


FIBRAS COLOREADAS II



NÉSTOR CLAVIJO MELLI
HERIC MARTÍNEZ CAÉTANO
NICOLÁS MENONI BÉRTIZ
ESTEBAN SALVO DONANGELO



ORIENTADOR: PABLO CANCELA

FACULTAD DE INGENIERÍA - INSTITUTO DE INGENIERÍA ELÉCTRICA
UNIVERSIDAD DE LA REPÚBLICA - URUGUAY
AGOSTO DE 2006

Resumen

Existen diferentes características que determinan la calidad de la lana. Una de ellas es la presencia de fibras coloreadas, éstas son fibras de lana con una pigmentación diferente a la habitual, generalmente oscuras. La lana que contiene una alta proporción de fibras coloreadas no puede ser utilizada en la confección de prendas claras, debido a que dichas fibras mantienen su coloración original luego del proceso de teñido, limitando su acceso a mercados exigentes.

La lana producida en Uruguay contiene una alta proporción de fibras coloreadas en relación a otros países tradicionalmente dedicados a la producción lanera (Australia, por ejemplo). Motivados por esto, en Uruguay se están realizando diferentes esfuerzos para solucionar esta problemática. En Facultad de Ingeniería se ha trabajado en la detección automática de fibras coloreadas, teniendo como objetivo a largo plazo realizar dicha detección en una etapa previa al procesamiento industrial de la lana.

Como la detección de fibras coloreadas en lana sin procesar es un problema complejo, se fijan pasos intermedios. Uno de éstos es la automatización del conteo de fibras de una muestra de lana procesada (top), en un tiempo similar al que le lleva a un operario realizar la misma tarea.

Este proyecto busca cumplir con la automatización de la detección utilizando tratamiento de imágenes. Para hacer ésto se desarrolló un software que procesa imágenes que corresponden a una determinada superficie de top, utilizando un banco de imágenes preexistente. Luego se buscó incrementar la superficie de lana fotografiada sin que la resolución utilizada se fuera a tamaños inmanejables por el peso de las imágenes, y de tal forma que permitiera la detección de las fibras, logrando así una mejor relación entre el tiempo de procesamiento y superficie de top procesada. Para esto se implementó un método de adquisición de imágenes utilizando tolueno y un escáner.

Acompañando los objetivos anteriores, se planteó la posibilidad de realizar el diseño de un dispositivo que automatice la adquisición de imágenes, y que incorpore el procesamiento de las mismas utilizando el software desarrollado. Éste debería procesar en tiempo real una muestra de 100 gramos de lana, que es la cantidad que se utiliza en forma estándar en la industria para la esti-

mación de la cantidad de fibras coloreadas. Cumpliendo con este objetivo, se realizó un bosquejo y presupuesto de un sistema de adquisición y procesamiento automático de imágenes.

Adicionalmente, se logró caracterizar y clasificar las fibras coloreadas en dos tipos. Vale aclarar que la tarea de clasificar las fibras coloreadas es realizada actualmente de forma visual por un operario, de lo cual surge la necesidad de automatizar el proceso.

En el presente documento se detallan los objetivos, desarrollo y resultados del proyecto de fin de carrera FIBRAS COLOREADAS II.

En el capítulo 1 se describe la problemática de las fibras coloreadas, se detallan los diferentes métodos existentes para la detección de las mismas y se describen los objetivos del proyecto. En el capítulo 2 se describen las bases de imágenes utilizadas y su método de adquisición. En el capítulo 3 se describe el algoritmo desarrollado para la detección y clasificación de fibras coloreadas. En el capítulo 4 se muestran los resultados de la validación del algoritmo de detección. En el capítulo 5 se describen los diferentes métodos de clasificación de fibras coloreadas analizados y sus resultados. En el capítulo 6 se especifican las funciones utilizadas en el software, y se describe la interfaz gráfica del mismo. En el capítulo 7 se describe el sistema de adquisición y procesamiento automático diseñado, junto con su presupuesto. En el capítulo 8 se detallan sugerencias a tener en cuenta para posteriores realizaciones en este mismo tema. En el capítulo 9 se detallan las conclusiones del proyecto. En el Apéndice A se realiza un resumen de redes neuronales en general, y se detallan en particular dos de ellas que fueron utilizadas en la clasificación de fibra coloreadas. En el apéndice B se realiza un estudio para determinar la mínima resolución necesaria para la detección de fibras coloreadas.

Índice general

1. Introducción	2
1.1. Calidad de la lana	2
1.2. ¿Cómo se obtiene el top de lana?	5
1.3. Control de calidad.	5
1.4. ¿Cómo se ataca el problema?	6
1.5. Formas de detección de fibras coloreadas.	6
1.5.1. Proyecto de fin de carrera Fibras Coloreadas	6
1.5.2. CSIRO	8
1.5.3. IWTO	10
1.6. ¿Cuál es el objetivo de este proyecto?	11
1.6.1. Objetivos del proyecto	12
1.6.2. Criterios de evaluación	13
2. Base de imágenes utilizadas	14
2.1. Base del proyecto Fibras Coloreadas	14
2.1.1. Bases A y B	15
2.1.2. Base C	15
2.1.3. Base D	17
2.1.4. Procedimiento adquisición	17
2.2. Base adquirida en este proyecto	18
2.2.1. Motivación	18
2.2.2. Implementación	18
2.2.3. Utilizando bolsas de plástico y escáner.	19
2.2.4. Utilizando un recipiente de vidrio y escáner	19
3. Detección automática	23
3.1. Introducción	23
3.2. Detección de las zonas de interés	24
3.3. Eliminación de regiones pequeñas	31
3.4. Performance del algoritmo	32
3.5. Eliminación de cúmulos	33
3.6. Detección de extremos	35
3.7. Corrección de discontinuidades en las fibras	36
3.8. Cálculo de los puntos representativos de cada fibra	39
3.9. Reestablecimiento de dimensiones	42
3.10. Trazado de rectas perpendiculares a la fibra	42
3.11. Caracterización del perfil.	44
3.12. Depuración final	48

3.13. Método alternativo para trazar las rectas perpendiculares a las fibras	50
4. Validación del algoritmo de detección	52
5. Clasificación	56
5.1. Clasificación de fibras	56
5.1.1. Introducción	56
5.2. Planteo del problema	56
5.3. Métodos utilizados	57
5.3.1. Ancho	58
5.3.2. Nivel de gris	59
5.3.3. Ancho y nivel de gris	60
5.3.4. Color	61
5.3.5. Longitud	61
5.4. Resultados y Análisis	62
5.4.1. Ancho	62
5.4.2. Nivel de gris	67
5.4.3. Ancho y nivel de gris	72
5.4.4. Color	76
5.4.5. Longitud	78
5.5. Conclusiones	78
6. Documentación del Software.	80
6.1. Descripción de las clases implementadas	80
6.2. Descripción de la funciones implementadas	82
6.3. Interfaz gráfica con el usuario	87
7. Sistema de Adquisición	91
8. Pasos Siguientes	97
9. Conclusiones	98
10.Apéndice A	
Redes Neuronales	103
10.1. Introducción	103
10.2. Casos particulares	106
10.2.1. Redes neuronales Radial Basis	106
10.2.2. Redes Feed forward-backpropagation	108
11.Apéndice B	
Determinación de la mínima resolución para la detección	112
12.Apéndice C	
Material adjunto y requerimientos del sistema	117
12.1. Contenido del DVD	117
12.2. Requerimientos del sistema	118
12.2.1. Software	118
12.2.2. Requerimientos mínimos de hardware	118

Capítulo 1

Introducción

1.1. Calidad de la lana

En el contexto de la industria lanera se encuentra el problema de la presencia de impurezas en la lana que reducen su calidad. Entre estas impurezas se encuentran las fibras coloreadas. Éstas se clasifican según su origen en dos categorías: genéticas (proviene de lunares) o ambientales (proviene de puntas quemadas por la orina o roce con otros animales). Las fibras de lana son categorizadas según su nivel de coloración en una escala del 0 al 8 . La organización CSIRO (Commonwealth Scientific and Industrial Research Organization) define como fibras coloreadas a aquellas de nivel superior a 4. Éstas conservan su color original luego del proceso de teñido, y se hacen presentes como líneas oscuras no deseadas cuando la lana es destinada a la elaboración de telas de colores tenues.

Existen diferentes características que inciden en la calidad de la lana. Algunas de ellas son: el diámetro, el largo, el color y la resistencia. Todas estas características determinarán el uso final que se le dará a la misma, y por lo tanto su precio.

La primera característica con la cual se diferencian los distintos tipos de lana es el diámetro. Las fibras que tienen menor diámetro son utilizadas para la elaboración de prendas de vestir livianas. Con las de diámetro medio se realizan prendas de vestir pesadas. Las de mayor diámetro son utilizadas en la fabricación de alfombras, entre otras cosas. De lo anterior se desprende que los distintos fines a los que se destina la lana, requieren diferentes exigencias de calidad.

El diámetro de las fibras depende de varios factores, como pueden ser: la región del cuerpo del animal, la raza, el sexo y la nutrición. En el cuadro 1.1 se muestran los diámetros usuales para las diferentes razas.

Cuadro 1.1: Diámetro en distintas razas

Raza	Diámetro μm
Merino australiano fino	18-21
Merino australiano	21-25
Merino precoz francés	19-25
Hampshire	27-29
Suffolk	27-29
Corriedale	27-29
Romney Marsh	29-31
Texel	28-35
Lincoln	39-41

La longitud de la fibra, define si la misma se utilizará para cardado y peinado, o sólo para cardado, éstas son dos formas de proceso. Se destina para cardado y peinado aquellas que tienen como mínimo 5 centímetros, y para cardado las de menor longitud. La lana peinada adquiere mayor valor debido a que se destina para prendas finas como la gabardina y el casimir; en cambio la lana que sólo es cardada tiene menor valor y se destina para fieltros, frazadas o mantas.

El factor que más incide sobre esta característica de las fibras es la raza del animal. En el cuadro 1.2 se muestran los largos usuales para las diferentes razas.

Cuadro 1.2: Largo en distintas razas

Raza	Largo de la mecha (cm)
Merino australiano fino	7-13
Merino australiano	7-13
Merino precoz francés	6-9
Hampshire	4-8
Suffolk	5-9
Corriedale	10-16
Romney Marsh	12-16
Texel	16
Lincoln	20-40

Se entiende por resistencia al esfuerzo de extensión que puede soportar un haz de fibra sin romperse. Esta varía según el grosor de la lana, a mayor grosor mayor resistencia.

La resistencia puede alterarse debido a una alimentación deficiente, especialmente en el último tercio de gestación o primeros dos meses de lactancia,

también por factores climáticos (calor y humedad) y/o enfermedades, provocando una disminución del diámetro normal, y deterioros en la composición química de las fibras.

Las fibras de color tienen la particularidad de no poder ser teñidas como las fibras blancas, lo que se traduce en que las mismas no pueden ser utilizadas en prendas de colores claros, esta restricción implica una depreciación en el valor de la lana.

La lana tiene fibras coloreadas debido a dos motivos: motivos genéticos y motivos ambientales (roce con otros animales y el contacto con la orina).

Las fibras son clasificadas según su grosor y coloración desde el 1 hasta el 8. Se considera que una fibra de lana es una fibra coloreada cuando su clasificación por tipo es igual o superior a 5. Para determinar a qué clase corresponde cada fibra, se utiliza un patrón en el que están presentes los diferentes tipos de fibras, y cada fibra coloreada es comparada con dicho patrón. La cantidad de fibras coloreadas que presenta una muestra de lana es entonces uno de los factores que incide en su calidad, la misma se mide en fpk ¹.

Otro problema para el teñido es que actualmente se están utilizando bolsas de plastillera para el empaque luego de la esquila. Estas bolsas están compuestas por hebras con una textura muy similar a la de las fibras de lana, ya que pueden ser separadas en hebras más delgadas y son de un color traslúcido, lo que impide su detección por medios ópticos.

Actualmente, Uruguay se encuentra mal posicionado en cuanto a la cantidad de fibras coloreadas con respecto a otros países dedicados tradicionalmente a la producción lanera, como Australia o Nueva Zelanda. En particular, la raza que mejor se adapta a la geografía uruguaya es el Corriedale, ya que es la que cumple mejor la política de balance carne-lana. Esta raza es la que presenta peor performance en las características que hacen a la calidad por cantidad de fibras coloreadas. Para la raza Merino el estándar internacional para una buena calidad de lana es de 50 fpk en top de 21 a 23 micrómetros de espesor, para la raza Corriedale el Standard es de 300 fpk en top de 27 a 30 micrómetros de espesor. En Uruguay lo típico es de 1500 fpk sin acondicionar ² y 500 fpk acondicionada.

¹fibras coloreadas por kilogramo de top

²El acondicionamiento consiste en realizar una preselección de la lana en el momento de la esquila

1.2. ¿Cómo se obtiene el top de lana?

El procesamiento de la lana comienza con la esquila de la oveja, la cual es realizada una o dos veces al año, dependiendo de las condiciones climáticas.

Luego de haber esquilado a la oveja, la lana es sometida a un proceso de lavado. La materia prima es introducida en unas bateas con agua caliente donde se realiza su lavado utilizando detergentes. A continuación es secada mediante corrientes de aire caliente y sometida a un proceso de cardado, el cual sirve para separar la lana de semillas y vegetales. El cardado es realizado mediante una máquina compuesta por tambores de diferentes tamaños con guarniciones de púas de acero. Un ejemplo de una máquina que realiza el proceso de cardado se puede apreciar en la figura 1.1



Figura 1.1: Máquina cardadora

Después de esto, la lana es sometida al peinado. El objetivo de esta etapa es la eliminación de las fibras cortas y la paralelización de las fibras largas.

El producto obtenido luego de estos procesos se denomina top.

1.3. Control de calidad.

El control de calidad para evaluar el número de fibras coloreadas se realiza sobre el top de lana. Lo anterior implica que sólo es posible determinar si un lote es apto o no, luego de haber invertido recursos en el proceso de creación del top. Sería más provechoso saber el contenido de fibras coloreadas en etapas anteriores, pero esto resulta estadísticamente muy difícil debido a que la distribución de las fibras coloreadas no es uniforme, ya que las mismas se presentan en cúmulos, resultando en regiones con escasa cantidad de fibras coloreadas, y otras con gran densidad de las mismas. Ésto dificulta la implementación de técnicas de

muestreo. Luego del cardado, las fibras coloreadas se dispersan, lográndose una distribución más uniforme de las misma y facilitando así el muestreo.

1.4. ¿Cómo se ataca el problema?

En la etapa previa al procesamiento de la lana, sería deseable atacar la problemática de las fibras coloreadas, y es donde se concentran todos los esfuerzos, comenzando por el mejoramiento genético de las razas, que actualmente es tema de estudio de la Facultad de Veterinaria. Estos esfuerzos intentan reducir las fibras coloreadas de origen genético, las cuales aparecen como lunares en el animal. Siguiendo por el acondicionamiento de la lana al momento de la esquila, la misma tiene como objetivo poder separar la lana manchada por la orina del animal de la lana limpia.

1.5. Formas de detección de fibras coloreadas.

Por lo mencionado anteriormente, la detección de fibras coloreadas es un tema de relevancia a la hora de determinar la calidad de la lana. Actualmente, las técnicas de detección se aplican sobre el top de lana. En este sentido existen varias técnicas que posibilitan dicha detección. Ninguna de estas técnicas ha llegado a ser una estándar. En las siguientes secciones se describen brevemente alguna de ellas.

1.5.1. Proyecto de fin de carrera Fibras Coloreadas

En el Proyecto de Fin de Carrera del año 2002 *Detección de Fibras Coloreadas en lana*, se diseñó un procedimiento para realizar el conteo de fibras coloreadas en un volumen reducido de lana.

En dicho trabajo se buscó una solución al problema de detectar fibras coloreadas en muestras de top, planteando una solución por medio de un sistema de visión artificial. Se construyó un software para la resolución del problema, que implementa algoritmos de tratamiento de imágenes (proyección de Karhunen Loeve, compensación lumínica, filtros de Gabor, histéresis y morfología), sobre fotografías digitales. Siendo necesario para la correcta obtención de estas imágenes un sistema de adquisición específico, se diseñó un artefacto que pone en práctica la técnica de luz balanceada.

En resumen, el proceso que se implementó en dicho proyecto fue el siguiente. Se coloca una pequeña muestra de lana entre dos placas de vidrio y luego se realiza un balanceo de la iluminación para contrastar lo mejor posible las fibras coloreadas de las que no lo son. Luego, se toma una fotografía de la muestra, la cual es procesada por un software que realiza un conteo de las fibras coloreadas allí presentes. Las áreas con las que se trabajó fueron de 18×24 milímetros y de 30×40 milímetros.

Técnica de luz balanceada

La técnica de luz balanceada consiste en iluminar la muestra con dos fuentes de luz blanca, una superior y otra inferior, controlando sus intensidades para obtener un balance que logre cancelar las sombras de las fibras blancas y resaltar las fibras coloreadas. La figura 1.2 compara las imágenes adquiridas de una muestra, sin balancear las intensidades a la izquierda, y utilizando el método de luz balanceada a la derecha.



Figura 1.2: Comparación del efecto de aplicar luz balanceada

FotoResaltador

FotoResaltador (se muestra en la figura 1.3), es el equipo lumínico que implementa el método de detección por luz balanceada. Integra un sistema de iluminación superior fijo, uno inferior controlable y un conjunto de difusores.



Figura 1.3: FotoResaltador

1.5.2. CSIRO

Son las siglas para Commonwealth Scientific and Industrial Research Organisation. Es una organización australiana que investiga y discute aspectos que conciernen a la vida de ese país. Contiene un grupo de trabajo de 6500 personas que buscan incrementar la calidad de vida. Entre los temas de esta organización se encuentran: energía y transporte, recursos naturales, ambiente, comunicaciones e industrias manufactureras.

Esta organización ha producido varios dispositivos que se usan para la detección de fibras coloreadas en lana, algunos de éstos se detallan a continuación:

Dark fibre detector: Es un método manual de conteo de fibras coloreadas que utiliza luz balanceada y una lupa con la cual un operario realiza el conteo en forma visual. Este método es utilizado actualmente en Uruguay. Al ser un método manual los resultados dependen en gran medida del operador. Además, es un método lento que implica que su utilización se reduzca a laboratorios, no utilizándose normalmente en la industria. Ver figura 1.4




Figura 1.4: Dark Fibre detector

LaserScan: Es un instrumento que utiliza un láser que sirve para determinar el grosor de las fibras. Tiene la particularidad de servir para varios tipos de fibras (alpaca, angora y lino).

El dispositivo detecta el coeficiente de variación de diámetro, realiza un histograma con la distribución del diámetro, grafica la curvatura de la fibra y entrega el factor de confort (porcentaje de fibras $< 30,5\mu\text{m}$ de lana). Este dispositivo no realiza un conteo de la cantidad de fibras coloreadas. El dispositivo se muestra en la figura 1.5.

El proceso comienza con el seccionamiento del top en partes de 2 milímetros. Esto se realiza mediante una guillotina, como muestra la figura 1.6.



Figura 1.5: Laserscan

Las fibras de lana son mezcladas en una solución y luego son pasadas por



Figura 1.6: Guillotina

una célula de medida. Cuando una fibra se interpone ante el láser cambia la intensidad recibida y es traducida en el conteo de una fibra. La velocidad del dispositivo se sitúa en 1000 fibras cada 40 segundos.




Figura 1.7: Sirolan-Laserscan

Sirolan FleeceScan: También es una solución desarrollada por CSIRO. Es un set de instrumentos portátiles para testear el diámetro de las fibras de manera rápida y precisa. Básicamente es el método anterior con un modo de lavado previo.

1.5.3. IWTO

Son las siglas para International Wool Textil Organisation. Es una organización internacional que representa los intereses del negocio de la lana en todas sus etapas: criadores de ovinos, procesos a los cuales es sometida la lana, negocios, etc.

Sus miembros son países, y en representación de Uruguay se encuentra el LATU. En esta organización se discuten los problemas comunes y se buscan sus soluciones. Esta organización tiene varios estándares de métodos para medir la calidad de la lana. En particular existe la recomendación IWTO 55-99 que implementa una forma para contar la cantidad de fibras coloreadas desarrollado por la organización CENTEXBEL (el dispositivo se muestra en la figura 1.8). Estos procedimientos se encuentran documentados en un libro llamado Libro Rojo de la IWTO.



Figura 1.8: Contador de fibras coloreadas

Top Tester: Como integrante de la IWTO, el LATU actualmente realiza el conteo de las fibras presentes en una muestra de lana mediante la utilización de un dispositivo denominado Top Tester.

El dispositivo tiene dos partes fundamentales. En primer lugar contiene dos pares de rodillos que giran a distinta velocidad entre ellos. La muestra de lana pasa a través de estos rodillos. El hecho de girar a diferentes velocidades permite que las fibras de lana sean estiradas y que se forme un fino velo.

Luego el velo pasa por detrás de una lupa mediante la cual un operario realiza el conteo. El dispositivo contiene una botonera que permite al operario registrar la presencia de fibras. El dispositivo se muestra en la figura 1.9.



Figura 1.9: Top Tester

1.6. ¿Cuál es el objetivo de este proyecto?

Este proyecto busca incursionar en el campo de investigación de la detección automática de fibras en las muestras de top. Trata de lograr un método de laboratorio que mediante la fotografía y el proceso digital logre dar una buena estimación de la cantidad y tipo de fibras coloreadas presentes en una muestra de lana. Este método debería poder lograr tiempos y performances al menos similares a las que se logra mediante la detección manual, tratando de dar un aporte a la ardua tarea que implica la detección manual, siempre pensando en la aplicación de la ingeniería a los procesos de producción.

