised and Unsupervised Learning for Data Science*. Springer.
- Bogale, M., Baniya, A. & DiGennaro, P. (2020). Nematode Identification Techniques and Recent Advances. *Plants*, 9 (10), 1260.
- Bongers, T. & Ferris, H. (1999). Nematode community structure as a bioindicator in environmental monitoring. *Trends in Ecology & Evolution*, 14 (6), 224-228.
- Boyd, S. & Vandenberghe, L. (2004). *Convex optimization*. Cambridge University Press.
- Brown, S., Pedley, K. C. & Simcock, D. C. (2016). Estimation of surface area and volume of a nematode from morphometric data. *Scientia*, 2016.
- Carr, H., Snoeyink, J. & van de Panne, M. (2010). Flexible isosurfaces: Simplifying and displaying scalar topology using the contour tree. *Computational Geometry*, 43 (1), 42-58.
- Chen, M., Correa, C., Islam, S., Jones, M. W., Shen, P.-Y., Silver, D., Walton, S. J. & Willis, P. J. (2007). Manipulating, deforming and animating sampled object representations, En *Computer Graphics Forum*. Wiley Online Library.
- Chew, L. P. (1989). Constrained delaunay triangulations. *Algorithmica*, 4 (1-4), 97-108.
- Coello, C. A. C., Pulido, G. T. & Lechuga, M. S. (2004). Handling multiple objectives with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 8 (3), 256-279.
- Cootes, T. F., Taylor, C. J., Cooper, D. H. & Graham, J. (1995). Active Shape Models - Their Training and Application. *Computer vision and image understanding*, 61 (1), 38-59.
- Cootes, T. F. & Taylor, C. J. (1993). Active Shape Model Search using Local Grey-Level Models: A Quantitative Evaluation., En *BMVC*. Citeseer.
- Costa, C., Antonucci, F., Pallottino, F., Aguzzi, J., Sun, D.-W. & Menesatti, P. (2011). Shape analysis of agricultural products: a review of recent research advances and potential application to computer vision. *Food and Bioprocess Technology*, 4 (5), 673-692.



- Coto, G. R. (2007). **Conceptos introductorios a la topología**. Costa Rica, EUNED.
- Currie, M., Cantarelli, M., Idili, G. & Larson, S. (2014). OpenWorm: an open-science approach to modeling **Caenorhabditis elegans**. *Frontiers in Computational Neuroscience*, **8** (137), 2194-2232.
- Cury, C. (2015). **Statistical shape analysis of the anatomical variability of the human hippocampus in large populations**. (Tesis doctoral). Université Pierre et Marie Curie-Paris VI.
- Delingette, H. (1999). General object reconstruction based on simplex meshes. *International Journal of Computer Vision*, **32** (2), 111-146.
- Donoho, D. L., Tsai, Y., Drori, I. & Starck, J.-L. (2012). Sparse solution of underdetermined systems of linear equations by stagewise orthogonal matching pursuit. *IEEE Transactions on Information Theory*, **58** (2), 1094-1121.
- Dorer, P. & Alvarado, P. (2006). LTI-Lib { a C++ Open Source Computer Vision Library. En K.-F. Kraiss (Ed.), **Advanced Man-Machine Interaction. Fundamentals and implementation** (pp. 399-421). Berlin Heidelberg, Springer Verlag.
- Duran-Mora, J. (2018). **Estudio poblacional y alternativas de control para el nematodo nodulador en tomate (solanum lycopersicum l.) en la zona occidental de Costa Rica** (Tesis para optar el grado de Doctor en Ciencias Naturales para el Desarrollo, con énfasis en Sistemas de Producción Agrícola). Doctorado en Ciencias Naturales para el Desarrollo. <https://repositoriotec.tec.ac.cr/handle/2238/10656>.
- Eberhart, R. & Kennedy, J. (1995). A new optimizer using particle swarm theory, En **MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science**. IEEE.
- Elías, I. (2014). La estrategia competitiva del sector agrario a través de la innovación y desarrollo. **Cuadernos de Investigación EPG**.
- Esquivel, A. (2011). **Nematodos como indicadores ambientales**. Costa Rica: Universidad Nacional. <https://repositorio.una.ac.cr/bitstream/handle/11056/7460/Nematodos%20como%20indicadores%20ambientales.pdf?sequence=1>
- Esquivel, A. & Peraza, W. (2009). **Nematodos toparasitos asociados a cultivos agrícolas en Costa Rica**. Escuela de Ciencias Agrarias, Universidad Nacional.
- Farin, G. (1983). Algorithms for rational Bezier curves. *Computer-aided design*, **15** (2), 73-77.