El punto de partida es el proyecto de fin de carrera Fibras Coloreadas realizado en el año 2002, que demostró la posibilidad de realizar dicha detección por medio de la adquisición y tratamiento de imágenes en forma digital.

1.6.1. Objetivos del proyecto

Los objetivos de este proyecto son:

1. Investigación.

Se estudiarán los proyectos y soluciones que existen hasta el momento. En particular se estudiará el Proyecto Fibras Coloreadas realizado anteriormente en Facultad. También se hará hincapié en la recomendación de la IWTO que tiene especificada una solución a este problema.

Se realizarán visitas al LATU para observar los procedimientos manuales de conteo de fibras coloreadas.

También se realizará una visita a la Facultad de Veterinaria, donde actualmente se realizan investigaciones genéticas sobre las fibras coloreadas.

2. Poder analizar una muestra mayor de lana.

En el proyecto de Detección de Fibras Coloreadas se estudió una muestra de 18×24 milímetros. Lo ideal sería poder procesar una imagen de aproximadamente 10×10 centímetros para que sea factible implementar la detección de fibras en 100 gramos de lana en tiempo real.

3. Mejorar la eficiencia del algoritmo anterior

Dado que las muestras de lana a analizar en este proyecto van a ser de un volumen mayor, se necesitaría optimizar al máximo los algoritmos para lograr mejores velocidades de procesamiento, ya que en el proyecto anterior en ningún momento se buscó optimizar el mismo por razones de tiempo.

4. Dispositivo que automatice el proceso

De haber logrado los dos puntos anteriores, se diseñará un dispositivo que automatice el proceso de conteo de fibras en un tiempo similar al que le lleva actualmente a un experto realizar dicha tarea. Se debe hacer una estimación de costos para la realización de un prototipo. En caso de contar con dinero suficiente se podría construir el mismo.

5. Detección de impurezas

Paralelamente, se buscarán formas de detección de otras impurezas, principalmente polipropileno. Actualmente existe un problema de contaminación de la lana con estas fibras debido a que son transportadas en bolsas de dicho elemento. Estas fibras, que tampoco se tiñen (como las fibras coloreadas), tienen al menos dos problemas para su detección: tienen dimensiones similares a la de la lana y son de color claro (traslúcidas) por lo que es difícil detectarlas.

1.6.2. Criterios de evaluación

Se considerará que se lograron los dos primeros objetivos si, para una muestra de lana analizada de 10×10 centímetros, se puede realizar el procesamiento de la misma en un tiempo igual o menor al que le lleva al técnico. Para el tercer objetivo, se considerará alcanzado el mismo si se logra un documento con el diseño de un prototipo y los cálculos de costos del mismo. El último objetivo se considerará logrado si se presenta un documento conteniendo los resultados de las investigaciones realizadas, no estando obligados a encontrar la solución a este problema.

Capítulo 2

Base de imágenes utilizadas

2.1. Base del proyecto Fibras Coloreadas

Para el desarrollo y prueba de la solución propuesta, se utilizaron dos bases diferentes de imágenes.

La primer base utilizada es la adquirida durante el proyecto de fin de carrera *Fibras Coloreadas*.

Esta base de imágenes se encuentra dividida en cuatro partes, a las cuales se referenciará en este documento como *Base A*, *Base B*, *Base C* y *Base D*.

Las tres primeras bases contienen en total 199 imágenes, la *Base D* no es tomada en cuenta dado que esta base no está supervisada. Cada imagen fue estudiada por un técnico, al cual se referenciará como *el experto* en este documento, el cual indicó el tipo y la cantidad de fibras coloreadas presentes en cada imagen. Un ejemplo de las imágenes marcada por *el experto* se muestra en la figura 2.1.

Los colores de la fibra se interpretan de acuerdo al cuadro 2.1.




Figura 2.1: Imagen marcada por el experto

Cada una de las imágenes adquiridas tienen un tamaño de 1536 píxeles de ancho y 2048 píxeles de largo. El formato de dichas imágenes es png.

Cuadro 2.1: Codificación

Color	Tipo de Fibra
rojo	5
amarillo	6
verde	7
celeste	8

2.1.1. Bases A y B

Las bases de imágenes A y B contienen un conjunto de 170 fotografías y copias de éstas con marcas de color que definen el tipo de fibra.

Estas marcas corresponden a la decisión de la experta del SUL tomada según la técnica de supervisión manual utilizando el Detector de Fibras Coloreadas de CSIRO. Los siguientes parámetros caracterizan a las imágenes de las bases A y B .

- Campo de visión 18×24 centímetros
- Distancia de toma 40 milímetros
- Pixels/milímetro 82
- Tiempo de apertura $1/20$ segundos
- Apertura $F10,3$
- Distancia focal 17 milímetros
- Sensibilidad 100 asas

La base A se separó en dos bases A1 y A2 de 20 y 50 fotografías, que en el proyecto anterior fueron utilizados para distintas etapas en el entrenamiento del software y la base B se reservó para la evaluación del mismo. La información de estas bases se complementa con los archivos *baseA.xls* y *baseB.xls* que concentran el conteo de las fibras de cada tipo en el conjunto de las imágenes. También figuran en las carpetas que contienen las imágenes, archivos Léame explicativos. En los cuadros 2.2, 2.3 y 2.4 se detallan la cantidad de fibras clasificadas por tipo que existen en cada base.

2.1.2. Base C

La base de imágenes C está formada por un conjunto de 29 fotografías, con copias marcadas por el experto, de características similares a las de los grupos A y B salvo un campo de visión mayor. Los parámetros que caracterizan a las fotografías del grupo C son:

- Campo de visión 30×40 milímetros

Cuadro 2.2: Base A1

	Total de Fibras
Fibras Tipo 5	4
Fibras Tipo 6	4
Fibras Tipo 7	6
Fibras Tipo 8	8
Fibras Contaminantes	0

Cuadro 2.3: Base A2

	Total de Fibras
Fibras Tipo 5	12
Fibras Tipo 6	11
Fibras Tipo 7	19
Fibras Tipo 8	13
Fibras Contaminantes	3

Cuadro 2.4: Base B

	Total de Fibras
Fibras Tipo 5	16
Fibras Tipo 6	29
Fibras Tipo 7	42
Fibras Tipo 8	31
Fibras Contaminantes	4

- Distancia de toma 70 milímetros
- Pixels/milímetro 51
- Tiempo de apertura 1/20 segundos
- Apertura $F10,3$
- Distancia focal 17 milímetros
- Sensibilidad 100 asas

Existe el archivo baseC.xls análogo a baseA.xls y BaseB.xls y un archivo LéameC.txt específico. En el cuadro 2.5 se muestra la cantidad de fibras clasificadas por tipo que existen en esta base.

En este proyecto se utilizó la *Base C* y la *Base A2* para el entrenamiento del software y la *Base A1* y *Base B* para la evaluación del mismo.

Cuadro 2.5: Base C

	Total de Fibras
Fibras Tipo 5	9
Fibras Tipo 6	12
Fibras Tipo 7	19
Fibras Tipo 8	19
Fibras Contaminantes	3

2.1.3. Base D

La base *D* se separa en dos conjuntos *D1* y *D2*. El conjunto *D1* consta de 8 fotografías del patrón de fibras coloreadas perteneciente al SUL. Estas imágenes no fueron utilizadas para la calibración pues presentan marcas. El conjunto *D2* consta de 92 fotografías no supervisadas por el experto, por lo tanto no se tiene información acerca del tipo de fibras. Ambas bases fueron obtenidas según los siguientes parámetros.

- Campo de visión 18×24 milímetros
- Distancia de toma 40 milímetros

A pesar de la existencia, esta base no fue utilizada en este proyecto dado que al no estar supervisadas no aportaban ninguna información para la evaluación del algoritmo.

2.1.4. Procedimiento adquisición

Las fotografías que forman las bases *A*, *B* y *C* fueron tomadas en un proceso de 16 horas de duración, repartido en cuatro días de trabajo conjunto con la experta¹ del SUL. El método utilizado para supervisar fue el siguiente:

- a) El especialista detecta fibras en muestras de top con sus instrumentos.
- b) Luego con el sistema de adquisición se fotografía un área de top que contiene las fibras identificadas por el experto.
- c) La fotografía en formato TIF se carga en el computador a través del cable USB.
- d) Se realizan marcas de color en una copia de la imagen para identificar la posición de las fibras y el tipo de cada una de ellas según lo especificado en el punto a).
- e) Se llena en la planilla del archivo baseA.xls (ó baseB.xls, ó baseC.xls) donde se registra el o los tipos de fibra que allí aparecen e información específica como por ejemplo la presencia de contaminantes.

¹Liliana Criado

2.2. Base adquirida en este proyecto

2.2.1. Motivación

Los bancos de imágenes con los cuales se había estado trabajando hasta el momento y en base a los cuales se diseñó el algoritmo, colmaban las necesidades básicas para una buena detección de las fibras pero existían propiedades que se podían mejorar. Por ejemplo, había imágenes en las que el fondo no era del todo uniforme, se encontraban diferentes niveles de brillo en una misma imagen, y se distinguían fibras que no eran fibras coloreadas desde ningún punto de vista.

En la figura 2.2 se muestra una parte del fondo de una imagen en particular. En el medio de esta se puede apreciar la diferencia del brillo que existe con respecto a los bordes.

En la figura 2.3 se muestran los brillos provocados sobre las fibras de lana



Figura 2.2: Iluminación no uniforme

comunes, además si se observa en detalle se pueden ver las fibras del fondo (parte gris). Estos pequeños detalles se transforman en grandes problemas a la hora de




Figura 2.3: Presencia de brillos

detectar únicamente las fibras coloreadas. Otra posibilidad que se planteó fue adquirir imágenes con menor resolución, lo cual implicaría un menor tiempo de procesamiento, pero fue descartada ya que esto impediría la clasificación de los distintos tipos de fibras.

2.2.2. Implementación

Se plantearon varios procedimientos para crear este nuevo banco de imágenes. En primer lugar la idea era volver a calibrar el FibroCaptor tratando justamente

de solucionar los problemas antes mencionados. Esta solución no era muy alentadora dado que en realidad no existían muchos parámetros para ajustar de forma de evitar dichos problemas.

Fue entonces que llegó un comunicado del personal del LATU con la noticia de que estaban enterados de que en Australia se estaba desarrollando un nuevo método para la adquisición de imágenes con el objetivo de contar las fibras coloreadas. Este método consiste en mezclar la muestra de lana con Tolueno (también llamado Metil-Benceno) dado que el índice de refracción de éste y el de la lana son muy parecidos (1.49 para el tolueno a 20 °C y 1.5-1.7 para la lana). Esto trae como consecuencia que al mezclarlos no se pueda distinguir con facilidad lo que es lana y lo que es tolueno, dejando un fondo mucho más uniforme cuando se usa para la adquisición de imágenes.

Un problema no menor que surge el trabajar con esta sustancia, es que es un líquido muy volátil y algo tóxico con lo cual hay que tener varias precauciones para su manejo. Además derrite varias sustancias como ser espuma-plast, algunos plásticos blandos, etc.

En este contexto surgieron dos formas de implementar la adquisición, como se menciona a continuación.

2.2.3. Utilizando bolsas de plástico y escáner.

Una idea fue colocar el tolueno en bolsas de polipropileno de 15×20 centímetros junto con la muestra de lana. Luego de introducidos los componentes la bolsa se cerraba en forma hermética y se la colocaba sobre el escáner para luego obtener la imagen, el esquema se muestra en la figura 2.4.

Un problema que surgió fue que al cerrar la bolsa quedaban burbujas de aire dentro de ella y había que sacarlas debido a que sino aparecían como cúmulos en la imagen que dificultaban la detección de fibras. Se intentaron varias formas de hacer esto pero nunca se logró sacar todo el aire del interior de las bolsas.

2.2.4. Utilizando un recipiente de vidrio y escáner

Otra idea fue hacer un recipiente de vidrio de unos $20 \times 20 \times 5$ centímetros en donde se coloca el tolueno con una capa fina de lana para evitar que algunas fibras coloreadas queden muy atrás y por lo tanto luego en la imagen aparezcan muy tenues. Este sistema se muestra en la figura 2.5.

También se cuenta con una tapa flexible rectangular de $18 \times 18 \times 0,5$ centímetros y de color blanco que se coloca sobre la mezcla de lana y tolueno. Esta tapa se coloca de forma tal de ir barriendo las burbujas de aire que se encuentran en la mezcla. Para esto se apoya solamente una arista y se baja la tapa como se




Figura 2.4: Bolsa de plástico y escáner




Figura 2.5: Recipiente y escáner

indica en la figura 2.6.

De esta forma se logra sacar casi en su totalidad las burbujas quedando un fondo bastante uniforme en las imágenes. La tapa tiene que ser blanca para ayudar a contrastar más las fibras coloreadas del fondo de la imagen y además el peso de ésta sirve para compactar un poco más la mezcla contra el piso del recipiente lo cual evita que fibras coloreadas queden muy por detrás del resto de la muestra. Una vez preparada la muestra con el procedimiento antes mencionado se la coloca sobre el escáner para la adquisición de las imágenes.

En el momento de la adquisición surgió la duda de cuál era la definición




Figura 2.6: Eliminación de burbujas de aire

óptima para las imágenes. Para decidir esto se tuvo en cuenta el tiempo que le lleva al escáner adquirir los datos y la definición de la imagen producida. Si se piensa en el dispositivo trabajando en forma continua se puede aprovechar este tiempo de adquisición para ir procesando la imagen que se adquirió antes. La tabla 2.6 muestra los tiempos de adquisición en función de la resolución.

Cuadro 2.6: Tiempos de adquisición

Resolución (dpi)	Tiempo de adquisición
600	menos de 1 minuto
800	1 minuto
1200	2 minutos
1600	4 minutos
2400	6.5 minutos
3200	9 minutos
4800	13 minutos

Luego de observar las imágenes y teniendo en cuenta el tiempo de procesamiento se decidió que la resolución optima era la de 1200 dpi, con un tiempo de adquisición de unos 2 minutos aproximadamente. Las dimensiones de estas imágenes son de unos 17×13 centímetros dado que el recipiente era 20×20 centímetros y los bordes de la imagen se recortan un poco por la distorsión que en ellos se produce.

En la figura 2.7 se muestra una imagen adquirida con el procedimiento antes mencionado.

Si se observa el fondo, se puede apreciar que existe una gran mejora con respecto al de las imágenes de la primera base, con lo cual se logró solucionar uno de los problemas que existía con el fondo, como se mencionaba al comienzo de esta sección.




Figura 2.7: Imagen adquirida utilizando tolueno

En la figura 2.7 también se pueden apreciar la presencia de una burbuja que no fue posible eliminar por el procedimiento descrito anteriormente. Las burbujas tienen una topología y tamaño muy diferente a la de las fibras, además no aparecen en grandes cantidades, por lo que pueden ser fácilmente eliminables.

Capítulo 3

Detección automática

3.1. Introducción

Debido al pequeño espesor que tienen las fibras (entre 23 y 28 micras en promedio), se hace necesario trabajar con imágenes de alta resolución para poder diferenciar los distintos tipos (ver Apéndice B). Lo anterior implica que las imágenes contienen una gran cantidad de píxeles, y puede producir que los algoritmos que se ejecutan sobre estas imágenes consuman un tiempo considerable de procesamiento.

Para evitarlo, se requiere predetectar zonas donde haya una alta probabilidad de que exista una fibra, para luego realizar un estudio detallado de estas zonas y así descartar de antemano las zonas de poco interés.

Un falso negativo es cuando el algoritmo no detecta la fibra y sin embargo la fibra está y es una fibra coloreada. Un falso positivo es cuando el algoritmo detecta como fibra coloreada algo que en realidad no lo es. Lo ideal es no tener ningún tipo de falso (tanto positivos como negativos). El primer objetivo es minimizar los falsos negativos que son los más importantes y luego concentrarse en los falsos positivos.

Se buscará que este algoritmo presente la menor cantidad de falsos negativos posibles. Deberá realizar, además, la mínima cantidad de operaciones para poder cumplir con los requerimientos de tiempo. Una vez detectadas las zonas de interés, se procede al estudio detallado de cada una de las fibras. Este estudio detallado consiste en medir las características que se usan para diferenciar entre los distintos tipos de fibras coloreadas.

Las imágenes utilizadas durante el desarrollo del software son las que se encuentran en la *Base C*, trabajándose con imágenes en escala de gris, ya que la utilización de los diferentes canales R, G ó B, no aporta mayor informa-

ción que las imágenes en escala de gris, como se explica en la sección 5.3.4. En este capítulo, cada una de las imágenes de dicha base serán referenciadas como *imagenOriginal*, y al píxel de la fila i y columna j de esta imagen se le llamará *imagenOriginal*(i,j).

Consideraciones generales.

Observando con atención las imágenes de la base de datos, se pueden distinguir fibras de color más oscuro que las demás, éstas son las fibras coloreadas, que se intenta detectar y clasificar con el algoritmo desarrollado. Vale la pena observar algunas características de las fibras y las imágenes en general.

- Las fibras coloreadas son más oscuras, por lo tanto presentan un menor nivel de brillo que el resto de la imagen.
- Las fibras contienen zonas más claras que se cofunden con el fondo de la imagen.
- Hay ejemplos de imágenes en donde las fibras presentan una morfología complicada (fibras trenzadas).
- Algunas imágenes presentan manchas e impurezas que pueden tener el mismo nivel de gris que las fibras coloreadas.
- La iluminación de la imagen no necesariamente es uniforme.
- El nivel medio de iluminación no necesariamente se mantiene constante entre todas las fotos de la base.
- Existen zonas de la imagen con elevado valor de gris debido al reflejo de la luz.

3.2. Detección de las zonas de interés

En general los puntos listados en la sección anterior representan los obstáculos que es necesario sortear para esta primera etapa del algoritmo, que trata de la predetección de zonas de interés.

Será el compromiso de diseño el mantener un adecuado nivel de equilibrio entre exactitud y simplicidad del algoritmo. Exactitud implica tener una performance aceptable de detección evaluando qué casos patológicos serán necesarios tener en cuenta y cuáles no. Por otra parte, la simplicidad del método se traduce en velocidad de procesamiento para cumplir con uno de los objetivos que es lograr el menor tiempo de ejecución posible. Surge, entonces el siguiente algoritmo que trata de ser robusto frente a los obstáculos antes descritos.

Seguramente, lo primero que parece obvio realizar, tratando de explotar el hecho de que las fibras coloreadas poseen un menor nivel de gris, es aplicar un umbral absoluto a la imagen. Los píxeles cuyo nivel de gris queden por debajo

del umbral serán considerados como pertenecientes a una fibra coloreada.

Este método se puede descartar fácilmente observando los resultados obtenidos para una imagen en particular: si se umbraliza la imagen mostrada en la figura 3.1, se obtiene la imagen mostrada en la figura 3.2. Se puede observar que el borde de la imagen es de un nivel de gris similar al de la fibra coloreada, por lo que se marca como tal luego de la umbralización, esto hace que este método falle frente a imágenes con iluminación no uniforme. En particular, para las bases de imágenes utilizadas la iluminación es parabólica, lo cual se puede apreciar claramente en la figura 3.2.




Figura 3.1: Detección de fibras coloreadas utilizando el nivel de gris

La anterior da una idea de que para el desarrollo del algoritmo, no podrán ser utilizados umbrales globales, sino que deberá subdividirse la imagen en diferentes secciones y en cada una de ellas se elegirá un umbral local.

El método de detección desarrollado utiliza el hecho que, cuando en una región de una imagen, aparece una gran variación en el nivel de gris de los píxeles de la misma, se produce un aumento de la varianza en dicha región.

Si se observa la figura 3.1, se puede apreciar que las fibras oscuras (fibras coloreadas) resaltan sobre el fondo gris claro de la imagen. En otras palabras, el nivel de gris de los píxeles que conforman la fibra es significativamente inferior al del resto de la imagen (figura 3.3), por lo que la varianza del nivel de gris de una zona que contenga una porción de fibra coloreada, va a ser mayor que la de una zona sin fibras coloreadas. El método de detección ubica entonces las zonas donde se produce un aumento de la varianza y las selecciona como zonas donde probablemente se pueda ubicar una fibra.




Figura 3.2: Detección de fibras coloreadas utilizando un umbral absoluto para el nivel de gris




Figura 3.3: Detección de la fibra utilizando la variación del nivel gris

Las muestras de lana habitualmente presentan puntos y líneas brillantes debido principalmente al pasaje de luz desde la parte inferior del fibrocaptor. La variación del nivel de gris produce un aumento de la varianza, lo cual sería interpretado por el algoritmo de predetección como una región donde posiblemente se encuentre una fibra. Lo anterior es un inconveniente ya que produciría un aumento de los falsos positivos. Para solucionar este inconveniente se divide la imagen (de $N \times M$ píxeles) en una cuadrícula de $L1 \times L2$ píxeles, donde $L1 = N/7$, y $L2 = M/7$ (la división es entera). A cada elemento de esta cuadrícula se le denominará *región* en el resto del documento. La construcción de las regiones se muestra en la figura 3.4.

La construcción una *región* de tamaño $L1 \times L2$ píxeles, se ejemplifica en el siguiente pseudo-código:




Figura 3.4: Construcción de regiones a partir de la imagen original. En este ejemplo $N = 1536$, $M = 2048$, $L1 = 219$, y $L2 = 292$ píxeles

$$\begin{aligned}
 ®ion(i, j) = imagenOriginal(filas + i, columnas + j) \\
 &\forall i, j / 1 < i < L1, 1 < j < L2 \\
 &filas \text{ y } columnas \text{ son las coordenadas de la imagen original} \\
 &\text{desde donde se comienza a construir region}
 \end{aligned}$$

Para eliminar los brillos mencionados anteriormente se elige un umbral de saturación, por lo que a todos los píxeles de una *región* cuyo nivel de gris supere dicho umbral, se les cambia el valor de gris por la media de gris de la región. El umbral de saturación es diferente para cada región y depende de la media del nivel de gris de la misma, como se ejemplifica en el siguiente pseudo-código:

$$\begin{aligned}
 &if \text{ region}(i, j) > UmbralSaturacion \\
 &\forall i, j / 1 < i < L1, 1 < j < L2 \\
 &\text{region}(i, j) = MediaRegion
 \end{aligned}$$

Una vez eliminados los brillos, se procede a dividir cada una de las regiones en cuadrículas de $K \times K$ píxeles, a cada una de estas zonas se le denominará *cuadro* durante el resto del documento. La construcción de cada cuadro de tamaño $K \times K$ se realiza mediante el siguiente pseudo-código:

$$\begin{aligned}
 &cuadros(i, j) = region(filas + i, columnas + j) \\
 &\forall i, j / 1 < i < K, 1 < j < K
 \end{aligned}$$

Donde *filas* y *columnas* representa el punto de inicio (en una *región*), desde donde se comienza a construir *cuadros*.

A cada uno de los *cuadros* se le calcula la varianza del nivel de gris. Los valores de las varianzas de *cuadros* son guardados en una matriz de tamaño $L3 \times L4$ píxeles (por cada *cuadro* se guarda un valor en *matrizVarianza*), donde $L3 = N/8$, y $L4 = M/8$, la cual será referenciada como *matrizVarianza*. Este proceso se muestra en la figura 3.5.

A partir de este momento se trata con una imagen en escala de gris (*matrizVar-*




Figura 3.5: Proceso de reducción en el tamaño de la imagen original

ianza), de tamaño muy inferior al de la imagen original (64 veces menor). En esta imagen se toma el valor medio y máximo de gris, y un valor α (parámetro que se ajusta para encontrar un umbral adecuado, a la hora de definir si un píxel pertenece o no a una zona donde podría existir una fibra), a partir de los cuales es posible seleccionar los píxeles de *matrizVarianza* en que la varianza es mayor a cierto umbral. El umbral se elige (seleccionando un α adecuado), de tal forma que los píxeles de *matrizVarianza* que estén por encima del mismo sean aquellos correspondientes a *cuadros* donde se encuentra una porción de fibra coloreada (recordar que un *cuadro* de una *región*, se transforma en un píxel en *matrizVarianza*). Este umbral se calcula de la siguiente forma:

$$umbral = media(matrizVarianza) + \alpha \times DesviacionEstandar(matrizVarianza)$$

Se utilizan dos valores de α diferentes. Para el α inferior (umbral bajo), se obtiene una imagen con gran cantidad de falsos positivos (el algoritmo considera que es una fibra cuando en realidad no lo es), para el α superior (umbral alto), se obtiene una imagen con gran cantidad de falsos negativos ¹. Las imágenes obtenidas para ambos α serán referenciadas como *imagenSuperior* e *imagenInferior* respectivamente.

Este proceso se muestra en la figura 3.6.

¹Falsos negativos aquí se refiere a pérdida de píxeles que pertenecen a la fibra, pero no a la fibra total




Figura 3.6: Imagen binaria

Los valores de α fueron seleccionados ejecutando el algoritmo y estudiando los resultados con las imágenes de la *Base C*. El valor superior se selecciona de manera que no existan falsos positivos, sin importar que las fibras sean seccionadas. El valor inferior se selecciona de manera que no existan falsos negativos, sin importar la cantidad de falsos positivos que se presentan. Se muestran los resultados de este algoritmo en las figuras 3.7 y 3.8.



Figura 3.7: Umbral superior

A partir de estas imágenes se aplica un procedimiento iterativo en donde el punto de partida es la *imagenSuperior*. Para cada punto *imagenSuperior*(i,j) marcado como probable de formar parte de una fibra, el algoritmo investiga en un entorno de dicho punto, pero en la *imagenInferior*. Si en este entorno hay algún punto (i,j) marcado, se marca entonces el punto *imagenSuperior*(i,j). Se repite este procedimiento hasta que no se produzcan cambios entre la iteración anterior y actual. Se obtendría mediante este procedimiento una imagen con pocos espúreos (entendiendo espúreos como puntos marcados en donde no existen fibras) y la fibra sin discontinuidades. A esta imagen se le llamará *imagenBinaria*. El procedimiento de iteración y el resultado final se muestra en la figura 3.9.




Figura 3.8: Umbral inferior




Figura 3.9: Resultado *imagenBinaria*

Las imágenes mostradas en esta sección para ejemplificar el funcionamiento del algoritmo, corresponden a la base *C* del Proyecto de Fin de Carrera *Fibras Coloreadas*.

Luego se ejecutó el algoritmo sobre las imágenes adquiridas para este proyecto sin modificación de los umbrales, los resultados se pueden ver en la figura 3.10 para una resolución de 1200 dpi. Los resultados para ambas bases de imágenes son similares, esto muestra la robustez del algoritmo, ya que no fueron modificados los umbrales.




Figura 3.10: Resultado *imagenBinaria*

3.3. Eliminación de regiones pequeñas

Luego del proceso de iteración queda cierto ruido en *imagenBinaria*, esto es, pequeñas regiones que sobrevivieron a la iteración pero que no pertenecen a fibras. No todas las regiones pequeñas que sobreviven a la iteración anterior deben eliminarse, ya que algunas son parte de fibras que se cortaron durante el proceso de binarización. Las fibras se cortan debido a que no tienen el mismo nivel de gris en toda su extensión, sino que en ciertas regiones se diferencian claramente del fondo y en otras no, provocando en las últimas que la varianza sea pequeña y no supere el umbral que determina si un píxel (en *imagenBinaria*) pertenece al fondo o una fibra. Esto puede apreciarse en la figura 3.11

Para solucionar este problema primero se hace una dilatación de todas las regiones, con esto logran unirse trozos de fibra que están próximos (la unión de trozos de fibra mas alejados se verá mas adelante en este mismo capítulo), luego se etiquetan las diferentes regiones conexas que aparecen en *imagenBinaria*, y




Figura 3.11: Resultado *imagenBinaria*

se eliminan aquellas con cantidad de píxeles menor que cierto umbral, esto se puede ver en la figura 3.12.




Figura 3.12: Resultado *eliminación de regiones pequeñas*

3.4. Performance del algoritmo

Una vez alcanzado estos resultados, se ha llegado al punto donde finalizó el Proyecto de Fin de Carrera *Fibras Coloreadas*. Por lo que es conveniente realizar un estudio de las mejoras alcanzadas respecto al proyecto anterior en cuanto al tiempo de ejecución.

El software desarrollado en el Proyecto de Fin de Carrera Fibras Coloreadas, tiene un tiempo de ejecución de aproximadamente 40 segundos. Para una computadora de similares características, el algoritmo desarrollado en este proyecto tiene un tiempo de ejecución de 2.4 segundos.

A continuación se muestra la cantidad de operaciones que realiza el algoritmo en función de las características de la imagen. No es significativa en la cantidad total de operaciones la cantidad de fibras presentes en la imagen.

$$\text{operaciones} = \text{COLUMNAS} \times \text{FILAS} \times 63$$

Donde $\text{FILAS} = N$, $\text{COLUMNAS} = M$.

Se puede apreciar entonces que existe una linealidad entre la cantidad de operaciones y el tamaño de la imagen. Para la base de imágenes obtenida durante el Proyecto de Fin de Carrera anterior la cantidad de operaciones es de aproximadamente $1,98 \times 10^6$. Para una imagen de 1200 dpi de la base obtenida para este proyecto, la cantidad de operaciones es de aproximadamente $3,4 \times 10^7$.

3.5. Eliminación de cúmulos

Luego de finalizado el proceso de iteración, descrito en la sección 3.2 es probable poder observar la presencia de cúmulos en *imagenBinaria*. Esto se produce cuando cambios bruscos en la iluminación de zonas cercanas a la fibra son detectadas por la varianza. Al realizar la iteración se produce un efecto de desborde de la fibra sobre estas zonas.

En la figura 3.13 se muestra un ejemplo. La *imagenSuperior* se encuentra a la izquierda y la *imagenInferior* se encuentra a la derecha. Con color rojo se encuentran marcados los píxeles sobre los cuales se producirán los desbordes durante la iteración. Como se describió en secciones anteriores, la iteración comienza con cada píxel *true* de la *imagenSuperior*, para cada uno de ellos se busca en los píxeles adyacentes pero de *imagenInferior*, si hay algún píxel *true*, entonces esos píxeles son marcados como *true* en *imagenBinaria*.




Figura 3.13: Generación de cúmulos

Para la eliminación de estos cúmulos se realiza el siguiente procedimiento: Se recorre la *imagenBinaria*, para cada punto marcado en dicha imagen se traza un cuadrado centrado en el mismo. Para cada cuadrado se cuenta la cantidad de píxeles blancos presentes; si este número excede un determinado nivel se pinta todo el cuadrado de negro. Esto se justifica observando que, debido al fino espesor de las fibras, la superficie ocupada por la misma dentro de un cuadrado siempre es relativamente pequeña con respecto al área de cuadrado, a diferencia de un cúmulo que puede llegar a ocuparlo totalmente.




Figura 3.14: Eliminación de cúmulos

En la figura 3.14 se puede observar cómo se realiza la elección de los puntos que se van a eliminar (cuadrados en rojo), los puntos que no se eliminarán son los que se encuentran dentro de los cuadrados de color verde.

Este método presenta fallas en algunos casos. Cuando la fibra presenta cúmulos en su zona media la misma puede ser seccionada, dado que el método elimina dichos cúmulos sin importar si la fibra pertenece al mismo. En la figura 3.15 se presenta un ejemplo de dicho problema.




Figura 3.15: Eliminación de cúmulos (caso de falla), cúmulo en el centro de un fibra

En la figura 3.16 se aprecia cómo el método secciona la fibra.

Este problema de seccionamiento es superado por un bloque posterior en el cual se unen las fibras.




Figura 3.16: Eliminación de cúmulos (caso de falla), fibra seccionada al eliminar cúmulos

3.6. Detección de extremos

Conociendo los extremos de las fibras resulta más sencillo poder encontrar puntos representativos de las mismas. Por ejemplo se puede comenzar a recorrer la fibra desde un extremo y tomar puntos intermedios hasta llegar al otro extremo (dentro una misma región conexa). Por lo tanto, previo a la identificación de las diferentes fibras se hace necesario identificar los extremos de cada una de ellas.

Para esto se procede a etiquetar las diferentes zonas conexas de *imagenBinaria*.

Para cada píxel de *imagenBinaria* marcado como perteneciente a una fibra, se traza una circunferencia de radio R y centro (i,j) , esto se muestra en la figura 3.17. Luego se intersecta la circunferencia con *imagenBinaria*, considerándose




Figura 3.17: Trazado de circunferencias.

sólo las intersecciones que pertenecen a la misma región que el centro de la circunferencia.

Se distinguen algunos casos:

- En caso que la intersección de como resultado un sola región conexa, entonces se traza una nueva circunferencia de radio r (menor que R) con el mismo centro. Si la intersección de la nueva circunferencia es también una única región conexa, entonces el centro es marcado como punta.
- En caso que la intersección de como resultado más de una región conexa con la misma etiqueta, entonces se considera que el centro no es un ex-

tremo.

En la figura 3.17 el punto **b** será considerado extremo, mientras que el punto **a** no lo será.

Los motivos de la necesidad del trazado de dos circunferencias son dos. En primer lugar evitar que se presenten falsos extremos debido a pequeños seccionamientos de la fibra (en general no mayores de un píxel). En segundo lugar marcar como extremo un punto lo más cercano a la punta de la fibra, por motivos que quedarán claros en las secciones posteriores de este documento.

Los resultados se muestran en la figura 3.18.




Figura 3.18: Detección de extremos

3.7. Corrección de discontinuidades en las fibras

En varias ocasiones se puede observar que en *imagenBinaria* se encuentran pequeñas discontinuidades en las fibras coloreadas.

Un ejemplo de este problema se muestra en la figura 3.19. Estas discontinuidades




Figura 3.19: Fibras segmentadas

están asociadas en la mayoría de los casos al algoritmo utilizado, pero en otras

ocasiones sucede debido a que segmentos de las fibras coloreadas quedan ocultos detrás de una muestra blanca de lana.

El siguiente algoritmo soluciona algunos cortes de fibras donde se cumplen algunas condiciones que ameritan unir ambas puntas.

Para unir una fibra se tienen que cumplir las siguientes condiciones.

- Las puntas a unir tienen que distar menos de $2 \times R$, siendo R el radio que se utilizó para encontrar las puntas de las fibras (ver sección 3.6). En la figura 3.20, se puede apreciar la unión de dos puntas separadas la máxima distancia posible ($2 \times R$).
- Las pendientes sobre los extremos de las fibras (recta 1 y recta 2) tienen que ser similares con un margen de tolerancia, figura 3.20.
- La pendiente de una recta trazada entre las dos puntas (recta 3), tiene que ser similar a alguna de las pendientes antes mencionadas, con cierto margen de tolerancia, figura 3.20.




Figura 3.20: Distancias y pendientes

Para verificar los ítems anteriores se realiza el siguiente algoritmo. Primero se seleccionan todos los pares de puntas que distan menos de $2 \times R$ y no pertenecen a la misma zona conexa. Luego se ordenan los más cercanos, o sea, si hay dos puntos (P1 y P2) que distan de un tercer punto (P3) menos de $2 \times R$, se toma como pareja los dos más cercanos (P1 y P3), figura 3.21.




Figura 3.21: Distancias entre fibras

Segundo, se traza una circunferencia en cada punta (P1 y P2). Se encuentra la intersección entre esta circunferencia y la zona predetectada (P11 y P22), figura 3.22, estos puntos serán utilizados para el cálculo de las pendientes en las puntas de las fibras .




Figura 3.22: Cálculo de puntos

Se ordenan los puntos para obtener los vectores directores de las rectas a trazar, de la forma que se muestra en la figura 3.24, en donde se puede apreciar que se toma en un caso, como la punta del vector a la punta de la fibra, y como la cola del vector, a la intersección con la fibra. El otro vector director tiene los puntos elegidos de manera inversa.

La forma de construir los vectores permite diferenciar casos en los que los vectores tienen dirección similar pero sentidos diferentes, lo que se busca para unir puntas es que coincidan tanto en dirección como sentido . Finalmente, se calcula la pendiente que tiene la recta trazada entre P1 y P2 (figura 3.23), si esta pendiente es similar a la pendiente de las rectas trazadas anteriormente por P1, y P2, se unen dichas puntas. De esta forma se evita unir fibras que si bien presentan la misma pendiente en sus puntas y distan entre sí menos de $2 \times R$, no están enfrentadas como para ser unidas (figura 3.24).

Con este algoritmo se unen correctamente gran cantidad de trozos de fibras que se cortaron en etapas anteriores de procesamiento.




Figura 3.23: Vectores directores



Figura 3.24: Vectores directores

3.8. Cálculo de los puntos representativos de cada fibra

Una vez encontradas las puntas de cada fibra, y las zonas de la imagen donde están las fibras (de aquí en mas las denominaremos zonas predetectadas), el próximo paso sería, ayudados con estos datos, individualizar cada fibra. Lo anterior no es un tema menor dado que hay casos en que las fibras presentan cruces, como se indica en la figura 3.25, lo cual implica que sus zonas predetectadas forman una única región conexa, lo que imposibilita individualizar las fibras. Para sortear este problema se realiza una selección de puntos sobre las zonas predetectadas que individualizan cada fibra.




Figura 3.25: Dos fibras que se cruzan

En esta sección se explica cuál es el procedimiento seguido para la obtención de este conjunto de puntos de una determinada fibra, llamados en el resto del documento *puntos representativos de la fibra*. Se comienza trazando una circunferencia (de radio r) con centro en una de las puntas de la fibra (punto A, figura




Figura 3.26: Trazado de rectas para el primer punto.

3.26), se encuentra la intersección de la circunferencia con la fibra (punto C). Luego se traza una recta por los dos puntos anteriores (A y C); con centro en C se traza una semicircunferencia simétrica respecto a la recta (figura 3.27). La intersección de la semicircunferencia con la zona predetectada (punto D) se marca como un punto representativo de la fibra.




Figura 3.27: Elección de puntos representativos.

En el próximo paso se toman los puntos C y D y luego se procede igual que en el paso anterior, ver figura 3.28. Se continúa este procedimiento hasta que




Figura 3.28: Trazado de semi-circunferencias.

no se intersecta a ningún punto de la zona predetectada, lo que significa que se está en el final de una fibra.

Dado que cada fibra tiene dos puntas, este procedimiento se repetiría dos veces para cada fibra, lo que implicaría contarla dos veces. Para evitarlo, al encontrar el último punto representativo de una fibra, se eliminan las puntas (que fueron halladas en la etapa de detección de extremos, sección 3.6) que distan menos de un radio R de dicho punto.

Se presenta el problema del cruces de fibras diferentes, por ejemplo como se

muestra en la figura 3.29.

El problema se resuelve tomando el siguiente criterio: cuando se traza una semi-




Figura 3.29: Elección de puntos representativos cuando se produce un cruce de fibras

circunferencia con centro cercano al cruce de las fibras, se van a tener dos o más intersecciones con la zona predetectada (figura 3.29) . Se va a considerar punto representativo de la fibra a aquel que esté más cerca del punto de intersección de la recta anterior con la semicircunferencia, punto **A** de la figura 3.29, la recta anterior es la que une los últimos dos puntos representativos encontrados. De esta forma se logra desacoplar dos o más fibras cruzadas. El método funciona correctamente en los cruces de fibras, suponiendo que la fibra no cambia demasiado su pendiente en el entorno del punto de cruce. En la figura 3.29 se puede observar como el algoritmo es capaz de tomar el camino correcto mientras se cumpla dicho supuesto.

En el caso de que no se cumpla el comportamiento supuesto, este método puede fallar , como se indica en la figura 3.30, en el cual el punto **B** está más cerca de **a** que de **A**.

El problema se puede solucionar si se achica el radio de la semi-circunferencia,




Figura 3.30: Caso en que falla la elección de puntos representativos.

pero pagando el precio de tener un tiempo mayor de procesamiento debido a que hay que recorrer más puntos de la fibra.

Luego que se tienen identificadas las diferentes fibras mediante sus puntos representativos, el objetivo es identificar el tipo de fibra mediante propiedades de la misma que se detallarán más adelante.

En las siguientes etapas se trabaja con los siguientes supuestos, los cuales son responsabilidad de los bloques anteriores:

- Imagen submuestreada binaria en donde se predetectaron las zonas en donde hay fibra.
- Conjunto de puntos que individualizan cada fibra; un conjunto por cada fibra.
- Cada punto distará una distancia R de su antecesor y su predecesor a excepción de las puntas de la fibra.

3.9. Reestablecimiento de dimensiones

Se comenzó el procesamiento con una imagen en escala de grises de tamaño $N \times M$. Luego del procesamiento descrito en secciones anteriores se pasa a trabajar con una imagen binaria 64 veces mas pequeña. Sobre esta imagen binaria se realizó el proceso de predetección de fibras.

Si el único interés fuera contar las fibras coloreadas, con esto sería suficiente, ya que se tiene las fibras individualizadas a través de sus puntos representativos. Como interesa también poder clasificar las fibras según su tipo, se hace necesario obtener características de las fibras que permitan realizar dicha clasificación. Para ello es necesario volver a la imagen original, y valiéndose de la información obtenida en etapas anteriores (puntos representativos, puntas de las fibras, zonas predetectadas), poder medir las características necesarias de las fibras.

Para volver a la imagen original se le asigna a cada píxel el tamaño que representaba en la imagen original cuando fue submuestreada al comienzo del proceso, y de esta forma se retorna a las dimensiones originales. El procedimiento de obtención de las características de las fibras se detalla en las siguientes secciones.

3.10. Trazado de rectas perpendiculares a la fibra

El objetivo de esta parte es lograr tomar una sección de la fibra a la cual se le llama *perfil*, para luego medir propiedades, como el ancho, el valor mínimo y la media de los niveles de gris. En la figura 3.31 se muestra un ejemplo del perfil de una fibra.

Para obtener el perfil se tiene que tomar una sección perpendicular a la fibra, debido a que la medida del ancho requiere esta propiedad. La idea es tomar un perfil por cada punto representativo. El método comienza trazando una circunferencia con centro en uno de los puntos representativos y se halla la intersección




Figura 3.31: Perfil de la zona perpendicular a la fibra

de la circunferencia con la zona predetectada. De esta forma, se cuenta con dos regiones donde buscar la fibra (zonas 1 y 2). En la figura 3.32 se muestra el procedimiento.