- Foley, T. A. & Nielson, G. M. (1989). Knot selection for parametric spline interpolation. En *Mathematical methods in computer aided geometric design (261-CP4)*. Elsevier.
- Friedman, J., Hastie, T. & Tibshirani, R. (2001). *The elements of statistical learning (Vol. 1)*. Springer series in statistics New York.
- Gallagher, T., Bjorness, T., Greene, R., You, Y.-J. & Avery, L. (2013). The geometry of locomotive behavioral states in *C. elegans*. *PLoS one*, 8 (3), e59865.
- Garza-Hume, C., Jorge, M. C. & Olvera, A. (2018). Areas and Shapes of Planar Irregular Polygons, *En Forum Geometricorum*.
- Geng, W., Cosman, P., Berry, C., Feng, Z. & Schafer, W. (2004). Automatic tracking, feature extraction and classification of *C. elegans* phenotypes. *IEEE Trans. Biomed. Eng.*, 51, 1811-1820.
- Geron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.
- Gomez, O. (2009). *Segmentación de nematodos en imágenes digitales usando redes neuronales (Tesis para optar al grado de Magister Scientiae en Computación)*. Instituto Tecnológico de Costa Rica. Costa Rica.
- Gonzalez, R. & Woods, R. (2008). *Digital Image Processing (Third Edition)*. Pearson Prentice Hall.
- Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning* [<http://www.deeplearningbook.org>]. MIT Press.
- Gruner, M. (2015). *Active Dictionary Models: A framework for non-linear shape modeling (Tesis para optar al grado de Magister Scientiae en Computación)*. Escuela de Ingeniería Electrónica. Instituto Tecnológico de Costa Rica. Cartago, Costa Rica.
- Harary, F. & Yan, H. (1990). Logical foundations of kinematic chains: Graphs, line graphs, and hypergraphs. *Journal of Mechanical Design - Transactions of the ASME*, 112, 79-83.
- Hernandez, R. & Torres, C. P. M. (2018). *Metodología de la investigación (Vol. 4)*. McGraw-Hill Interamericana.
- Hidalgo, M. G., Torres, A. M. & Gomez, J. V. (2012). *Deformation Models: Tracking, Animation and Applications (Vol. 7)*. Springer Science & Business Media.