Figura 3.32: Intersección con la zona predetectada

A continuación se selecciona en la zona uno, el píxel con el menor nivel de gris, lo mismo con la zona dos. Seguidamente se traza una cuerda entre estos dos puntos y luego un segmento perpendicular por el centro de la circunferencia, obteniéndose un segmento que corta en forma aproximadamente perpendicular a la fibra. Si se toma como ejemplo la figura 3.33, se puede apreciar como el perfil trazado es casi perpendicular a la fibra. El método anteriormente descrito funciona correctamente bajo el supuesto de que la fibra tenga un comportamiento regular entre los dos puntos de la cuerda. Si este supuesto no se cumple, existe una gran posibilidad de que el segmento trazado no sea perpendicular a la fibra, y de esa manera se distorsione la medida del ancho. Reduciendo el radio de la circunferencia se logra disminuir la posibilidad de que la fibra se comporte de la forma no deseada entre los dos puntos de la cuerda. Esta solución presenta la contraparte de no poder disminuir el radio de la circunferencia todo lo que se quiera, y el límite se da cuando la circunferencia es tangente a la zona

predetectada.




Figura 3.33: Trazado de perpendicular a la fibra

3.11. Caracterización del perfil.

En esta parte del método se cuenta con un segmento aproximadamente perpendicular a la fibra, en donde se puede evaluar el perfil del nivel de gris de la imagen original. En dicho perfil se notan claramente los píxeles que pertenecen a la fibra, debido al pronunciado pico que sobresale de la media de los niveles de gris. Lo antes mencionado se puede apreciar claramente en la figura 3.36.

A través de estos perfiles se busca encontrar alguna medida del ancho y nivel de gris de cada fibra. Si se observan los perfiles de dos fibras de tipos diferentes (por ejemplo una tipo 6 y otra tipo 7), se puede ver que la cantidad de píxeles de ancho que tiene cada una es muy parecida, lo cual hace que la clasificación sea difícil o imposible. Este problema se debe generalmente a que se tiene poca resolución en la imagen. Para mejorar un poco esta situación se hace un sobremuestreo utilizando interpolación bilineal sobre el perfil que se obtiene de cada fibra. Este sobremuestreo permite suavizar el perfil, ya que ahora se tienen más píxeles para representar al mismo. Esto podría permitir encontrar alguna diferencia entre el ancho de las fibras de distinto tipo. Por ejemplo en la figura 3.34 se muestran dos perfiles de dos fibras de distinto tipo (tipos 6 y 7), que dado la poca resolución presentan el mismo valor de ancho y tan solo se diferencian en los niveles de gris (la fibra tipo 7 es más oscura que la tipo 6). Para mejorar la visualización se graficaron los niveles de gris invertidos (la barra más alta es el mínimo valor de gris). Luego de realizada la interpolación aparecen valores intermedios de gris, provocando que los valores de ancho se diferencien de un tipo de fibra a otro. En resumen, lo que se hace es dar más granularidad al perfil (aumentándole la definición), aplicándole un zoom por un factor de n .




Figura 3.34: Comparación de los perfiles con y sin interpolación

Aún realizando la interpolación mencionada anteriormente, no siempre es clara la diferencia entre los anchos de los distintos tipos de fibra.

Si se observa nuevamente la forma del perfil en un entorno del píxel donde se encuentra el mínimo, se puede ver que éste tiene una forma parecida a la de una campana de Gauss. La distribución Gaussiana se caracteriza por dos parámetros, la Desviación Estándar y la media. La desviación estándar es una cierta medida del ancho de la campana, esta se calcula como el entorno a la media en donde la probabilidad es de un 63 por ciento. Las funciones Gaussianas con mayor desviación estándar son más anchas que las que tienen menor desviación estándar. Por lo tanto si se mira al perfil de la fibra como una función gaussiana se puede medir su desviación estándar y con ésta se tiene una estimación del ancho.

Para estos cálculos se trabaja únicamente con un conjunto de píxeles, en un entorno del píxel en donde se da el mínimo (figura 3.35), debido a que el perfil es bastante largo (es largo porque esto hace que la media del nivel de gris a lo largo de un perfil, sea más representativa del nivel medio del entorno de la fibra, que si se toma un perfil corto, ya que en este último caso los valores de gris de la fibra pesan más, la media de gris de un perfil se utiliza en la clasificación de

las fibras como se describe en la sección 5.3.2) y esto no lo hace tan parecido a una Gaussiana, en cambio en el entorno mencionado la semejanza es bastante buena.




Figura 3.35: Intersección con la zona predetectada

Para esto lo que se hace es invertir el perfil (dado que el pico se da en el mínimo valor de gris), esto es, hacer que el pico quede hacia arriba, únicamente para mejor manejo. Luego de esto se normaliza el perfil para que la suma de todos sus valores dé 1, ya que una condición de la gaussiana es que el área bajo la curva vale 1. Una vez hecho esto se pasa a medir la desviación estándar, lo cual se hace sumando las áreas que encierran los puntos en el entorno del pico, hasta que dicha suma valga 0.63 que es la condición de la desviación estándar.




Figura 3.36: Medida del ancho de la fibra

Se toma como ancho de cada perfil el valor obtenido para la desviación estándar. Si se promedian todos los anchos obtenidos, uno por cada punto representativo, entonces se tiene una aproximación del ancho en píxeles de la fibra.

Se puede observar en las figuras 3.37, 3.38, 3.39 y 3.40 (donde se muestran

perfiles de fibras de distinto tipo), la escasa diferencia entre los anchos de las fibras de distinto tipo. Ocurre otro problema con el ancho de las fibras, y es que el mismo puede ser muy irregular dentro de una misma fibra, esto es, que una fibra tipo 8 tiene zonas anchas como la mayoría de su tipo pero posee zonas que tienen anchos de tipo 5; esta fuerte variación en el ancho imposibilita al método poder discernir entre tipos de fibras sólo tomando el ancho de la fibra.

Se puede agregar que este problema se debe en parte a la poca resolución




Figura 3.37: perfiles fibra tipo 5




Figura 3.38: perfiles fibra tipo 6

de las muestras y al cruce se fibras blancas que produce fuertes variaciones en el ancho de la fibra dado que las fibras quedan más claras debido al cruce de dichas fibras. Para tener un mejor rechazo a este problema se propone la implementación de capturas de imágenes con tolueno.




Figura 3.39: perfiles fibra tipo 7




Figura 3.40: perfiles fibra tipo 8

3.12. Depuración final

Luego de la detección de las fibras surge otro problema debido a que en algunas regiones se detectan más puntas de las realmente existentes, debido por ejemplo a la forma de las zonas predetectadas, como en la figura 3.41 donde se observa una fibra con más de dos puntas. Si esas puntas no son eliminadas al llegar al límite de una zona predetectada (sección 3.8) puede suceder que se encuentren dos o más juegos de puntos representativos para una misma fibra, produciendo la detección de falsos positivos (figura 3.42), o sea, se detectan dos o más fibras donde hay una.

Para solucionar este problema se cuenta el número de segmentos (que unen dos puntos representativos consecutivos) en que cada fibra se cruza con las demás, si el número de cruces entre dos fibras es mayor que cierto umbral,




Figura 3.41: Detección incorrecta de puntas




Figura 3.42: Detección de fibras sin eliminar fibras duplicadas

se considera que ambas fibras son la misma, en cuyo caso se elimina la de menor longitud. El umbral está elegido de forma adecuada para eliminar fibras duplicadas, pero no eliminar las que se cruzan pero son diferentes fibras. El resultado de aplicar esta etapa del algoritmo se ve en la figura 3.43, donde se muestra la misma imagen que en las figuras 3.41 y 3.42, pero luego de eliminar las fibras duplicadas.



Figura 3.43: Eliminación de fibras duplicadas

3.13. Método alternativo para trazar las rectas perpendiculares a las fibras

Anteriormente se describió un método para trazar las líneas perpendiculares a las fibras con el objetivo de poder medir el ancho y nivel de gris de las mismas. Unos de los problemas más difíciles de resolver era justamente, tratar de atravesar la fibra de la forma más perpendicular posible. El método mencionado anteriormente se desenvuelve bastante bien, pero en algunos casos que ya fueron mencionados no es tan exacto. Estos casos dependen mucho de la forma de la fibra en un entorno al punto en donde cruza esa perpendicular.

El método alternativo aquí planteado trata de resolver, o por lo menos paliar lo más posible esta dificultad. El mismo se explica a continuación: Hasta el momento, antes de trazar la perpendicular se cuenta con la zona predetectada ya en su tamaño original, también se tiene la imagen original en escala de gris y el punto representativo, el cual se encuentra dentro de la zona predetectada. El próximo paso es el mismo que se da en el método anterior, en el cual se traza una circunferencia con centro en el punto representativo, y un radio con el cual se asegura que corta a la zona predetectada en dos regiones, como se ilustra en la figura 3.44




Figura 3.44: Identificación del punto de la fibra.

Luego de esto se toma únicamente una de las dos regiones y se encuentra el píxel en donde se da el menor valor de gris, píxel m en la figura 3.44. Al ser los niveles de gris de la fibra más oscuros que los del fondo, y al estar dentro de la zona predetectada, es seguro que este punto pertenece a la fibra. Por dicho punto únicamente cruzan cuatro rectas, y se sabe que la recta que genere el menor perfil es la más perpendicular a la fibra, esto se muestra en la figura 3.45.




Figura 3.45: Rectas que atraviesan la fibra por un determinado píxel.

Por lo tanto se toman los cuatro perfiles y se calcula el ancho en cada uno, tomando como valor representativo del ancho de la fibra el mínimo de estos valores.

Capítulo 4

Validación del algoritmo de detección

La validación del algoritmo se realiza utilizando las bases A y B . El entrenamiento del algoritmo se realizó utilizando la base C .

Se considera que el algoritmo funciona correctamente si es posible detectar uno o más puntos representativos de cada fibra, como se muestra en la figura 4.1. Se considera que existe un falso positivo cuando se detectan puntos representativos en un lugar donde no existen fibras, como se muestra en la figura 4.2. Se considera que existe un falso negativo cuando no son detectados puntos representativos en un lugar donde deberían existir los mismos, como se muestra en la figura 4.3.




Figura 4.1: Detección correcta de puntos representativos

La base $A1$ contiene un total de 21 fibras coloreadas, entre las cuales se encuentran 4 fibras tipo 5, 4 fibras tipo 6, 6 fibras tipo 7 y 8 fibras tipo 8.

La base B contiene un total de 122 fibras coloreadas, entre las cuales se encuentran 16 fibras tipo 5, 29 fibras tipo 6, 42 fibras tipo 7, 31 fibras tipo 8 y 4 fibras contaminantes (de otro material).




Figura 4.2: Falsos positivos en detección de puntos representativos




Figura 4.3: Falsos negativos en detección de puntos representativos

La base $A2$ contiene un total de 58 fibras coloreadas, entre las cuales se encuentran 12 fibras tipo 5, 11 fibras tipo 6, 19 fibras tipo 7, 13 fibras tipo 8 y 3 fibras contaminantes.

La base C contiene un total de 52 fibras de las cuales se encuentran 8 fibras tipo 5, 11 fibras tipo 6, 17 fibras tipo 7 y 16 fibras tipo 8.

En algunas imágenes se puede apreciar la presencia de falsos positivos. En la base B se presentan 10 de estos casos y en la base A sucede 5 veces. Si se analizan cuidadosamente estos casos, se puede apreciar que en todos los casos donde se presentan falsos positivos es porque efectivamente se puede detectar la presencia de una fibra o un contaminante con las mismas características morfológicas de la fibra. En la figura 4.4 se muestra un ejemplo de esto.

En las tablas 4.1, 4.2 y 4.3 se muestra el porcentaje de acierto por tipo de fibra para las bases $A1$, $A2$ y B . En la tabla 4.4 se muestra el porcentaje de aciertos para el total de fibras (agrupando las bases antes mencionadas).

A partir de estos resultados se pueden realizar las siguientes observaciones:

- Las fibras tipo 8 presentan el mayor porcentaje de acierto, el cual va




Figura 4.4: Falsos positivos en detección de puntos representativos

Cuadro 4.1: Validación de la base **B**

	Total de Fibras	Fibras Detectadas Correctamente	Porcentaje de Aciertos
Fibras Tipo 5	16	12	75
Fibras Tipo 6	30	29	96.7
Fibras Tipo 7	43	42	97.7
Fibras Tipo 8	31	31	100
Fibras Contaminantes	5	4	80

Cuadro 4.2: Validación de la base **A1**

	Total de Fibras	Fibras Detectadas Correctamente	Porcentaje
Fibras Tipo 5	4	4	100
Fibras Tipo 6	4	3	75
Fibras Tipo 7	6	5	83.4
Fibras Tipo 8	8	8	100

disminuyendo a medida que disminuye el tipo de fibra, siendo las tipo 5 las que presentan menor porcentaje. Esto es razonable debido a que las fibras tipo 8 presentan un contraste mayor respecto al fondo, mientras que las fibras tipo 5 se confunden más con el mismo, estando en el límite de lo que se considera una fibra coloreada, siendo lógico que los umbrales utilizados descarten algunas de estas fibras.

Cuadro 4.3: Validación de la base **A2**

	Total de Fibras	Fibras Detectadas Correctamente	Porcentaje de Aciertos
Fibras Tipo 5	12	10	83.4
Fibras Tipo 6	11	11	100
Fibras Tipo 7	19	18	94.8
Fibras Tipo 8	13	13	100
Fibras Contaminantes	3	2	66.7

Cuadro 4.4: Validación para todas las bases

	Total de Fibras	Fibras Detectadas Correctamente	Porcentaje de Aciertos
Fibras Tipo 5	32	26	81.25
Fibras Tipo 6	45	43	95.56
Fibras Tipo 7	68	65	95.59
Fibras Tipo 8	52	52	100

- El porcentaje de acierto para las fibras contaminantes es del 75 por ciento. Esto puede ser considerado un porcentaje aceptable teniendo en cuenta que el algoritmo no fue entrenado para trabajar con este tipo de fibras.
- El porcentaje general de aciertos (para todos los tipos de fibras) es del 94.42 por ciento. Este es un buen resultado. El único tipo de fibra que se aleja significativamente de este porcentaje es el tipo 5, pero las fibras de este tipo representan sólo el 16 por ciento del total.

Capítulo 5

Clasificación

5.1. Clasificación de fibras

5.1.1. Introducción

Luego de la detección de las fibras, se busca clasificarlas, esto es, ubicarlas en una de las cuatro categorías: tipo 5, 6, 7 u 8, que son los tipos de fibra que se contabilizan como fibras coloreadas. Las fibras tipo 5 son las más tenues y las tipo 8 las más nítidas.

5.2. Planteo del problema

Hay laboratorios donde se realiza la detección, conteo y clasificación de fibras coloreadas. Estas tareas son desarrolladas por técnicos que comparan la muestra de lana con un patrón. Dicho patrón consiste en una fibra de cada tipo dispuestas longitudinalmente como se muestra en la figura 5.1. El técnico compara cada fibra candidata a ser fibra coloreada con el patrón, y determina de esta forma si la fibra se encuentra en una de las cuatro categorías consideradas.

Existen otros métodos de detección y conteo de fibras coloreadas como fue explicado en el capítulo 1, pero este es el método utilizado actualmente en Uruguay, y es el que se utilizó para clasificar las fibras de los bancos de imágenes con los que se trabajó en este proyecto.

No existen estándares sobre las características de los distintos tipos de fibra (ancho, longitud, color, etc.). Esto es, no hay ninguna regla concreta mediante la cual una persona pueda decir que si una determinada fibra cumple determinados requisitos de ancho, longitud, color, etc, entonces es totalmente seguro que dicha fibra sea una fibra coloreada de un determinado tipo. Esto lleva a que el proceso de clasificación sea bastante subjetivo y puede dar resultados diferentes si es realizado por técnicos diferentes. Sin duda que para poder realizar la clasificación mediante un software de forma automática se debe tener bien definido cuándo una fibra es de determinado tipo, y dadas las características del



Figura 5.1: Patrón de fibras

problema planteadas anteriormente, la clasificación por tipo de fibra se torna casi imposible.

A continuación se detallan todos los intentos realizados para lograr la clasificación con sus respectivos resultados.

5.3. Métodos utilizados

En principio las características que permitirían distinguir un tipo de fibra de otro serían su grosor, y nivel de gris o color (según si se trabaja con imágenes en escala de gris o color), por lo que se encaró la tarea de clasificación utilizando principalmente estas características de las fibras, también se tomó en cuenta la longitud de las mismas.

El primer intento de clasificar las fibras coloreadas fue utilizando la información del ancho de las fibras, también se exploró la posibilidad de clasificación a través del nivel de gris de las mismas. Se investigó la posibilidad de vincular la información de gris con la información de ancho, para ello se utilizaron redes neuronales y mínimos cuadrados para ajustar alguna función con los datos de nivel de gris y ancho que permitiera realizar la clasificación. También se exploró la posibilidad de clasificación utilizando el color y la longitud de las fibras. Para extraer la información de ancho y nivel de gris de las fibras, se utilizaron los perfiles trazados sobre las mismas, como se explicó en el capítulo 3. Para la determinación de la longitud, simplemente se suma las distancias euclidianas entre los diferentes puntos representativos de la fibra. Como se detallará en las próximas secciones, se utilizaron distintos conjuntos de imágenes para el ajuste de los parámetros de clasificación, y para la clasificación propiamente dicha. Los

diferentes métodos mencionados se analizan en las siguientes secciones.

5.3.1. Ancho

La primer característica que se tomó en cuenta para realizar la clasificación fue el ancho de las fibras. Debido a que las fibras tienen pocos píxeles de ancho en las imágenes utilizadas (alrededor de 4 píxeles de ancho para las imágenes obtenidas durante el proyecto anterior), se realizó una interpolación bilineal de los perfiles trazados sobre las mismas y se tomó como ancho la desviación estándar de la aproximación del perfil por la densidad de probabilidad de una distribución Gaussiana, que aproxima al pico del perfil, esta aproximación se explica el capítulo 3.

Esto permite que el ancho se calcule con mas precisión. La idea original era que los distintos tipos de fibras iban a tener anchos sensiblemente diferentes, por lo que, eligiendo umbrales adecuados, se podrían diferenciar los cuatro tipos de fibras a través del ancho.

Existe un problema al utilizar los anchos para clasificar, y es que éstos son muy variables, más aún, si tomamos todos los anchos calculados en los distintos perfiles, se hacen prácticamente indistinguibles los distintos tipos de fibras coloreadas, ya que para los cuatro tipos de fibras el rango de valores de ancho es prácticamente el mismo.

Esto se debe a varias causas:

- Las fibras coloreadas están entrecruzadas con el resto de la lana. Esto hace que la fibra aparezca sobre la superficie en algunos tramos, y en otros esté cubierta por diferentes cantidades de lana, por lo que el ancho de una misma fibra es muy variable de un perfil a otro.
- Los perfiles trazados no siempre son totalmente perpendiculares a las fibras, dando valores de ancho un poco mayor que el real. En busca de mejorar en este aspecto se diseñó, pero no se implementó, un método alternativo para trazar las rectas perpendiculares a las fibras, éste se detalla en el capítulo 3.
- El método de cálculo del ancho. Como se explicó anteriormente, el ancho es la desviación estándar de la aproximación del perfil por la densidad de probabilidad de una distribución Gaussiana. Si los efectos explicados anteriormente (primer y segundo ítem) fueran pequeños, el promedio de los anchos entre los diferentes perfiles sería el valor elegido como ancho de la fibra, ya que de esta forma se independizaría dicha medida de posibles errores en perfiles particulares.
Debido al primer efecto (el ocultamiento de la fibra coloreada por parte de las fibras de lana) el promedio del ancho de la fibra en los puntos representativos no es un valor representativo, ya que en regiones donde la fibra no es muy nítida, el ancho disminuye y es mayor donde la fibra coloreada

está más descubierta.

Desde este punto de vista la medida más representativa del ancho sería tomar como tal, al mayor ancho entre los diferentes perfiles, esto es riesgoso debido a que también aparecen anchos grandes en zonas donde la fibra coloreada está totalmente tapada por lana, esto es así porque en esos perfiles la diferencia entre el fondo y la fibra es muy tenue o inexistente, dando una campana de Gauss muy aplanada y por ende una desviación estándar (ancho) grande.

Para solucionar estos problema se tomaron en cuenta los perfiles con un ancho en cierto entorno del ancho máximo, en concreto se toman perfiles en el intervalo: $[k \times \text{máximo ancho}, \text{máximo ancho}]$ con $k = 0.8$ ó 0.9 .

De esta forma se disminuye el error que podría ocurrir si se tomara solo el máximo ancho de entre todos los perfiles como ancho de la fibra, ya que podría darse el caso de que ese perfil no fuera el más representativo del ancho real de la fibra, por las razones expuestas anteriormente (máximos debidos a zonas donde no hay fibra y máximos debidos a perfiles no totalmente perpendiculares a la fibra). Luego se calculó el promedio de esos valores para todas las fibras de un mismo tipo y se eliminaron aquellos valores que están fuera del rango $[\text{Media} - \text{desviación estándar}, \text{Media} + \text{desviación estándar}]$. Con esta medida se persigue el mismo objetivo que al tomar anchos en un entorno del máximo. A los valores que sobrevivieron este proceso se les calculó el promedio, como valor representativo del ancho de las fibras de un tipo dado, y la desviación estándar como medida de la variación del ancho en torno al promedio.

También se consideró como posible método de clasificación, tomar una medida de la variación de los anchos (en particular se tomó la desviación estándar de los anchos calculados en todos los perfiles), ya que podría suponerse que las fibras tenues, al diferenciarse menos del fondo, podrían tener una variación menor en el valor de los diferentes anchos que las mas nítidas, debido a que la imagen es mas homogénea en el entorno de la fibra.

5.3.2. Nivel de gris

Otra característica que a priori permitiría clasificar las fibras es el nivel de gris, ya que a simple vista las fibras tipo 5 son más tenues que las tipo 8, como se muestra en la figura 5.1, se puede esperar encontrar alguna diferencia en el nivel de gris de los distintos tipos de fibras coloreadas. En esta etapa surge el problema de la iluminación no uniforme. Se pueden observar diferentes niveles de iluminación en diferentes imágenes y también dentro de una misma imagen, por lo que los niveles mínimos de gris en cada perfil (que son los valores de los que se está seguros que pertenecen a la fibra) varían mucho considerando fibras de un solo tipo, y se mezclan estos valores si consideramos los diferentes tipos de fibras.

Para independizarse de la iluminación se buscó algún indicador que midiera variaciones, más que valores absolutos. El más adecuado resultó ser la desviación estándar de los mínimos niveles de gris de los perfiles de cada fibra. El mínimo nivel de gris en un perfil es un punto que tiene gran probabilidad de pertenecer a la fibra, es mas, en torno a él es que se calcula el ancho de la fibra. Luego de tener todos los mínimos de los perfiles de una fibra, se calcula su desviación estándar. Con estos datos no se pudo encontrar un umbral para clasificar todos los tipos de fibra, pero si se encontró uno que permite clasificar las fibras agrupándolas en dos categorías, tipo 5 y 6 por un lado, y tipo 7 y 8 por otro.

También se utilizó la diferencia entre la media del nivel de gris y el mínimo de cada perfil. De esta forma se obtiene un mínimo relativo a la iluminación local. Luego de tener esas diferencias para cada perfil, se calculó la desviación estándar de las mismas, tomando ese valor para clasificar las fibras en dos categorías: fibras tipo 5 y 6 por un lado, y 7 y 8 por otro, usando un umbral adecuado.

5.3.3. Ancho y nivel de gris

Se utilizaron dos métodos para relacionar la información de nivel de gris y ancho: Redes Neuronales y Mínimos Cuadrados, los que se explican a continuación.

Redes Neuronales

Las redes neuronales son muy efectivas en algunos problemas de reconocimiento de patrones, y el problema de clasificación es en esencia un problema de reconocimiento de patrones, ya que cada tipo de fibra debe de tener un conjunto de características que la diferencie de las demás.

El hecho que la red neuronal ajuste muchos parámetros (pesos y umbrales), y siga un proceso de entrenamiento (aprendizaje), podría permitir encontrar relaciones entre los datos de entrada (que a su vez permitiría clasificar las fibras), que de otra forma llevaría mucho tiempo encontrar, si es que se encuentra.

Se probaron varios tipos de redes neuronales: backpropagation (feed-forward, cascada, Elman, Time-delay), regresión generalizada, Hopfield, LVQ, perceptrón, probabilísticas, radialbasis, competitivas. Para evaluar si una determinada red podría ser útil a la hora de clasificar las fibras coloreadas, se compara la salida de la etapa de entrenamiento con la salida deseada. En la mayoría de los casos la salida era una constante, independientemente de los datos de entrada, por lo que no servían para clasificar. Los únicos tipos de redes que pasaron la etapa de entrenamiento y dieron algún resultado diferente de una constante fueron las redes Radial Basis y las feed-forward backpropagation (ver apéndice A).

Los datos que se usaron para el entrenamiento de las redes fueron, como entradas, vectores formados por diferentes combinaciones de valores de ancho y nivel de gris, las que se detallan en la sección 5.4, y como salidas, vectores formados por el tipo de fibra correspondiente a cada valor de la entrada. También se investigó la posibilidad de clasificar en dos grupos, por ejemplo fibras tipo 5 y 6 por un lado, y tipo 7 y 8 por otro, siendo en este caso las salidas vectores con valores 0 y 1, o 1 y 2.

Para realizar la construcción y entrenamiento de estas redes, y la posterior simulación con las mismas se utilizó la rutina *nntool* de *Matlab*.

Mínimos cuadrados

Se utilizó el método de mínimos cuadrados para aproximar funciones de la forma:

$$\alpha \times x + \beta \times y = \text{tipo de fibra}$$

Donde x e y son vectores que contienen datos de ancho y nivel de gris, α y β son constantes a determinar por medio de mínimos cuadrados. Se probó con relaciones lineales entre variables ya que las redes neuronales que lograron clasificar mejor las fibras, tenían transferencias lineales en sus capas internas.

El objetivo fue encontrar los pesos α y β , que permitieran, al aplicárselos a valores de x e y correspondientes a un tipo de fibra, obtener como resultado dicho tipo. También se probó encontrar α y β diferentes para cada tipo de fibra, y luego para saber si una pareja de valores x e y pertenecían a un tipo de fibra, aplicarles los diferentes valores de α y β a x e y , y comparar en cada caso cuánto se alejaba el resultado del tipo de fibra correspondiente a esos α y β . Se tomaría como tipo de fibra aquel que se aproximara más al valor *tipo de fibra* correspondiente a esos α y β .

5.3.4. Color

Se estudió la posibilidad de clasificación a través del color, en concreto se investigó si existía alguna diferencia significativa en la intensidad luminosa de las fibras coloreadas utilizando los diferentes canales (R, G, y B) o alguna relación entre los canales RGB y el tipo de fibra.

5.3.5. Longitud

Se hizo una comparación entre los largos de las fibras de los distintos tipos para ver si se encontraba alguna diferencia que pudiera permitir la clasificación.

5.4. Resultados y Análisis

En esta sección se detallarán los resultados cuantitativos de los métodos explicados en la sección anterior, y se hará un análisis de los mismos. En el momento de graficar distribuciones de valores, se supondrá que se comportan siguiendo una distribución normal, por simplicidad, ya que no se dispone de datos sobre la distribución real de los mismos, y la distribución normal permite calcular fácilmente sus momentos de primer orden y también facilita el cálculo de umbrales óptimos, en caso de ser necesario.

5.4.1. Ancho

Primero se considera el promedio y la desviación estándar del ancho de todos los perfiles de cada fibra como forma de clasificación.

Cuadro 5.1: Promedios y desviación estándar del ancho por tipo de fibra

	Tipo 5	Tipo 6	Tipo 7	Tipo 8
Media	36.317	32.099	35.035	32.681
Desviación estándar	6.230	8.712	9.208	10.530

Con los resultados que se muestran en la tabla 5.1 no se puede utilizar el promedio para la clasificación de las fibras coloreadas, ya que la distancia máxima entre los mismos es del entorno de la mitad de la mínima desviación estándar, por lo que no existe un umbral que permita separar claramente dos tipos de fibras.

Observando los valores de la desviación estándar, podría existir alguna posibilidad de clasificación, ya que los valores para cada tipo de fibra están cercanos, pero son un poco diferentes, sobre todo entre el tipo 5 y los otros. Para poder clasificar se tomó cada fibra por separado, y se calculó la desviación estándar del ancho para la misma. Luego se calculó el promedio y la desviación estándar de estos valores para cada tipo de fibra, obteniéndose los valores que se muestran en la 5.2.

Cuadro 5.2: Promedios y desviación estándar de la desviación estándar del ancho por tipo de fibra.

	Tipo 5	Tipo 6	Tipo 7	Tipo 8
Media	5.792	8.213	8.855	9.306
Desviación Estándar	2.179	1.852	1.999	1.353

Para calcular los umbrales entre los diferentes tipos de fibras se utilizó la fórmula del umbral óptimo entre dos Gaussianas:

$$u^2(\sigma_1^2 - \sigma_0^2) + 2u(s_1\sigma_0^2 - s_0\sigma_1^2) + (s_0^2\sigma_1^2 - s_1^2\sigma_0^2) + 2\sigma_0^2\sigma_1^2 \ln\left(\frac{P_0\sigma_1}{P_1\sigma_0}\right) = 0$$

Donde u es el umbral óptimo, s_1 y s_0 son las medias y σ_1 y σ_0 las varianzas del ancho para los dos tipos de fibras entre las cuales se quiere calcular el umbral. P_1 y P_0 son las probabilidad de ocurrencia de cada tipo de fibra.

Los porcentajes de cada tipo de fibra se encontraron calculando cuantas fibras de ese tipo hay con relación al total, en las bases A1, A2, B y C. Los valores se muestran en la tabla 5.3.

Cuadro 5.3: Porcentajes de existencia de cada tipo de fibra

	Tipo 5	Tipo 6	Tipo 7	Tipo 8
Porcentajes	16.535	22.047	34.252	27.165

Cuadro 5.4: Umbrales para clasificar fibras utilizando la desviación estándar del ancho.

	Tipo 5 y 6	Tipo 6 y 7	Tipo 7 y 8
Umbral	7.8937	10.2614	9.9409

Se puede observar en los umbrales hallados (tabla 5.4), que dos de ellos caen fuera del rango [media 1, media 2], donde media 1 y media 2 son las medias de las Gaussianas entre las que se quiere encontrar el umbral óptimo. Esto se debe a que el umbral óptimo se da en un punto cercano al punto de corte entre ambas Gaussianas, corriéndose hacia la derecha de dicho punto en el caso del umbral entre fibras tipo 6 y 7, y hacia la izquierda en el caso del umbral entre fibras 7 y 8, debido a que la probabilidad de las fibras tipo 7 es mayor que las probabilidades de los demás tipos (el umbral se da exactamente en el punto de corte cuando las probabilidades son iguales). En la figura 5.2 se puede ver esto gráficamente, también se aprecia como los valores de los tipo 6, 7 y 8 están mezclados, no pudiéndose encontrar umbrales que separen las fibras de los tres tipos de forma que permita una clasificación con un porcentaje alto de acierto, ya que cualquier umbral que se eligiera dejaría un número significativo de fibras mal clasificadas, esto se puede ilustrar utilizando el umbral óptimo calculado para separar las fibras 5 de las 6, en la mitad de las fibras de cada uno de esos tipos de la base B que se dejaron para testear la clasificación. Los resultados se muestran en la tabla 5.5.




Figura 5.2: Distribución de la desviación estándar del ancho, por tipo de fibra, (tipo 5 = azul, tipo 6 = rojo, tipo 7 = verde, tipo 8 = amarillo).

Cuadro 5.5: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6, utilizando desviación estándar del ancho, con el umbral 7.8937

	Tipo 5	Tipo 6
Aciertos (cantidad de fibras/porcentaje)	3 (75 por ciento)	5 (38,5 por ciento)
Errores (cantidad de fibras/porcentaje)	1 (25 por ciento)	8 (61,5 por ciento)

Como se observa en la tabla 5.5, hay un 75 por ciento de acierto en la clasificación de las fibras tipo 5, y un 38.5 por ciento de acierto en las fibras tipo 6, el segundo valor es inaceptable, ya que incluso está por debajo del porcentaje que se obtendría con una clasificación al azar, tomando cada dos fibras tipo 6 una como correcta y otra como errónea (50 por ciento). Con este ejemplo se puede observar que esta forma de clasificación no sirve, porque si no es posible clasificar satisfactoriamente entre los dos tipos de fibra que presentan una separación mayor entre sus valores, menos se va a conseguir al intentar diferenciar entre otros tipos de fibra.

Como se explicó anteriormente, por cada fibra se tomaron aquellos anchos que están en un entorno del máximo ($[k \times \text{máximo ancho}, \text{máximo ancho}]$, con $k = 0,8$ ó $0,9$). Luego se calculó el promedio de esos valores, y se eliminaron aquellos que están fuera del rango $[\text{Media} - \text{desviación estándar}, \text{Media} + \text{desviación estándar}]$. Con los valores resultantes se calculó la Media y la desviación estándar. Los resultados obtenidos se muestran en la tabla 5.6. Esto se puede ver gráficamente en las figuras 5.3 y 5.4.

Cuadro 5.6: Media y desviación estándar por tipo de fibra para $k = 0,8$ y $k = 0,9$

	Tipo 5	Tipo 6	Tipo 7	Tipo 8
Media con $K = 0,8$	38.333	50.278	49.900	48.163
desviación estándar con $K = 0,8$	2.929	2.137	2.318	3.031
Media con $K = 0,9$	42.875	51.571	52.481	51.714
desviación estándar con $K = 0,9$	3.643	1.869	1.649	2.580




Figura 5.3: Distribución del ancho por tipo de fibra, para $k = 0,8$ (tipo 5 = azul, tipo 6 = rojo, tipo 7 = verde, tipo 8 = amarillo).

Con los datos anteriores se puede ver que el único tipo de fibra que se separa más claramente del resto es el tipo 5. Los tres tipos restantes aparecen bastante mezclados entre sí, mas aún, si se comparan los resultados para $k = 0,8$ y $k = 0,9$ se puede ver que la media del tipo 8 es menor que las de los tipo 6 y 7. Al aumentar k , lo que se hace es considerar menos perfiles para el cálculo del ancho de la fibra, por lo que el resultado obtenido no mejora aumentando k , ya que para $k = 0,9$ la mayor parte de las fibras solo tiene uno o dos perfiles en el rango $[k \times \text{máximo ancho}, \text{máximo ancho}]$. Aparece el mismo tipo de problema que ya se analizó al considerar la desviación estándar del ancho, al aparecer las distribuciones de los valores muy mezcladas entre sí. Como en ese caso la única diferenciación posible es entre fibras tipo 5 y 6.

Se realiza el cálculo para $k = 0,8$, que es el que presenta una mayor separación entre las medias de los tipos de fibra 5 y 6. El umbral óptimo es 45,5579. Con este umbral se clasifican las fibras de la *base B* que se dejaron para esa




Figura 5.4: Distribución del ancho por tipo de fibra, para $k = 0,9$ (tipo 5 = azul, tipo 6 = rojo, tipo 7 = verde, tipo 8 = amarillo)

tarea, tomándose para cada fibra aquellos anchos que están en un entorno del máximo $[0,8 \times \text{máximo ancho}, \text{máximo ancho}]$. Luego se calculó el promedio de esos valores, y se eliminaron aquellos que están fuera del rango $[\text{Media} - \text{desviación estándar}, \text{Media} + \text{desviación estándar}]$. Con los valores resultantes se calculó la Media y se comparó con el umbral. Los resultados obtenidos se muestran en la tabla 5.7.

Cuadro 5.7: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6, utilizando anchos máximos, con el umbral 45.5579

	Tipo 5	Tipo 6
Aciertos (cantidad de fibras)	2	10
Errores (cantidad de fibras)	2	3

El porcentaje de acierto para el cálculo anterior es de 50 por ciento para las fibra tipo 5, y 77 por ciento para las fibras tipo 6. Este resultado es inaceptable ya que no permite clasificar bien las fibras tipo 5. Además no es posible una clasificación entre los tipos 6, 7 y 8.

Con los métodos anteriores no se puede lograr una clasificación adecuada de las fibras, ya que no se pueden encontrar umbrales que permitan diferenciar claramente los cuatro tipos de fibra.

5.4.2. Nivel de gris

Primero consideramos el promedio y la desviación estándar del mínimo nivel de gris de todos los perfiles de cada fibra como forma de clasificación.

Cuadro 5.8: Promedios y desviación estándar del mínimo nivel de gris por tipo de fibra.

	Tipo 5	Tipo 6	Tipo 7	Tipo 8
Media	144.902	136.322	140.768	131.575
Desviación estándar	5.715	9.579	9.577	17.122

La media no se puede tomar como valor para clasificar debido a que los valores son muy próximos entre los distintos tipos de fibras, considerando las desviaciones estándar respectivas, provocando que los valores de todos los tipos de fibras estén muy mezclados. Esto se puede ver gráficamente en la figura 5.5.




Figura 5.5: Distribución del mínimo de gris por tipo de fibra, (tipo 5 = azul, tipo 6 = rojo, tipo 7 = verde, tipo 8 = amarillo)

Nuevamente, como en el caso del ancho, parece que la desviación estándar podría permitir diferenciar entre los distintos tipos de fibras. Para investigar esta posibilidad se calculó la desviación estándar de los mínimos de cada perfil para todas las fibras, se calculó la media y desviación estándar de estos valores. Lo anterior se hizo para cada tipo de fibra. Los resultados se muestran en la tabla 5.9.

Cuadro 5.9: Promedios y desviación estándar de la desviación estándar del mínimo de gris por tipo de fibra.

	Tipo 5	Tipo 6	Tipo 7	Tipo 8
Media	5.158	8.135	7.663	12.220
desviación estándar	1.192	3.186	3.321	4.596

La representación gráfica de estos valores se puede ver en la figura 5.6.




Figura 5.6: Distribución de la desviación estándar del mínimo de gris por tipo de fibra, (tipo 5 = azul, tipo 6 = rojo, tipo 7 =verde, tipo 8 =amarillo)

El único umbral que tiene sentido calcular es entre las fibra tipo 5 y tipo 8 (los dos extremos), ya que los tipos 6 y 7 son prácticamente indistinguibles entre sí, y tienen sus valores muy mezclados con los de las fibras tipo 5 y 8. El umbral óptimo en este caso es 5.7698. Clasificando las fibras tipo 5 y 8 de la base B, que se reservaron para este propósito, con el umbral óptimo, se obtienen los valores dados en la tabla 5.10.

Cuadro 5.10: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 8, utilizando la desviación estándar del mínimo nivel de gris, con el umbral 5.7698.

	Tipo 5	Tipo 8
Aciertos (cantidad de fibras)	1	13
Errores (cantidad de fibras)	3	0

Este umbral no sirve ya que no clasifica bien las fibras tipo 5. Modificando el umbral para que se clasifiquen de manera correcta la mayor cantidad posible de fibras tipo 5 y 8, se eligió el umbral 8. Si se juntan en una sola categoría las fibras tipo 5 y 6 por un lado, y las tipo 7 y 8 por el otro, con el umbral 8 aplicándolo a la separación entre estas categorías se obtienen los valores dados en la tabla 5.11. Estos resultados se obtuvieron utilizando la mitad de las imágenes de la base B, la otra mitad se utilizó para ajustar el umbral.

Cuadro 5.11: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la desviación estándar del mínimo nivel de gris, con el umbral 8, para la mitad de las imágenes de la base B.

	Tipo 5 - 6	Tipo 7 - 8
Aciertos (cantidad de fibras/porcentaje)	13 (76,5 por ciento)	27 (84,4 por ciento)
Errores (cantidad de fibras/porcentaje)	4 (23,5 por ciento)	5 (15,6 por ciento)

El resultado anterior es una posible forma de clasificación, para corroborar la validez de la misma se hizo la validación también con las bases A1, A2. Los resultados se muestran en las tablas 5.12 y 5.13.

Cuadro 5.12: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la desviación estándar del mínimo nivel de gris, con el umbral 8, para las imágenes de la base A1.

	Tipo 5 - 6	Tipo 7 - 8
Aciertos (cantidad de fibras/porcentaje)	6 (85,7 por ciento)	11 (78,6 por ciento)
Errores (cantidad de fibras/porcentaje)	1 (14,3 por ciento)	3 (21,4 por ciento)

Cuadro 5.13: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la desviación estándar del mínimo nivel de gris, con el umbral 8, para las imágenes de la base A2.

	Tipo 5 - 6	Tipo 7 - 8
Aciertos (cantidad de fibras/porcentaje)	10 (62,5 por ciento)	21 (81 por ciento)
Errores (cantidad de fibras/porcentaje)	6 (37,5 por ciento)	5 (19 por ciento)

Tomando los datos de las base de imágenes A1, A2, y B juntas, se tienen los valores de la tabla 5.14, que son los datos para todas las fibras que se utilizaron para testear el método de clasificación.

Cuadro 5.14: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la desviación estándar del mínimo nivel de gris, con el umbral 8, para las imágenes de las bases A1, A2, y B.

	Tipo 5 - 6	Tipo 7 - 8
Aciertos (cantidad de fibras/porcentaje)	29 (72,5 por ciento)	59 (81,9 por ciento)
Errores (cantidad de fibras/porcentaje)	11 (27,5 por ciento)	13 (18,1 por ciento)

Se analiza ahora el método de clasificación utilizando la desviación estándar de la diferencia entre la media y el mínimo de gris en cada perfil. Con el mismo procedimiento que para la desviación estándar del mínimo nivel de gris, tomando un umbral de 8, se llega el resultado presentado en la tabla 5.15.

Cuadro 5.15: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la desviación estándar de la diferencia entre la media y el mínimo nivel de gris en cada perfil, con el umbral 8, para las imágenes de las bases A1, A2, y B.

	Tipo 5 - 6	Tipo 7 - 8
Aciertos (cantidad de fibras/porcentaje)	34 (85 por ciento)	57 (79,1 por ciento)
Errores (cantidad de fibras/porcentaje)	6 (15 por ciento)	15 (20,9 por ciento)

Se puede apreciar que la mejor clasificación se consigue utilizando la desviación estándar entre la media y el mínimo del nivel de gris.

De las observaciones realizadas anteriormente no se deduce inmediatamente que los métodos de clasificación mostrados (utilizando la desviación estándar del mínimo nivel de gris y la desviación estándar de la diferencia entre media y mínimo nivel de gris), debieran dar porcentajes altos de acierto en la clasificación de fibras agrupándolas en las categorías 5 y 6 por un lado, y 7 y 8 por otro, ya que la diferencia clara está entre las fibras tipo 5 y 8, quedando las tipo 6 y 7 en una región intermedia.

Para analizar más en detalle los resultados obtenidos, se muestra en la tabla 5.16 el porcentaje de error por tipo de fibra, al utilizar el método de la desviación estándar del mínimo nivel de gris de cada perfil, y en la tabla 5.17, el porcentaje de error por tipo de fibra, utilizando el método de la desviación estándar de la diferencia entre media y mínimo nivel de gris de cada perfil.