- Holden, D., Saito, J. & Komura, T. (2016). A deep learning framework for character motion synthesis and editing. *ACM Transactions on Graphics (TOG)*, 35 (4), 1-11.
- Honeine, P. & Richard, C. (2011). Preimage Problem in Kernel-Based Machine Learning. *IEEE Signal Process*, 77-88.
- Huang, K.-M., Cosman, P. & Schafer, W. (2008). Automated Detection and Analysis of Foraging Behavior in *C. elegans*. *Image Analysis and Interpretation*, 2008. SSIAI 2008. IEEE Southwest Symposium on.
- Huang, Q.-X., Wicke, M., Adams, B. & Guibas, L. (2009). Shape decomposition using modal analysis, *En Computer Graphics Forum*. Wiley Online Library.
- Jahne, B. (2005). *Digital Image Processing 6th Edition*. Berlin [u.a.], Springer.
- Jimenez, J. (2019). SegNema: Nematode segmentation strategy in digital microscopy images using deep learning and shape models (Tesis para optar al grado de Magister Scientiae en Computacion). Escuela de Ingenieria en Computacion. Tecnologico de Costa Rica. Cartago, Costa Rica.
- Juhasz, Z. & Zelei, A. (2013). Analysis of worm-like locomotion. *Periodica Polytechnica Mechanical Engineering*, 57 (2), 59-64.
- Jukna, S. (2011). *Extremal combinatorics: with applications in computer science*. Springer Science & Business Media.
- Kamilaris, A. & Prenafeta-Boldu, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90.
- Kenney, E. & Eleftherianos, I. (2016). Entomopathogenic and plant pathogenic nematodes as opposing forces in agriculture. *International Journal for Parasitology*, 46 (1), 13-19. <https://doi.org/10.1016/j.ijpara.2015.09.005>
- Lawler, G. F. & Limic, V. (2010). *Random walk: a modern introduction (Vol. 123)*. Cambridge University Press.
- Lee, H., Grosse, R., Ranganath, R. & Ng, A. Y. (2009). Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations, *En Proceedings of the 26th annual international conference on machine learning*.
- Lee, J. A. & Verleysen, M. (2007). *Nonlinear dimensionality reduction*. Springer Science & Business Media.
- Levinson, N. & Redheffer, R. M. (1975). *Curso de variable compleja*. Revert .

- Liakos, K. G., Busato, P., Moshou, D., Pearson, S. & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18 (8), 2674.
- Lindenbaum, O., Stanley, J., Wolf, G. & Krishnaswamy, S. (2018). Geometry Based Data Generation, En *Advances in Neural Information Processing Systems*.
- Litany, O., Bronstein, A., Bronstein, M. & Makadia, A. (2018). Deformable shape completion with graph convolutional autoencoders, En *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Liu, J., Pan, Y., Li, M., Chen, Z., Tang, L., Lu, C. & Wang, J. (2018). Applications of deep learning to MRI images: A survey. *Big Data Mining and Analytics*, 1 (1), 1-18.
- Livingstone, D. J. (2008). *Artificial neural networks: methods and applications*. Springer.
- Loop, C., Schaefer, S., Ni, T. & Castano, I. (2009). Approximating subdivision surfaces with Gregory patches for hardware tessellation. En *ACM SIGGRAPH Asia 2009 papers* (pp. 1-9).
- Marín, J. (2009). *Ubicación de un Nematodo en Imágenes Digitales Utilizando el Algoritmo de Modelos Activos de Forma* (Tesis para optar al grado de Licenciatura). Instituto Tecnológico de Costa Rica. Costa Rica.
- Marler, R. T. & Arora, J. S. (2004). Survey of multi-objective optimization methods for engineering. *Structural and multidisciplinary optimization*, 26 (6), 369-395.
- Masci, J., Meier, U., Ciresan, D. & Schmidhuber, J. (2011). Stacked convolutional autoencoders for hierarchical feature extraction, En *International conference on artificial neural networks*. Springer.
- Mesejo, P., Ibanez, O., Cordon, O. & Cagnoni, S. (2016). A survey on image segmentation using metaheuristic-based deformable models: state of the art and critical analysis. *Applied Soft Computing*, 44, 1-29.
- Mora, S. (2019). *Informe Comercio Exterior del Sector Agropecuario (2017 { 2018) (inf. tec.)*. SEPSA. Costa Rica. <http://www.sepsa.go.cr/>
- Muja, M. & Lowe, D. G. (2009). Fast Approximate Nearest Neighbors with Automatic Algorithm Configuration, En *International Conference on Computer Vision Theory and Application VISSAPP'09*, INSTICC Press.
- Nalepa, J. & Kawulok, M. (2014). Fast and accurate hand shape classification, En *International conference: beyond databases, architectures and structures*. Springer.