Cuadro 5.16: Porcentaje de error al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la desviación estándar del mínimo nivel de gris en cada perfil, con umbral 8, para las imágenes de las bases A1, A2, y B.

Tipo de fibra	Error en la clasificación (porcentaje)
5	14.29 por ciento
6	34.61 por ciento
7	25.00 por ciento
8	3.22 por ciento

Cuadro 5.17: Porcentaje de error al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la Desviación Estándar de la diferencia entre media y mínimo nivel de gris en cada perfil, con umbral 8, para las imágenes de las bases A1, A2, y B.

Tipo de fibra	Error en la clasificación (porcentaje)
5	7.14 por ciento
6	19.23 por ciento
7	35.00 por ciento
8	3.22 por ciento

Analizando los datos del método de la Desviación Standard de la diferencia entre media y mínimo nivel de gris en cada perfil: para las fibras tipo 5-6 el porcentaje de error es de 15 por ciento (tabla 5.15), en la tabla 5.17 se puede apreciar que el mayor porcentaje de error se debe al tipo 6, 19.23 por ciento contra 7.14 por ciento del tipo 5. Además, en el resultado final para las fibras tipo 5-6 en conjunto, la influencia del error de las fibras tipo 6 es mayor que el de las fibras tipo 5, ya que el número de fibras tipo 6 es superior al de fibras tipo 5 (26 y 14 respectivamente). Para el tipo 7-8 el porcentaje de error es de 20.9 por ciento (tabla 5.15), en la tabla 5.17 se ve que el mayor porcentaje de error se debe al tipo 7 (35 por ciento), contra 3.22 por ciento del tipo 8. En el resultado final para las fibras tipo 7-8 en conjunto, la influencia del error de las fibras tipo 7 es mayor que el de las fibras tipo 8, ya que el número de fibras tipo 7 es superior al de fibras tipo 8 (41 y 31 respectivamente).

Se puede concluir que los porcentajes de error dados en la tabla 5.15 se deben principalmente a las fibras tipos 6 y 7, lo que era esperable ya que el umbral de clasificación se eligió entre los tipos 5 y 8, quedando las fibras tipo 6 y 7 distribuidas en forma aleatoria en torno a este umbral. Si bien las fibras tipos 6 y 7 presentan un alto porcentaje de error, el umbral elegido permite cierta clasificación de las mismas, dentro de los respectivos grupos 5-6 y 7-8. Con los datos de la tabla 5.17 se puede ver que para las fibras tipo 6 se tiene un porcentaje de acierto de 80.77, y para las tipo 7 el porcentaje de acierto es de 65 por ciento, esta asimetría en los porcentajes de acierto entre ambos tipos de fibras se debe a que la distribución de las Desviaciones Estándar para cada tipo

no es Gaussiana como se muestra en la figura 5.6, sino que tienen las distribuciones mostradas en la figura 5.7, donde se puede observar una separación mayor entre los valores para cada tipo de fibra que si la distribución fuera Gaussiana, permitiendo así clasificar, aunque con porcentajes de acierto no muy altos, las fibras coloreadas en dos categorías, tipos 5 y 6 por un lado, y tipos 7 y 8 por otro.




Figura 5.7: Distribución de la desviación estándar de la diferencia entre media y mínimo de gris por tipo de fibra, (tipo 5 = rojo, tipo 7 = azul).

Los razonamientos anteriores son también aplicables al método de clasificación que utiliza la desviación estándar del mínimo nivel de gris para cada perfil.

5.4.3. Ancho y nivel de gris

El primer criterio fue elegir como valores representativos del ancho de la fibra sólo aquellos que coinciden con puntos donde se da el mínimo nivel de gris o un valor cercano al mismo, asegurándose de esta manera que ese perfil está atravesando una zona donde la fibra es bastante nítida.

Usando redes neuronales.

Como se mencionó en la sección 5.3.3, se probaron diferentes tipos de redes neuronales, y diferentes tipos de datos de entrada y salida. Como datos de entrada se probaron diferentes combinaciones de anchos y nivel de gris, las mismas siempre consistieron de dos vectores, uno con información de ancho, y otro con información de nivel de gris, siendo la salida el tipo de fibra, o en caso de agrupar dos tipos en uno, la salida son dos tipos diferentes de fibras. Las entradas que se utilizaron fueron:

1. Los anchos de todos los perfiles de una fibra en pareja con sus respectivos mínimos de gris.

Una selección de parejas de anchos y mínimos que cumplan ciertos requisitos. Se usaron varios criterios: se seleccionaron anchos que están en el rango $[Media - desviación\ estándar, Media + desviación\ estándar]$, donde la Media y desviación estándar se considera sobre los valores de todos los perfiles. De entre estos valores se seleccionaron los que estaban en el rango $[k \times \text{máximo ancho}, \text{máximo ancho}]$, con $k = 0,8$ ó $0,9$, y los mínimos de gris correspondientes a esos perfiles. Se seleccionaron aquellos mínimos de gris que estuvieran en el rango $[\text{mínimo gris}, \text{mínimo gris} \times k1]$, con $k1 = 1,1$ ó $1,2$, y los anchos correspondientes a esos perfiles. La hipótesis más restrictiva fue tomar por separado los dos criterios para encontrar los anchos y mínimos de gris que se mencionaron anteriormente (anchos en el rango $[k \times \text{máximo ancho}, \text{máximo ancho}]$, y mínimos de gris en el rango $[\text{mínimo gris}, \text{mínimo gris} \times k1]$), y considerar solo aquellos perfiles donde se dan las dos condiciones, en este caso quedaban muy pocas fibras que se pudieran clasificar.

2. La desviación estándar del ancho y la desviación estándar de la diferencia entre la media y el mínimo nivel de gris de cada perfil.

La mayor parte de las redes, o no convergían, o daban salidas inútiles como el mismo valor para cualquier entrada. Las redes que dieron algún resultado diferente fueron las Feed - forward Backpropagation, y las Radial Basis. En las primeras se probaron exhaustivamente todas las variantes de la rutina `nntool` de Matlab en cuanto a funciones de entrenamiento, funciones de adaptación, funciones para estimación del error, funciones de transferencia, cantidad de capas y cantidad de neuronas por capa. Lográndose los mejores resultados para las funciones de entrenamiento, `trainbr`, estimación del error por mínimos cuadrados, dos capas, la primera con transferencia tangente hiperbólica, y la segunda una transferencia lineal, dos neuronas en la primera capa y una en la segunda. La entrada que mejores resultados obtuvo fue un vector con la varianza del ancho y otro con la varianza de la diferencia entre la media y el mínimo nivel de gris de cada perfil.

En la figura 5.8 se observa la salida de la red neuronal, y la salida esperada como ideal utilizando la mitad de las fibras de cada tipo de la base B. En la tabla 5.18 se muestran la media y la desviación estándar de los valores de salida de la red para una clasificación en cuatro categorías. En la tabla 5.19 se muestran los mismos valores pero para una clasificación en dos categorías, juntando los tipos 5 y 6 por un lado, y los tipos 7 y 8 por otro.




Figura 5.8: Entrenamiento de una red neuronal feed-forward backpropagation, con transferencias tansig y lineal (azul, salida deseada, rojo, salida de la red neuronal)

Cuadro 5.18: Media y desviación estándar de los datos de salida de una red neuronal Feed -Forward Backpropagation, para una clasificación en cuatro tipos de fibra.

	Tipo 5	Tipo 6	Tipo 7	Tipo 8
Media	5.911	6.000	6.825	7.157
desviación estándar	0.815	0.352	0.334	0.363

Cuadro 5.19: Media y desviación estándar de los datos de salida de una red neuronal Feed -Forward Backpropagation, para una clasificación en dos tipos de fibra.

	Tipo 5 - 6 (Salida ideal = 1)	Tipo 7 - 8 (Salida ideal = 2)
Media	1.560	1.694
desviación estándar	0.207	0.115

Los datos anteriores son los mejores que se obtuvieron utilizando redes neuronales y no permiten encontrar una clasificación satisfactoria.

Las redes Radial Basis permitieron ajustar perfectamente la curva de en-

trenamiento, pero a la hora de clasificar dieron resultados muy pobres. Esto se debe a que este tipo de redes son ideales para ajustar curvas que pasen por todos los puntos de interés, pero en los lugares intermedios entre esos puntos es impredecible a priori el valor que pueda dar, es similar a ajustar datos que tienen una relación lineal, con un polinomio de grado alto, la curva va a pasar por todos los puntos que se quiera, pero seguramente no va a ser la aproximación óptima, y entre dos datos consecutivos la curva puede tomar valores muy diferentes de ellos.




Figura 5.9: Aproximación de los datos de entrenamiento por parte de una red Radial Basis (azul = salida deseada, rojo = aproximación hecha por la red neuronal)

En las figuras 5.9 y 5.10 se ve un ejemplo de lo dicho anteriormente.

En este caso se trata de una red neuronal Radial Basis con $\text{spread constant} = 1$ y $\text{performance goal} = 10$. La misma se entrenó con la mitad de las fibras de la base B y se testeó con la otra mitad. Los valores de entrada fueron los mismos que para la red Feed - forward Backpropagation mencionada anteriormente, y el target del entrenamiento fue el tipo de fibra. En la figura 5.9 se muestra la aproximación realizada por la red al vector de salida de entrenamiento (si bien modificando spread constant y performance goal se puede lograr un ajuste perfecto, se evitó esto por lo mencionado anteriormente con respecto a las aproximaciones exactas de los puntos de una curva). En la figura 5.10 se puede observar la salida de esa red entrenada, al ponerle como entrada los datos de la otra mitad de la base B. Se puede observar que no es posible realizar ninguna clasificación con esa salida. Este fue el comportamiento general observado en este tipo de redes, un ajuste muy bueno a los datos en el entrenamiento, pero una




Figura 5.10: Simulación con una red neuronal Radial Basis, (azul = salida deseada, rojo = aproximación hecha por la red neuronal)

muy pobre o nula posibilidad de clasificación de otros datos.

3. Mínimos Cuadrados

Se intentó aproximar por mínimos cuadrados un vector formado por la desviación estándar del ancho de cada perfil, y otro con los valores de la desviación estándar de la diferencia entre la media y el mínimo nivel de gris, siguiendo la ecuación:

$$\alpha \times x + \beta \times y = \text{tipo de fibra}$$

x , e y y son los vectores mencionados anteriormente. α y β son los parámetros a ajustar por mínimos cuadrados.

En la figura 5.11 se muestran en azul los datos (tipo de fibra) que se usaron para ajustar α y β . En rojo se ve el resultado de aplicar esos α y β a los vectores x e y . Con este método no se encontró una forma de diferenciar entre los distintos tipos de fibras

5.4.4. Color

Para investigar si había alguna diferencia significativa en el nivel de gris entre los distintos canales (R, G, B) para una misma fibra, se consideró para cada fibra la diferencia entre la media y el mínimo nivel de gris en cada perfil, ya que este valor es el que interesa para clasificar las fibras. Para cada canal se realizó el mismo estudio que se detalló en las secciones anteriores. El canal




Figura 5.11: Aproximación del tipo de fibra por mínimos cuadrados, (azul = salida deseada, rojo = aproximación por mínimos cuadrados)

que dio mejores resultados a la hora de clasificar fue el canal verde. En la tabla 5.19 se muestran los resultados de la clasificación de las fibras de la base para el canal verde.

Cuadro 5.20: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la desviación estándar de la diferencia entre la media y el mínimo nivel de gris, con el umbral 7.9, para las imágenes de la base C, en el canal Verde

	Tipo 5 - 6	Tipo 7 - 8
Aciertos (cantidad de fibras/porcentaje)	11 (73,3 por ciento)	26 (76,5 por ciento)
Errores (cantidad de fibras/porcentaje)	4 (26,7 por ciento)	8 (23,5 por ciento)

En la tabla 19 se muestra la clasificación obtenida para la base C para imágenes en escala de grises.

Como se puede observar en las tablas 5.19 y 5.21, los resultados obtenidos para el canal verde, o imágenes en escala de grises son muy similares. Para los umbrales tomados en esas tablas se clasifica mejor con imágenes en escala de grises ya que los porcentajes para las fibras 5 -6 son iguales, y para las fibras 7-8 son mejores en las imágenes en escala de gris que en las imágenes en que se

Cuadro 5.21: Cantidad de aciertos y errores al clasificar las fibras tipos 5 y 6 por un lado, y las 7 y 8 por otro, utilizando la desviación estándar de la diferencia entre la media y el mínimo nivel de gris, con el umbral 4,7, para las imágenes de la base C, para escala de grises.

	Tipo 5 - 6	Tipo 7 - 8
Aciertos (cantidad de fibras/porcentaje)	11 (73,3 por ciento)	27(79,4 por ciento)
Errores (cantidad de fibras/porcentaje)	4 (26,7 por ciento)	7 (20,6 por ciento)

tomó solo el canal verde. Se puede elegir un umbral en el que las imágenes con solo el canal verde clasifican mejor las fibras 5-6 y se clasifican iguales las 7 -8 con ambos tipos de imágenes. El canal verde es el que mas se debería tener en cuenta, pero no aporta nada significativo sobre las imágenes en escala de gris.

5.4.5. Longitud

Para poder clasificar las fibras por su longitud, se tomó como medida de la misma la cantidad de puntos representativos de cada fibra, ya que la distancia que separa dos puntos representativos consecutivos siempre es la misma (8 píxeles). En la tabla 20 se muestran los resultados para cada tipo de fibra, para la mitad de las fibras de la base B.

Cuadro 5.22: Media y desviación estándar de la longitud, para los diferentes tipos de fibras, para la mitad de las fibras de la base B.

	Tipo 5	Tipo 6	Tipo 7	Tipo 8
Media	16,800	19,091	22,056	25,714
Desviación estándar	4.025	6.935	7.182	6.450

5.5. Conclusiones

Se analizaron exhaustivamente diferentes métodos de clasificación de fibras coloreadas utilizando los datos de ancho y nivel de gris de los perfiles de cada fibra. No se encontró ningún método de clasificación que diera resultados satisfactorios utilizando los datos del ancho de las fibras. Se encontraron métodos de clasificación con un alto porcentaje de acierto utilizando la información del nivel de gris de las fibras. En concreto se utilizó la desviación estándar de la diferencia entre media y mínimo del nivel de gris de cada perfil.

No se encontraron estadísticas sobre la precisión de un técnico en la detección y clasificación de fibras coloreadas, esto es, comparación entre los dictámenes de diferentes técnicos sobre una misma muestra de lana, por lo que no se sabe qué margen de error tiene la clasificación de las fibras de las bases de imágenes,




Figura 5.12: Distribución de la longitud para cada tipo de fibra (tipo 5 = azul, tipo 6 = rojo, tipo 7 =verde, tipo 8 =amarillo)

pero sin duda la clasificación no es infalible ya que depende de comparaciones subjetivas.

Teniendo en cuenta el comentario anterior, vale aclarar que los porcentajes de acierto obtenidos en los diferentes métodos de clasificación analizados son relativos, debido a que ésta clasificación daría porcentajes de acierto diferentes si el banco de imágenes utilizado hubiera sido evaluado por diferentes técnicos.

Capítulo 6

Documentación del Software.

En este capítulo se realiza una breve descripción del software realizado. La descripción se realiza en tres secciones. En primer lugar se realiza una breve descripción de las clases definidas, en la segunda sección se describen funciones que conforman el software. En tercer lugar se explica el funcionamiento de la interfaz gráfica.

6.1. Descripción de las clases implementadas

► Fibra

Esta clase guarda las características principales de una fibra. Las variables más relevantes de esta clase son:

- `puntos_representativos_x`.
Guarda las coordenadas horizontales de los puntos representativos de la fibra.
- `puntos_representativos_y`.
Guarda las coordenadas verticales de los puntos representativos de la fibra.
- `cantidad_de_puntos`.
Guarda la cantidad de puntos representativos de la fibra.
- `varianza_perfil`.
Guarda la desviación estándar de la curva de Gauss equivalente para cada perfil de la fibra, como se explica en el capítulo 3.
- `media_perfil`.
Guarda la media del nivel de gris de cada perfil.
- `minimo_perfil`.
Guarda el mínimo valor del nivel de gris de cada perfil.

- diferencia.
Guarda la diferencia entre el nivel medio de gris y el mínimo para cada perfil de la fibra.
- tipo.
Guarda la clasificación del tipo de fibra coloreada.
- estimador.
Guarda un valor utilizado como estimador para determinar el tipo de fibra.

► CMatriz

Esta clase tiene como componente fundamental un arreglo de tamaño variable donde son guardados de manera lineal los valores de determinada matriz. En el algoritmo, esta clase es utilizada para guardar la imagen que es procesada para encontrar las fibras coloreadas. Las variables más importantes de esta clase son:

- filas.
Representa la cantidad de filas de la matriz.
- columnas.
Representa la cantidad de columnas de la matriz.
- imagen.
Es un arreglo de tamaño $filas \times columnas$ en el cual es guardada en forma lineal una matriz de valores que van desde 0 a 255.

► CMatrizBinaria

Esta clase es similar a la anterior. Tiene como componente principal un arreglo en el cual se puede guardar de manera lineal los valores de una matriz binaria.

- filas.
Representa la cantidad de filas de la matriz.
- columnas.
Representa la cantidad de columnas de la matriz.
- imagen.
Es un arreglo de tamaño $filas \times columnas$ en el cual es guardada en forma lineal una matriz de valores 0 ó 1.
- numero_fibras.
Se utiliza para guardar la cantidad de fibras.
- indice_puntas.
Guarda la cantidad de puntas de fibras detectadas, como se explica en el capítulo 3.
- coordenadas_puntas_x.
Guarda las coordenadas horizontales de las puntas de las fibras.
- coordenadas_puntas_y.
Guarda las coordenadas verticales de las puntas de las fibras.

6.2. Descripción de la funciones implementadas

En esta sección se realiza una breve descripción de las funciones implementadas en el algoritmo. El objetivo es dar una idea general de lo que realiza cada función, si se desea tener un entendimiento más fino se deberá recurrir a la lectura del código fuente.

► AplicarUmbralSup

```
void AplicarUmbralSup(CMatriz *original, CMatriz *resultado, unsigned char umbral)
```

Aplica un umbral a *original* para eliminar brillos y el resultado lo devuelve en *resultado*. Si el valor del píxel (i, j) de *original* es mayor que el umbral, entonces el píxel (i, j) de *resultado* lo iguala al valor de la media de *original*. En el caso contrario el valor del píxel (i, j) de *original* es copiado en el píxel (i, j) de *resultado*.

► AplicarUmbralVar

```
void AplicarUmbralVar (CMatriz *original, bool *resultado, double umbral)
```

Aplica un el umbral a *original* y el resultado lo devuelve en *resultado*, la cual es una matriz binaria. Si el valor del píxel (i, j) de *original* es mayor o igual que el umbral, el píxel **resultado*(i, j) pasa a valer 1 y si es menor vale 0.

► AproximarPorRectas

```
void AproximarPorRectas (CMatrizBinaria *datos)
```

Dada la matriz **datos* en la cual se encuentran las fibras detectadas, esta función se encarga de aproximar estas fibras por segmentos de recta. Utiliza para esto los extremos de las fibras, los cuales fueron detectados por la función *Cefa*.

► Binarizacion

```
void Binarizacion (CMatriz *original, CMatrizBinaria *binaria)
```

Transforma la imagen *original* en escala de grises de tamaño 1536 x 2048 en la imagen *binaria* binaria de tamaño 192 x 256, calculando la varianza

de bloques de tamaño 8 x 8 de la imagen original y aplicando umbrales. En la matriz *binaria* se puede identificar claramente lo píxeles que componen cada fibra coloreada.

► BloqueImagenChica

void *BloqueImagenChica* (int *i*, int *j*, unsigned char **punteroOriginal*, unsigned char **punteroResultado*)

En *punteroResultado* se devuelve un bloque de la imagen apuntada por *punteroOriginal* de tamaño L x L comenzando en las coordenadas (*i*, *j*).

► Bloques

void *Bloques* (CMatriz **original*, CMatrizBinaria **resultado*, double *alfa*, int *coordenadasFilas*, int *coordenadasColumnas*)

Convierte un bloque de *original* en escala de grises, en un bloque más pequeño *resultado* binario de 192 x 256 píxeles que comienza en las coordenadas *coordenadasFilas* y *coordenadasColumnas*, *alfa* se usa para determinar el umbral con el cual se decide si el píxel es 1 o 0.

► Busqueda

void *Busqueda* (int **J*, int *tamanoJ*, int *k*, int **posicion*)

Busca el valor *k* en *J* y devuelve la posición en *posicion*, si no se encuentra devuelve *posicion* = -1, *tamanoJ* es el tamaño del vector *J*.

► Cefa

void *Cefa* (CMatrizBinaria **imagen*)

Encuentra las puntas de las fibras que se encuentran en *imagen* y los datos los guarda en el propio objeto *CMatrizBinaria *imagen*.

► DesvStandard

double *DesvStandard* (CMatriz **bloque*)

Calcula la desviación estándar de *bloque* y la devuelve como un parámetro de salida.




Figura 6.1: Estructura para dilatar.

► Dilate

```
void Dilate (CMatrizBinaria *matriz)
```

Esta función dilata la imagen con una estructura en forma de cruz como se muestra en la figura 6.1. Se recorre *matriz* con la cruz y cuando el centro de la misma coincide con un valor de 1 en *matriz*, los otros cuatro puntos de *matriz* que quedan bajo los cuatro puntos restantes de la cruz se pintan con 1.

► EliminarCumulos

```
void EliminarCumulos (CMatrizBinaria *imagen)
```

Elimina los cúmulos de *imagen* y retorna a *imagen* ya modificada.

► EliminarFibrasRepetidas

```
void EliminarFibrasRepetidas (CMatrizBinaria *datos)
```

Elimina fibras de *datos* que se encuentran superpuestas en más de un 50 por ciento de su recorrido. El resultado es la matriz *datos* modificada.

► EliminarRegionesChicas

```
void EliminarRegionesChicas (CMatrizBinaria *matriz, int umbral)
```

Elimina las regiones con una cantidad de píxeles menores que *umbral*, de la imagen binaria *matriz*. En ésta se actualizan los números de las diferentes regiones. *PixelesPorRegion* indica en cada posición del vector (la posición indica que número de región es) la cantidad de píxeles que contiene dicha región. La posición cero indica la cantidad de regiones que hay. El resultado es la misma *matriz* pero modificada.

► **EncontrarPuntas**

```
bool EncontrarPuntas (CMatrizBinaria *matriz, CMatrizBinaria *imagen,  
int radio, int x0, int y0, double *f)
```

Encuentra la intersección de una circunferencia *imagen* de centro x_0 y y_0 y radio *radio* con la imagen binarizada *matriz*. Si dicha intersección es una región conexa devuelve como parámetro de salida *true* en otro caso *false*. El parámetro *f* es un vector con los grados de cada punto de la circunferencia, es una medida de la cantidad de puntos de la circunferencia.

► **FindSimple**

```
void FindSimple (CMatrizBinaria *matriz, int *I, int *J)
```

Encuentra los puntos de *matriz* diferentes de 0, devuelve las coordenadas de los mismos en los vectores *I* y *J*.

► **IdentificarFibras**

```
void IdentificarFibras (CMatriz *original, CMatrizBinaria *binaria)
```

Calcula las características de cada una de las fibras. Recibe la imagen original en escala de grises *original* y la imagen binaria *binaria*. Ubica los puntos representativos de *binaria* en *original*, traza rectas perpendiculares a la fibra y calcula las características de los puntos de intersección de estas rectas con la fibra.

► **Interseccion**

```
bool Interseccion (int xa1, int ya1, int xa2, int ya2, int xb1, int yb1, int  
xb2, int yb2)
```

Encuentra la intersección entre dos segmentos de recta, dados por las coordenadas de entrada y devuelve *true* si la intersección existe. Los parámetros x_{a1} y y_{a1} son los valores de las coordenadas de una de las puntas del segmento *a*, y x_{a2} y y_{a2} corresponden a la otra punta del mismo segmento. Lo mismo para los extremos del segmento *b*.

► **Label**

void *Label* (CMatrizBinaria **original*)

Devuelve en *original* $\rightarrow$ *regiones*, las zonas etiquetadas de *original* $\rightarrow$ *imagen*. En *original* $\rightarrow$ *pixeles_por_region*, devuelve el número de píxeles en cada región. En *original* $\rightarrow$ *I* y *original* $\rightarrow$ *J*, se guardan las coordenadas de los puntos etiquetados.

► **Maximo**

int *Maximo* (int **bloque*)

Devuelve el máximo valor del vector *bloque*.

► **MaximoVector**

int *MaximoVector* (int **punteroVector*, int **punteroPosicionMaximoVector*)

Devuelve el máximo de *punteroVector*, y la posición del mismo en *punteroPosicionMaximoVector*.

► **MinimoVector**

int *MinimoVector* (int **punteroVector*, int **punteroPosicionMinimoVector*)

Devuelve el mínimo de *punteroVector*, y la posición del mismo en *punteroPosicionMinimoVector*.

► **Media**

double *Media* (CMatriz **bloque*)

Calcula el promedio de los píxeles de *bloque*.

► **Mediana**

float *Mediana* (int **vector*)

Devuelve la mediana de un vector de enteros, en *vector*[0] está el largo del vector, si el vector está vacío devuelve -1 .

► **MinimoUne**

```
int MinimoUne (int *x_min, int *y_min, CMatriz *matriz)
```

Devuelve el mínimo valor de *matriz* $\rightarrow$ *distancia* y las coordenadas del mismo en *x_{min}* e *y_{min}*.

► **UneFibras**

```
void UneFibras (CMatrizBinaria *imagen)
```

Une pequeños seccionamientos de fibra en *imagen*.

► **Zoom**

```
double Zoom (CMatriz *matriz, int factor, int anchoPerfil)
```

Realiza un zoom con el método de la binomial en *matriz* por un factor *factor*. Está pensado para que todas las filas de *matriz* sean iguales a un único perfil (esto es así porque queda más sencillo realizar el zoom), por ende en *anchoPerfil* se devuelve el ancho del perfil y la función retorna el valor de la desviación estándar.

6.3. Interfaz gráfica con el usuario

Se intentó en todo momento que la interfaz con el usuario fuera lo más simple posible. Teniendo esto en cuenta, se evitó tener que solicitar al usuario del software datos para realizar el procesamiento (como puede ser la solicitud de introducir umbrales de detección).

Al ejecutar el software se despliega la ventana que se muestra en la figura 6.2. Dicha pantalla tiene, entre otros menús, el menú *Archivo* $\rightarrow$ *Abrir* permite cargar las imágenes que se desean procesar.

La biblioteca utilizada para cargar, escribir y visualizar imágenes es Cx-Image, la cual permite trabajar con los siguientes formatos: BMP, GIF, JPG, PNG, MNG, ICO, TIF, TGA, PCX, WBMP, WMF, EMF, J2K, JBG, JP2, JPC, PGX, RAS y PNM.




Figura 6.2: Ventana inicial

Una vez cargada la imagen que desea estudiarse en el software, se debe ingresar al menú *Funciones*. Dentro de dicho menú se pueden ejecutar seis opciones, los cuales, como muestra la figura 6.3 son: *binarización*, *eliminar cúmulos*, *enviar puntas*, *une fibras*, *aproximar por rectas* e *identificar fibras*.

Cada una de las opciones ejecuta las rutinas descritas en el capítulo 3. Una vez finalizada la ejecución, el software presenta el resultado en pantalla, como se muestra en la figura 6.4.

La salida final del programa se presenta en tres formas diferentes:

- Un cuadro de diálogo en el que se muestra la cantidad de fibras coloreadas por tipo, y la suma de éstas.
- Una ventana en la cual se muestran las fibras detectadas, diferenciando su tipo por el nivel de gris de las mismas. Las fibras tipo 5 y 6 se visualizan con un nivel de gris claro y las tipo 7 y 8 en un nivel de gris más oscuro.
- Un archivo de texto, donde se almacenan datos más específicos de los perfiles de cada fibra detectada. Éstos son: media, mínimo y media menos mínimo del nivel de gris, tipo de fibra (con 1 se representan las fibras tipo 5 y 6, y con 2 las tipo 7 y 8), ancho de la fibra en ese perfil (medido en píxeles). En la figura 6.5 se muestra un ejemplo de este archivo.




Figura 6.3: Menú de funciones




Figura 6.4: Ventana con resultados finales

Media del perfil	148	150	151	151	150
Mínimo del perfil	133	131	133	120	113
Media menos Mínimo	15	19	18	31	37
Tipo de fibra	1	1	1	1	1
Ancho (en píxeles)	30	33	52	26	20
Media del perfil	150	154	154	154	154
Mínimo del perfil	120	127	133	129	132
Media menos Mínimo	30	27	21	25	22
Tipo de fibra	2	2	2	2	2
Ancho (en píxeles)	24	29	27	20	26

Figura 6.5: Archivo de texto de salida

Capítulo 7

Sistema de Adquisición

Uno de los objetivos de este proyecto era diseñar una máquina de laboratorio que logre automatizar el proceso de adquisición de las imágenes.

El siguiente es un esbozo de una posible solución del diseño. En el mismo se presenta una posible orientación en donde se tienen en cuenta los principales problemas que enfrenta la adquisición de imágenes utilizando sustancias tóxicas, dejando de lado los detalles mecánicos que será necesario resolver al momento de la implementación.

Los principales problemas que trata de resolver este diseño son los siguientes:

- La adquisición de las imágenes se realiza bajo condiciones hostiles para un operario, dadas las emanaciones de tolueno.
- Es necesario lograr obtener un velo muy fino a partir del top de lana para realizar la adquisición de imágenes de manera que las fibras queden expuestas.
- Un velo de lana no soporta mucha tracción.
- Se tiene que poder compactar el velo contra el escáner para que el mismo enfoque todas las fibras presentes en el mismo.
- La presentación de la muestra sobre el escáner debe contener la menor cantidad de burbujas dado que las mismas distorsionan la imagen.
- El sistema debe de ser lo más automático posible y debe soportar un flujo continuo para la muestra de 100 gramos de lana.

La figura 7.1 presenta una vista general del sistema, en donde se pueden apreciar:

- PC para controlar el sistema y hacer el procesamiento de las imágenes, el mismo debe tener la capacidad suficiente de cumplir con las exigencias requeridas por el software de detección.
- Campana cerrada con extracción forzada de aire en donde se encuentra el sistema de manejo de la lana, la misma logra aislar al operario de las sustancias tóxicas. La campana posee guantes adheridos a la misma para realizar el manejo de la muestra. La campana es totalmente estanca y prevee orificios para reponer el aire que es extraído, o sea que siempre tiene menor presión respecto a donde se encuentra el operario y evita posibles acumulaciones de vapor de tolueno altamente volátil.
- Escáner para la adquisición de las imágenes. El mismo debe tener una resolución mínima de 1200 dpi, se comunicará por el puerto USB 2.0 dado su gran performance para la transmisión de grandes cantidades de datos (480 Mbps).
- PLC, el cual se encarga de controlar los movimientos mecánicos del sistema de manejo de lana, el mismo tendrá comunicación serial con la PC y trabajará en una configuración maestro esclavo con la misma.




Figura 7.1: Vista lateral del sistema de adquisición

La figura 7.2 presenta el equipo contenido completamente en el interior de la campana. El ciclo de la muestra comienza cuando el par de rodillos Ra tracciona el top desde el contenedor de lana, seguido, el par de rodillos Rb traccionan nuevamente el top pero a una velocidad mayor que el par Ra, logrando que el top se afine hasta convertirse en un velo, esto se debe a que el flujo másico




Figura 7.2: Vista lateral del sistema de adquisición

se conserva, por lo tanto el aumento de velocidad implica una disminución de la sección. Dicho velo es introducido en un recipiente de vidrio que se encuentra apoyado sobre el escáner y nuevamente es traccionado por el par de rodillos Rd a la salida del recipiente.

Los rodillos traccionan lana por un tiempo T , y luego cuando todo el recipiente esta cubierto por velo que no ha sido escaneado, el par de rodillos Rd se detiene, un ΔT después se detienen los restantes pares. Esta asincronía logra que se acumule velo en el recipiente con tolueno y de esta forma se logra disminuir la tensión sobre el mismo. A continuación el brazo a (Ba) apoya la placa sobre el fondo del recipiente de vidrio, con el objetivo compactar la muestra, y debido al ángulo oblicuo que forma la misma con el fondo del recipiente, durante el descenso también logra eliminar burbujas. Cuando la placa se encuentra paralela al fondo del recipiente y compactando la muestra, el escáner realiza el barrido. El ciclo se repite hasta terminar la muestra de top del contenedor de lana seca. La sincronía de todos estos movimientos las maneja el PLC ayudado de relés de fin de carrera para el movimiento de la placa, y sensores para detectar interrupciones en el flujo de lana debido a ruptura en el velo.

El diseño también posee un sistema de control de nivel para reponer el tolueno que se pierde por la salida del velo impregnado desde el recipiente de vidrio, el mismo se muestra en la figura 7.2.

En la figura 7.5 se muestra un presupuesto estimado para la construcción del prototipo. Se prevee la utilización de materiales de utilización común en la industria y de fácil obtención en plaza.




Figura 7.3: Vista trasera del sistema de adquisición




Figura 7.4: Vista superior del sistema de adquisición

Artículo	Referencias	Precio unitario (U\$S)	Cantidad	Total (U\$S)
Componentes mecánicos				
rodillo metálico	Ra, Rb, Rc, Rd	146	4	584
rodillo goma	Ra, Rb, Rc, Rd	100	4	400
cúpula metálica	cúpula	250	1	250
guía metálica	Ga, Gb	20	3	60
brazo metálico	Ba	32	1	32
recipiente de vidrio	recipiente de vidrio	20	1	20
eje cigüeñal	eje	15	1	15
componentes eléctricos				
motor dcc	Motor A	22	1	22
motor dcc	Motores rodillos	22	4	88
PLC	PLC	170	1	170
relé fin de carrera	N/A	18	2	36
relé motor	N/A	4	5	20
sensor	N/A	100	1	100
fuelle 12V 10A	N/A	230	1	230
escáner	escáner	1200	1	1200
Computadora				
RAM 2 G	N/A			
Micro Pentium 4 3,2 MHz	N/A			
HD 40 GB	N/A			
Tarjeta de video 128 MB	N/A			
Mainboard con puertos USB y serial	N/A			
fuelle ATX	N/A			
monitor 17"	N/A			
lectora DVD RW	N/A			
gabinete, teclado y mouse	N/A			
sub total	PC	1000	1	1000
Imprevistos				
Imprevistos 20%	N/A			845
		Presupuesto total	Dólares	5072

Figura 7.5: Presupuesto para el sistema de adquisición (N/A = No Aplica)

Capítulo 8

Pasos Siguientes

Durante el proyecto se diseñó un método para la adquisición de imágenes mediante la utilización de tolueno que minimiza los riesgos para la salud del operario. De todas formas, sería conveniente encontrar otras sustancias con propiedades similares al tolueno en cuanto a índice de refracción, pero con menor grado de toxicidad. Un punto que queda pendiente en este proyecto es, entonces, estudiar el comportamiento de otras sustancias. Este estudio se podría realizar con ayuda del Instituto de Química de esta Facultad, con la Facultad de Química o con el LATU entre otros.

Habría que diseñar en detalle y construir un prototipo del sistema de adquisición esbozado. Esto implica diseñar el mecanismo de control e integrar el software desarrollado.

Otro punto que quedó pendiente en este proyecto es el entrenamiento del algoritmo para muestras con tolueno. Esto se debe realizar entregándole una serie de muestras de lana a un técnico para que las estudie. Con los resultados entregados por el técnico se procede a correr el algoritmo sobre las imágenes para realizar el entrenamiento del mismo.

Continuar la investigación hasta lograr la detección de fibras coloreadas en lana sin procesar.

Capítulo 9

Conclusiones

Los objetivos de este proyecto fueron detallados en el capítulo 1. A continuación se enumeran los objetivos planteados al comienzo del proyecto, y las tareas desarrolladas para cumplir con los mismos.

- **Investigación de la problemática de las fibras coloreadas.**

Objetivo

Se estudiarán los proyectos y soluciones que existen hasta el momento. En particular se estudiará el Proyecto Fibras Coloreadas realizado anteriormente en Facultad. También se hará hincapié en la recomendación de la IWTO que tiene especificada una solución a este problema.

Se realizarán visitas al LATU para observar los procedimientos manuales de conteo de fibras coloreadas.

También se realizará una visita a la Facultad de Veterinaria, donde actualmente se realizan investigaciones genéticas sobre las fibras coloreadas.

Tareas realizadas

Se realizó un estudio detallado de las soluciones que existen hasta el momento, poniendo énfasis en el Proyecto de Fin de Carrera Fibras Coloreadas. Luego de evaluar este último proyecto se decidió tomar una nueva orientación haciendo algoritmos más simples que insuman menos recursos de procesamiento, esta política se reflejó en una mejora sustancial en el tiempo de proceso sin perder mucha precisión en la predetección, como se explica en el capítulo 3 para la comparación de tiempos.

Se realizaron visitas al LATU donde se estudiaron los métodos actuales del conteo de fibras coloreadas. Se pudo tener idea de las complicaciones del manejo manual de las muestras de lana, y qué cosas tener en cuenta para la implementación automática de dicho manejo. Se conoció un poco sobre el intrincado mundo de las normas y de las fuerzas que direccionan

las políticas que manejan las estandarizaciones y que no siempre es fácil que la investigación y los intereses industriales converjan a los mismos objetivos.

Se visitó la Facultad de Veterinaria donde se conoció el método de lavado de lana sucia desarrollado en la misma.

Se considera por lo tanto, que esta etapa fue cumplida satisfactoriamente.

- **Poder analizar una muestra mayor de lana.**

Objetivo

En el proyecto de Detección de Fibras Coloreadas se estudió una muestra de 18 x 24 milímetros. Lo ideal sería poder procesar una imagen de aproximadamente 10 x 10 centímetros. para que sea factible implementar la detección de fibras en 100 gramos de lana en tiempo real.

Tareas realizadas

Durante este proyecto se trabajó con las mismas muestras que en el proyecto anterior. Luego se adquirieron muestras de 13.5 centímetros de ancho y 20 centímetros de largo adquiridas mediante la utilización de un escáner y utilizando tolueno. Se ejecutó el algoritmo de detección entrenando con el banco de imágenes adquirido en el Proyecto Fibras Coloreadas, sobre el nuevo banco de imágenes.

Aunque no se contó con la evaluación de un experto para validar los resultados de la aplicación del algoritmo sobre el nuevo banco de imágenes, a simple vista se puede apreciar que la detección de fibras se realiza correctamente, sin necesidad de modificar los umbrales utilizados.

El hecho de poder trabajar con imágenes de tamaño mayor en tiempos razonables, se debe a la mejora en el tiempo de ejecución del algoritmo y a la técnica del tolueno, que permite trabajar con imágenes de menor resolución obteniendo de todas formas una detección correcta.

Esto demuestra que es posible trabajar con áreas de gran tamaño sin necesidad de utilización de hardware costoso, por lo que este objetivo se considera cumplido.

- **Mejorar la eficiencia del algoritmo anterior**

Objetivo

Dado que las muestras de lana a analizar en este proyecto van a ser de un volumen mayor, se necesitaría optimizar al máximo los algoritmos para lograr mejores velocidades de procesamiento, ya que en el proyecto anterior en ningún momento se buscó optimizar el mismo por razones de tiempo.

Tareas realizadas

En un principio, se consideró realizar modificaciones en el software del proyecto anterior de manera de disminuir lo más posible las operaciones realizadas. De esta manera se pensaba disminuir el tiempo de ejecución para poder procesar muestras de mayor tamaño.

Luego de estudiar el algoritmo y realizar algunas pruebas con la varianza, se llegó a la conclusión que lo mejor iba a ser replantearse el algoritmo. Se estudió cómo realizar la detección de la manera más eficiente y luego se hizo un software para la detección de fibras. Este software disminuyó en 20 veces el tiempo de procesamiento, lo que luego posibilitó el tratamiento de imágenes de 60 veces más tamaño.

Si bien no se trabajó sobre el algoritmo anterior para mejorarlo, se realizó un software que cumple las tareas que el mismo realizaba, mejorando el tiempo de ejecución y logrando obtener las características de cada fibra. Por lo que se considera que este punto fue cumplido correctamente.

■ **Dispositivo que automatice el proceso**

Objetivo

De haber logrado los dos puntos anteriores, se diseñará un dispositivo que automatice el proceso de conteo de fibras en un tiempo similar al que le lleva actualmente a un experto realizar dicha tarea. Se debe hacer una estimación de costos para la realización de un prototipo. En caso de contar con dinero suficiente se podría construir el mismo.

Tareas realizadas

Se realizó un esbozo de un dispositivo para automatizar la adquisición y detección de fibras coloreadas. Se realizó un presupuesto del costo del sistema. No fue posible construirlo debido a que no se contaba con dinero suficiente. Este objetivo se cumplió satisfactoriamente.

■ **Detección de impurezas**

Objetivo

Paralelamente, se buscarán formas de detección de otras impurezas, principalmente polipropileno. Actualmente existe un problema de contaminación de la lana con estas fibras debido a que son transportadas en bolsas de dicho elemento. Estas fibras, que tampoco se tiñen (como las fibras

coloreadas) tienen al menos dos problemas para su detección: tienen dimensiones similares a la de la lana y son de color claro (traslúcidas) por lo que es difícil detectarlas.

Tareas realizadas

No se pudo avanzar en este sentido debido a problemas de tiempo y a no tener una base de imágenes con gran cantidad de impurezas como para poder realizar un entrenamiento y validación del algoritmo.

- **Porcentaje de acierto**

El porcentaje de acierto en la detección de fibras coloreadas fue muy bueno (de alrededor del 95 por ciento).

- **Clasificación**

Un objetivo que no se planteó como objetivo explícito del proyecto, pero que siempre se manejó, fue la determinación del tipo de fibra. Se logró clasificar las fibras en dos subgrupos, tipo 5 y 6 por un lado, y tipo 7 y 8 por otro.