- Nutanong, S., Zhang, R., Tanin, E. & Kulik, L. (2010). Analysis and evaluation of v\*-knn: an efficient algorithm for moving knn queries. *The VLDB Journal*, 19 (3), 307-332.
- Piegl, L. & Tiller, W. (1995). *The NURBS book* (monographs in visual communications)(1997, 646 p). New York: Springer, ISBN.
- Ponce, J., Chelberg, D. & Mann, W. B. (1989). Invariant properties of straight homogeneous generalized cylinders and their contours. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (9), 951-966.
- Pratt, L. & Rivera, L. (2003). *Tendencias en el Desarrollo de la Agricultura en Centroamerica: Nuevos Retos para el Sector Privado y el Dise~no de Pol ticas Publicas* (inf. tec.). Centro Latinoamericano de Competitividad y Desarrollo Sostenible CLACDS { INCAE.
- Pu, Y., Gan, Z., Henao, R., Yuan, X., Li, C., Stevens, A. & Carin, L. (2016). Variational autoencoder for deep learning of images, labels and captions, En *Advances in neural information processing systems*.
- Puckering, T., Thompson, J., Sathiyamurthy, S., Sukumar, S., Shapira, T. & Ebert, P. (2017). Automated wormscan. *F1000Research*, 6.
- Qing, F., Yu, X. & Jia, Z. (2019). A robust MOF method applicable to severely deformed polygonal mesh. *Journal of Computational Physics*, 377, 162-182.
- Rahman, M. A. & Wang, Y. (2016). Optimizing intersection-over-union in deep neural networks for image segmentation, En *International symposium on visual computing*. Springer.
- Raiko, T., Valpola, H. & LeCun, Y. (2012). Deep learning made easier by linear transformations in perceptrons, En *Artificial intelligence and statistics*.
- Real, R. & Vargas, J. M. (1996). The Probabilistic Basis of Jaccard's Index of Similarity. *Systematic Biology*, 45 (3), 380-385.
- Refaeilzadeh, P., Tang, L. & Liu, H. (2009). Cross-Validation. En L. LIU y M. T. OZSU (Eds.), *Encyclopedia of Database Systems* (pp. 532-538). Boston, MA, Springer US. [https://doi.org/10.1007/978-0-387-39940-9\\_565](https://doi.org/10.1007/978-0-387-39940-9_565)
- Restif, C. & Metaxas, D. (2008). Tracking the swimming motions of *C. elegans* worms with applications in aging studies, En *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer.

- Rizvandi, N., Pizurica, A. & Philips, W. (2008). Machine Vision Detection Of Isolated And Overlapped Nematode Worms Using Skeleton Analysis. Image Processing, 2008. ICIP 2008. 15th IEEE International Conference on, 2972-2975.
- Rizvandi, N., Pizurica, A., Philips, W. & Ochoa, D. (2008). Edge Linking Based Method to Detect and Separate Individual C. Elegans Worms in Culture. Computing: Techniques and Applications, 2008. DICTA '08. Digital Image, 65-70.
- Sadrnia, H., Rajabipour, A., Jafary, A., Javadi, A. & Mosto , Y. (2007). Classification and analysis of fruit shapes in long type watermelon using image processing. Int. J. Agric. Biol, 1 (9), 68-70.
- Scholkopf, B., Mika, S., Smola, A., Ratsch, G. & Muller, K.-R. (1998). Kernel PCA pattern reconstruction via approximate pre-images, En International Conference on Artificial Neural Networks. Springer.
- Scholkopf, B., Smola, A. & Muller, K.-R. (1998). Nonlinear component analysis as a kernel eigenvalue problem. Neural computation, 10 (5), 1299-1319.
- Sedgewick, R. & Wayne, K. (2011). Algorithms. Addison-Wesley Professional.
- Sethian, J. (1999). Level Set Methods and Fast Marching Methods: Evolving Interfaces in Computational Geometry, Fluid Mechanics, Computer Vision, and Materials Science. Cambridge University Press.
- Shlens, J. (2009). A Tutorial on Principal Component Analysis. Center for Neural Science, New York University y Systems Neurobiology Laboratory, Salk Institute for Biological Studies.
- Sonka, M., Hlavac, V. & Boyle, R. (2014). Image processing, analysis, and machine vision. Cengage Learning.
- Suprem, A., Mahalik, N. & Kim, K. (2013). A review on application of technology systems, standards and interfaces for agriculture and food sector. Computer Standards & Interfaces, 35 (4), 355-364.
- Szeliski, R. & Tonnesen, D. (1992). Surface modeling with oriented particle systems, En Proceedings of the 19th annual conference on Computer graphics and interactive techniques.
- Terzopoulos, D. & Metaxas, D. (1991). Dynamic 3D models with local and global deformations: Deformable superquadrics. IEEE Transactions on Pattern Analysis & Machine Intelligence, (7), 703-714.

- Terzopoulos, D., Platt, J., Barr, A. & Fleischer, K. (1987). Elastically Deformable Models. SIGGRAPH Comput. Graph., 21 (4), 205-214. <https://doi.org/10.1145/37402.37427>
- Van Bezooijen, J. (2006). Methods and techniques for nematology. Wageningen University Wageningen, The Netherlands.
- Van Der Maaten, L., Postma, E. & Van den Herik, J. (2009). Dimensionality reduction: a comparative. J Mach Learn Res, 10 (66-71), 13.
- Wagsta , K., Cardie, C., Rogers, S., Schrod, S. Et al. (2001). Constrained k-means clustering with background knowledge, En ICML.
- Wilder, J., Feldman, J. & Singh, M. (2011). Superordinate shape classification using natural shape statistics. Cognition, 119 (3), 325-340.
- Willmott, C. J. & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. Climate research, 30 (1), 79-82.
- Wilson, M. & Kakouli-Duarte, T. (2009). Nematodes as environmental indicator. CABI.
- Woess, W. (2000). Random walks on infinite graphs and groups (Vol. 138). Cambridge University Press.

# Apendice A

## Herramienta de segmentacion manual para hitos de frontera

Herramienta de segmentacion de hitos fue implementada para el proceso de investigacion. En las etapas del proceso, se ha llevado numerosas tareas agrupadas con el n de cubrir las especi caciones descritas en el anteproyecto de investigacion.

Para satisfacer los requerimientos para la construccion de la base de datos, la herramienta permite cargar una imagen digital y anotar los hitos de frontera sobre el contorno del elemento estructural de forma que en conjunto simulan la silueta del organismo.

Despues del posicionamiento del primer hito en la imagen, se esbozan segmentos de aproximacion continuos entre cada par de puntos automaticamente. Cada punto se une al anterior y con el sucesor a traves de dichos segmentos. Cada hito puede ser movido para ajustar el contorno, y si es necesario, se puede incluir nuevos hitos entre los ya colocados con el n de ajustar mejor la silueta formada. Ademas, la herramienta permite anotar los hitos mas proximos a la cabeza y cola.

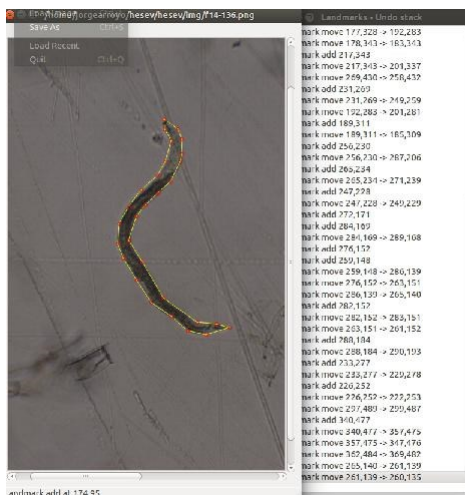


Figura A.1: Secuenciacion de hitos en una imagen usando HESEV.



# Indice alfabético

- modelo evolutivo de forma, 64
- Normalizacion de la base de datos, 42
- Adaptacion a la forma verme, 67
- Ajuste de forma usando el MOPSO, 65
- Ajuste de los parametros del MEF, 90
- Alineacion y escalado, 45
- Alineamiento de formas vectoriales, 26
- Analisis de componentes principales con kernel, 18
- Analisis de Procrusto, 28
- Aproximacion de siluetas vermes, 79
- Aproximacion de siluetas vermes usando ACP y ACPK, 80
- Aproximacion de siluetas vermes usando sub-dominio de forma, 86
- Base de datos de imagenes digitales de ne-matodos, 40
- Caminatas aleatorias, 30
- Componentes principales, 18
- Componentes principales no lineales, 18
- Conjunto de entrenamiento, 41
- Coordenadas baricentricas, 30
- Deformabilidad verme, 79
- Deformaciones del esqueleto, 52
- Deformaciones vermes de crecimiento y decrecimiento, 56
- Deformaciones vermes oscilantes de cola y cabeza, 53
- Delimitaciones al alcance de la investigacion, 8
- Dominancia de Pareto, 31
- Dominancia debil, 31
- Dominio y subdominio de formas vermes, 47
- Evolucion de forma a traves del metodo del forrajeo, 68
- Fin de la i-esima iteracion del MEF, 71
- Frente de Pareto optimo, 31
- Funciones objetivo, 58
- Funcion verme de distancia, 59
- Funcion Gaussiana, 61
- funcion Sigmoide, 58
- Funcion verme de borde, 60
- Funcion verme de distancia, 59
- Generacion de formas vermes en un  $S_{Dr}$ , 49
- Herramienta de segmentacion manual para hitos de frontera, 109
- Hipotesis, objetivos y estructura del documento, 6
- Imagen digital, 17
- Imagenes digitales y gradiente direccional, 17
- Interpolacion polinomica parametrica, 28
- Introduccion, 1
- Marco teorico, 11
- Medicion del ajuste de la forma verme, 92
- Medida de ajuste a la forma verme, 73
- Medida optima de borde-longitud, 65
- Modelos activos de forma, 26
- Modelos de distribucion de puntos, 26
- Modelos de forma basados en aprendizaje profundo, 24

- Modelos de forma basados en hitos de frontera, 25
- Modelos deformables, 22
- Metodo de pre procesamiento de formas vermes, 46
- Metodo de deformacion de nematodos: forrajeo , 52
- Metodo del forrajeo, 52
- Metodo del serpenteo, 46
- Metodos de reduccion de dimensionalidad, 18
- Normalizacion por simetría de forma, 46
- Numero de coordenadas baricentricas de sobre cada subdominio de forma  $S_{Df}$  , 91
- Numero de hitos por estancia segmentada, 43
- Numero de particiones sobre el dominio de forma  $D_f$  , 90
- Optimizacion multiobjetivo, 30
- Optimizacion por enjambre de part culas, 32
- Optimizacion por enjambre de part culas multiobjetivo, 34
- Orientacion en la secuencia de los hitos, 42
- Posicionamiento inicial de  $f_0^b$ , 66
- Problema de la preimagen, 20
- Representacion vectorial de la forma vermes a traves de hitos, 75
- Resultados, 97
- Resultados experimentales y analisis, 74
- Simulacion de movimientos aleatorios vermes, 49
- Subdominio de formas permitidas, 47
- S mplexes geometricos, 29
- Transformacion a escala de grises, 17
- Truncamiento a un dominio de formas permitidas, 68
- Truncamiento de part culas en un  $S_{Df}$  , 57
- Validacion cruzada de k-iteraciones, 36
- Variabilidad de formas, 88
- Vector gradiente direccional, 17
- Vectores decision, 31
- Vectores objetivo, 32
- Vectores ortogonales de borde, 61
- Vectores tangenciales de borde, 60
- Vertices y particiones sobre el dominio de forma , 92
- Indice de Jaccard, 36
- ndice de cercan a, 79