Bibliografía

- [1] Kernighan, B.W., Ritchie, D.M.: El lenguaje de programación C, Prentice - Hall, 1991.
- [2] Ceballos, F.J.: Curso de programación C++, Addison - Wesley, 1991.
- [3] Williams, M.: La esencia de Visual C++ 4, Prentice - Hall, 1996.
- [4] Schildt, H.: C Manual de referencia, McGraw - Hill, 1990.
- [5] Eckel, B.: Aplique C++, McGraw - Hill, 1991.
- [6] Lozano, E.: Tópicos en reconocimiento de patrones, funciones de base radial, Universidad de Puerto Rico, Recinto Universitario de Mayagüez, Departamento de Matemáticas, 2002, disponible en: <http://math.uprm.edu/elioli/radial.pdf>, Agosto 2006.
- [7] Bose, N.K., Liang, P.: Neural Networks Fundamentals with graphs, algorithms and applications, McGraw - Hill, 1996
- [8] González, R.C., Woods, R.E.: *Tratamiento Digital de Imágenes* Addison-Wesley/Diaz De Santos, 1992.
- [9] Bazerque, J.A., Ciambelli, J.C., Lafon, S.J.: *FibroCaptor: Manual de Usuario, Detección de Fibras Coloreadas en Lana* Proyecto de fin de carrera, Facultad de Ingeniería(IIE), Universidad de la Republica, 2003.
- [10] Bazerque, J.A., Ciambelli, J.C., Lafon, S.J.: *Detector de Fibras coloreadas en Lana: Manual del Instalador, Detección de Fibras Coloreadas en Lana* Proyecto de fin de carrera, Facultad de Ingeniería(IIE), Universidad de la Republica, 2003.
- [11] Bazerque, J.A., Ciambelli, J.C., Lafon, S.J.: *FotoResaltador: Características Técnicas, Detección de Fibras Coloreadas en Lana* Proyecto de fin de carrera, Facultad de Ingeniería(IIE), Universidad de la Republica, 2003.
- [12] Perera, G.: *Probabilidad y Estadística Matemática, un primer encuentro*, Centro de Publicaciones del Centro de Estudiantes de Ingeniería, 2001.
- [13] CSIRO: <http://www.csiro.au>
- [14] IWTO: <http://www.iwto.org>
- [15] LATU: <http://www.latu.org.uy>
- [16] SUL: <http://www.sul.org.uy>

Capítulo 10

Apéndice A

Redes Neuronales

10.1. Introducción

Las redes neuronales artificiales (RNA) son redes interconectadas en paralelo, de elementos simples (usualmente adaptativos) llamados neuronas, las cuales tienen una organización jerárquica.

En un comienzo, las RNA buscaron simular el comportamiento de las redes neuronales biológicas. Las neuronas biológicas tienen varias entradas (dendritas), una salida (el axón), y realizan algún procesamiento de las señales que reciben. La comunicación entre neuronas se produce a través de las sinapsis. Las entradas recibidas por la neurona, por medio de las diferentes dendritas, tienen distinta influencia en la salida dependiendo de diversos factores. Algunos de ellos son: posición de la dendrita con respecto al cuerpo celular, estado de la membrana celular en el momento de recibir una señal e influencia de señales recibidas en dendritas cercanas. En la figura 10.1 se muestran dos neuronas naturales conectadas entre sí por medio de una sinapsis.

Como se puede observar en la figura 10.2, una neurona artificial, a semejanza de una neurona biológica, tiene varias entradas y una salida. Las neuronas artificiales se interconectan entre sí formando una red. Las uniones entre las distintas neuronas se llaman sinapsis y tienen diferentes pesos, los cuales se aplican a las señales de entrada a la neurona. Sean $x_1, x_2 \dots x_n$, las entradas a una neurona en particular, la entrada total que recibe la neurona es:

$$net = \sum_{i=1}^n w_i \times x_i \text{ (Ecuación A1)}$$

Donde w_i son los pesos sinápticos correspondientes a cada entrada.




Figura 10.1: Dos neuronas naturales interconectadas por una sinapsis




Figura 10.2: Dos neuronas artificiales (círculos grandes) interconectadas por una sinapsis

Con el paso del tiempo, las RNA se independizaron de su origen en cuanto a la semejanza con sistemas biológicos, llegando a ser representadas actualmente por modelos matemáticos que nada tienen que ver con los sistemas de neuronas que se encuentran en la naturaleza. Aún así, conservan varias de las características originales que son las que le dan una gran vigencia en la resolución de muchos problemas prácticos. Entre estas características características, cabe destacar:

- **Tolerancia a fallos.**

La tolerancia a fallos se la da el hecho de tener información redundante, esto hace que la red pueda seguir respondiendo aceptablemente aún ante un daño parcial.

- **Capacidad de aprendizaje.**

Las RNA pueden ser entrenadas con una serie de datos de entrada y salida deseadas para que, luego de aplicado el algoritmo de aprendizaje (entrenamiento), ajuste sus parámetros. Luego del entrenamiento, se puede lograr que ante una entrada cualquiera pueda dar una salida apropiada.

- **Auto organización.**

Una RNA crea su propia representación de la información en su interior, liberando al usuario de esta tarea.

- **Flexibilidad.**

Una RNA puede manejar cambios no importantes en las entradas debido, por ejemplo, a ruidos, dando de todas formas la salida correcta.

- **Tiempo real.**

La estructura de la RNA es paralela, por lo que se puede implementar en hardware para obtener respuestas en tiempo real.

Existe una función de activación que determina cuál será el siguiente estado de la neurona dado un conjunto de entradas y el estado actual de la misma. Los estados pueden ser: reposo y excitado. Puede haber un conjunto continuo de valores de activación en el intervalo $[0, 1]$, ó $[-1, 1]$, o varios valores discretos; muchas veces la función de activación es la identidad. Luego se pasa esta información por una función de transferencia, obteniéndose de esta forma la salida de la neurona. En la tabla 10.1 se pueden ver algunas de las funciones de activación - transferencia más utilizadas, en la misma Φ representa el umbral de activación (umbral con relación al cual se decide el tipo de activación de la neurona), y net es la suma de todas las entradas a la neurona ponderadas por sus respectivos pesos (ecuación A.1).

Cuadro 10.1: Funciones de activación - transferencias más habituales

Nombre	Salida	Fórmula
Escalón	$y(t+1) =$	1 si $[net > \Phi]$ $y(t)$ si $[net = \Phi]$ 0 si $[net < \Phi]$
Lineal o identidad	$y(t+1) =$	$net - \Phi$
Sigmoidal	$y(t+1) =$	$\frac{1}{1+e^{-(net-\Phi)}}$

Para formar una RNA las neuronas se agrupan en capas. Una capa es la de entrada, con las neuronas conectadas a las entradas a la red, la otra es la capa de salida, que entrega la salida de la red, y pueden existir capas ocultas, que se conectan con otras capas de neuronas y no con las entradas o salidas directamente.

Hay diferentes topologías de redes, por ejemplo: todas las neuronas de una capa pueden estar conectadas con todas las de una capa siguiente, neuronas de una misma capa conectadas entre sí, neuronas conectadas consigo mismas, etc..

Las aplicaciones de las redes neuronales son muy variadas: reconocimiento de patrones, clasificación, predicción (por ejemplo, del mercado financiero o

del clima), memorias asociativas, sistemas de control, resolución de problemas complejos donde no existe un modelo matemático preciso o algoritmos con complejidad razonable (por ejemplo, problema del viajante), etc.

10.2. Casos particulares

En esta sección se describen los dos tipos de RNA que dieron mejores resultados en la clasificación de fibras coloreadas. Estas redes fueron Radial Basis y Feed-forward backpropagation.

Las RNA son modelos lineales. Un modelo lineal de una función $f(x)$ tiene la forma:

$$f(x) = \sum_{j=1}^m w_j \times h_j(x) \text{ (Ecuación A2)}$$

Donde $h_j(x)$ (llamadas funciones base), son funciones fijas para cada j , y w_j son los *pesos* de cada función. Ejemplos de funciones base en otras aplicaciones diferentes a las redes neuronales son:

$$h_j(x) = \sin\left(\frac{2 \times \Pi \times j \times (x - \Theta_j)}{m}\right) \text{ Serie de Fourier (Ecuación A3)}$$

$$h_1(x) = 1$$

$$h_2(x) = x \text{ Recta } f(x) = a \times x + b \text{ (Ecuación A4)}$$

10.2.1. Redes neuronales Radial Basis

Las funciones de base radial (RBF) fueron originalmente propuestas en interpolación de funciones (Powel 1987), y fueron usados por primera vez por Broomhead y Lowe en 1988.

Las RBF son funciones definidas como una combinación lineal de funciones base radialmente simétricas, esto significa que las funciones h_j de la ecuación A2 son funciones radialmente simétricas. Algunas de las funciones base radiales más usadas se muestran en la tabla 10.2. Estas funciones son muy diferentes entre sí, y se utilizan distintas funciones para diferentes aplicaciones.

Las RBF transforman un patrón $x \in \mathbb{R}^n$ en un espacio n - dimensional según la siguiente transformación:

Cuadro 10.2: Funciones base radiales mas usadas

Nombre	Fórmula ($z = \ x - \mu\ \div h$)
Gaussiana	$\exp^{-z^2}$
Exponencial	$\exp^{-z}$
Cuadrática	$z^2 + \alpha \times z + \beta$
Cuadrática inversa	$1/\ 1 + z^2\ $
Placa Fina	$z^\alpha \times \lg(z)$
Trigonométrica	$\sin(z)$

$$g_j = \sum_{i=1}^n w_{ij} \times \Phi_i(\|x - \mu_i\|) \text{ (Ecuación A5)}$$

Donde w_{ij} son los pesos, los vectores μ_i los centros, y Φ_i son RBF. Una forma más generalizada de estas redes es:

$$g_j = \sum_{i=1}^n w_{ij} \times \Phi_i(\|x - \mu_i\| \div h) + w_{j0}$$

con $j = 1, \dots, n$ (Ecuación A6)

Donde h es un factor de escala, y w_{j0} es un valor que se denomina sesgo.

Una vez que las formas de las funciones no lineales fueron especificadas y los centros determinados, se tiene un modelo lineal cuyos parámetros pueden ser fácilmente hallados por mínimos cuadrados o cualquier otro método de optimización. Lo que se hace en la práctica es elegir la función de base radial apropiada, determinar los centros y luego calcular los pesos utilizando algún criterio de optimización lineal.

■ Determinación de la función base radial

Esto se hace según el problema a resolver, por ejemplo la gaussiana es más apropiada en la estimación de densidad utilizando kernels, las de placa fina en ajuste de curvas, etc.

■ Determinación de los centros

El número de centros se puede determinar por cross validación, monitoreo del funcionamiento en una muestra de prueba separada, Mezcla Gaussiana, etc.. Algunos de los métodos más utilizados para determinar el valor de los centros son:

- **Selección aleatoria.**

Se eligen aleatoriamente entre el conjunto de datos.

- **Conglomerados.**

Los centros seleccionados con la selección aleatoria pueden ser usados como semillas para el algoritmo k-means y así obtener los centros de las RBF como centros de los conglomerados. El algoritmo k-means divide los datos en k grupos o clusters, el centro μ_j es la media del grupo, de forma que la suma de los cuadrados $\|x_k - \mu_j\|^2$ es mínima, para cada grupo.

- **Mezclas Gaussianas.**

Dado el modelo de una Mezcla Gaussiana, se calculan los parámetros con el algoritmo EM (Máxima Expectación).

- **K - vecinos mas cercanos.**

Es un método supervisado que no necesita conocer todos los datos para definir las fronteras de decisión.

- **Mínimos cuadrados ortogonales.**

El problema de la determinación de los centros se ve como un problema de selección de variable.

- **Cálculo de los pesos**

Pueden ser hallados por mínimos cuadrados u otro método de optimización lineal. Las RBF pueden ser vistas como redes neuronales, suponiendo una red de una sola capa oculta con funciones de activación radiales (como se puede ver en la figura 10.3). Las variables $x_i, i = 1, \dots, n$ forman la capa de entrada, la capa oculta son las funciones de base radial evaluadas en las variables de entrada, las conexiones entre la capa oculta y la capa de salida está dada por los pesos w_{ij} .

10.2.2. Redes Feed forward-backpropagation

En una red Backpropagation (figura 10.3) existe una capa de entrada con n neuronas y una capa de salida con m neuronas y al menos una capa oculta de neuronas internas. Cada neurona de una capa (excepto las de entrada) recibe entradas de todas las neuronas de la capa anterior y envía su salida a todas las neuronas de la capa posterior (excepto las de salida). No hay conexiones hacia atrás feedback ni laterales entre las neuronas de la misma capa.

La aplicación del algoritmo tiene dos fases, una hacia delante y otra hacia atrás. Durante la primera fase el patrón de entrada es presentado a la red y propagado a través de las capas hasta llegar a la capa de salida. Obtenidos los




Figura 10.3: Redes Feed forward-backpropagation

valores de salida de la red, se inicia la segunda fase, comparándose estos valores con la salida esperada para obtener el error. Se ajustan los pesos de la última capa proporcionalmente al error. Se pasa a la capa anterior con una retropropagación del error, ajustando los pesos y continuando con este proceso hasta llegar a la primera capa. De esta manera se han modificado los pesos de las conexiones de la red para cada patrón de aprendizaje del problema, del que se conocía su valor de entrada y la salida deseada que debería generar la red ante dicho patrón.

La técnica Backpropagation requiere el uso de neuronas cuya función de activación sea diferenciable, y por lo tanto continua.

Pasos del algoritmo:

- Se inicializan los pesos de la red con valores pequeños aleatorios
- Se presenta un patrón de entrada y se especifica la salida deseada de la red.
- Se calcula la salida de la red para las entradas actuales, o sea para una determinada capa oculta, la entrada neta a una neurona de dicha capa es:

$$net_{pj} = \sum_{i=1}^N w_{ji} \times x_{pi}$$

Donde el índice p se refiere la p-ésimo vector de entrenamiento, j a la j-ésima neurona oculta, e i a la i-ésima entrada. La salida de la neurona luego de aplicar la función f a los datos es:

$$y_{pj} = f_j(net_{pj})$$

Los mismos cálculos se realizan para obtener las salidas de las neuronas de salida.

- Se calculan los términos de error para todas las neuronas: si la neurona j es una neurona de la capa de salida, el valor del error es:

$$\delta_{pj}^0 (d_{pj} - y_{pj}) \times f_j'(net_{pj})$$

Donde d_{pj} es la salida deseada. La función f debe ser derivable. En general se dispone de dos formas de función de salida:

La función lineal.

$$f_j(net_{pj}) = net_{pj}$$

La función sigmoideal:

$$f_j(net_{pj}) = \frac{1}{1 + e^{-net_{pj}}}$$

La selección de la función depende de la forma que se decida representar la salida: si se desea que las neuronas de salida sean binarias, se utiliza la función sigmoideal, en otros casos, la lineal. Para una función lineal, tenemos: $f'_k = 1$, mientras que la derivada de una función sigmoideal es: $f'_j = y_{pj} \times (1 - y_{pj})$ por lo que los términos de error para las neuronas de salida quedan:

$$\delta_{pj}^0 = (d_{pj} - y_{pj}) \text{ para la salida lineal}$$

$$\delta_{pj}^0 = (d_{pj} - y_{pj}) y_{pj} (1 - y_{pj}) \text{ para la salida sigmoideal}$$

Si la neurona j no es de salida, entonces la derivada parcial del error no puede ser evaluada directamente, por tanto se obtiene el desarrollo a partir de valores que son conocidos y otros que pueden ser evaluados. La expresión obtenida en este caso es:

$$\delta_{pj}^k = f_j^{j'}(net_{pj}^k) \sum_k \delta_{pk}^0 w_{kj}^0$$

Donde se observa que el error en las capas ocultas depende de todos los términos de error de la capa de salida. De aquí surge el término propa-

gación hacia atrás.

- Actualización de los pesos: para ello se utiliza un algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la capa de entrada, ajustando los pesos de la siguiente forma: Para los pesos de las neuronas de la capa de salida:

$$\Delta w_{ij} = y_i \times y_j$$

$$\Delta w_{ij}^0(t+1) = \alpha \times \delta_{pk}^0 \times y_{pj}$$

Donde Δw_{ij} es la variación del peso de la conexión entre las neuronas i y j , y_i e y_j son las salidas de las neuronas i , y j . α es el factor de aprendizaje ($0 < \alpha < 1$) que regula la velocidad del aprendizaje.

Para los pesos de las neuronas de la capa oculta:

$$w_{ij}^k(t+1) = w_{ij}^k(t) + \Delta w_{ij}^k(t+1)$$

$$\Delta w_{ij}^k(t+1) = \alpha \delta_{pj}^k(t+1) \times x_{pi}$$

En ambos casos, para acelerar el proceso de aprendizaje se puede añadir un término momento.

- El proceso se repite hasta que el término de error resulta aceptablemente pequeño para cada uno de los patrones aprendidos.

El término de error se puede calcular como: $E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2$

Capítulo 11

Apéndice B

Determinación de la mínima resolución para la detección

El siguiente desarrollo es un cálculo aproximado de la resolución mínima necesaria para detectar las fibra más finas cuyo ancho está en el entorno de los (Y) micrones. El objetivo es poder cuantizar con al menos un bit la fibra de menor ancho. El ancho del píxel será llamado (X). Dado un arreglo matricial de píxeles mapeados sobre la imagen de una fibra coloreada, se pueden considerar dos casos del posicionamiento geométrico de la fibra respecto al arreglo. Los dos casos antes mencionados se muestran en la figura 11.1, en donde se aprecia que para una fibra de ancho (Y) el área que ocupa sobre el píxel es máxima cuando la misma se encuentra alineada con el arreglo y mínima cuando se encuentra a 45° del mismo.

Si se observan las zonas marcadas con óvalos en detalle se puede comprender claramente lo anteriormente expuesto, ver figura 11.2.

La acotación anterior es importante por suponer que el píxel codifica el nivel de gris ponderando los niveles que sobre el aparecen por el área que estos ocupan. Para mayor simplicidad se supondrá para este análisis que la imagen original solo tiene 2 niveles de gris, el de la fibra y el del fondo. Estos dos niveles son ponderados por su área, de lo que resulta el nivel de gris del píxel que finalmente es umbralizado para decidir si el píxel es o no una fibra coloreada, este proceso se ejemplifica para un píxel en la figura 11.3.

La pregunta es: ¿cuál es el área mínima que tiene que ocupar la fibra para que dicho píxel sea marcado como fibra, si se supone un umbral fijo que depende del nivel de gris de la fibra y del fondo?.

Respondiendo esta pregunta se puede tener una aproximación al tamaño máxi-




Figura 11.1: Zonas geométricas




Figura 11.2: Fibras sobre píxeles




Figura 11.3: Resumen del proceso

mo de píxel, pues quien esta fijo en este problema es el area mínima a detectar. El lado del área fue anteriormente llamado (Y).

Caso extremo:

- Si se fija el umbral para decidir que un píxel es fibra en el nivel de gris de la fibra, entonces el píxel tendrá que ser totalmente cubierto por la fibra para que este sea considerado fibra. Esto implica tener que escoger un píxel cuya diagonal sea menor igual que el ancho (Y). Este es entonces el caso más conservador.

Por otro lado considerando que el umbral siempre está por encima del nivel de gris de la fibra y por debajo del nivel de gris del fondo, si la resolución mínima se eligiera con con el criterio antes mencionado se estaría sobredimensionando la adquisición, alargando por consiguiente el tiempo de proceso.

- Si se supone ahora que el umbral esta por encima del nivel de gris de la fibra, se realiza el siguiente análisis para el cálculo de la resolución mínima

Se definen las siguientes variables:

A_{fo} : Área del píxel ocupada por el fondo (normalizada por el área del píxel).
 A_{fi} : Área del píxel ocupada por la fibra (normalizada por el área del píxel).
 U : Umbral que discrimina si un píxel pertenece o no a una fibra.
 Y : Ancho mínimo de la fibra a codificar.
 X : Lado máximo del píxel (resolución).
 N_{fi} : Nivel de gris de la fibra.
 N_{fo} : Nivel de gris del fondo.
 N_{pi} : Nivel de gris codificado por el píxel.

Suponiendo un comportamiento lineal del píxel en lo que respecta al nivel codificado respecto al área y al nivel de gris que ocupa cada elemento en el píxel, se puede calcular entonces el N_{pi} en función de N_{fo} , N_{fi} , A_{fo} y A_{fi} de la siguiente manera :

$$N_{pi} = (N_{fi} \times A_{fi} + N_{fo} \times A_{fo})$$

Si se umbraliza N_{pi} y se despeja A_{fi} .

$$\begin{aligned} (N_{fi} \times A_{fi} + N_{fo} \times A_{fo}) &\leq U \\ (N_{fi} \times A_{fi} + N_{fo} \times (1 - A_{fi})) &\leq U \\ A_{fi}(N_{fi} - N_{fo}) &\leq U - N_{fo} \end{aligned}$$

$$A_{fi} \geq \frac{(U - N_{fo})}{(N_{fi} - N_{fo})} = h$$

Considerando que $N_{fi} \leq N_{fo}$, $U \leq N_{fo}$ y $N_{fi} \leq U \leq N_{fo}$ entonces $0 \leq h \leq 1$.

Si se considera la geometría del píxel se tienen 2 casos dependiendo del umbral:

$$1 \ A_{fi} \geq 0,5 \ 2 \ A_{fi} < 0,5$$

Falta relacionar A_{fi} con Y y con X . Para el caso más acotado, o sea que la fibra se encuentra en diagonal respecto a el arreglo de píxeles, las áreas antes mencionadas se calculan de la siguiente manera.

$$\begin{aligned} 1 \quad A_{fi} &= \frac{Y^2}{X^2} \\ 2 \quad A_{fi} &= \frac{X^2 - (X \times \sqrt{2} - Y)^2}{X^2} \end{aligned}$$

Juntando las dos ecuaciones para A_{fi} en cada uno de los casos.

$$\begin{aligned} \blacksquare \quad \frac{Y^2}{X^2} &\geq \frac{U - N_{fo}}{N_{fi} - N_{fo}} \Rightarrow X \leq \sqrt{\frac{Y^2}{h}} \\ \blacksquare \quad \frac{X^2 - (X \times \sqrt{2} - Y)^2}{X^2} &\geq \frac{U - N_{fo}}{N_{fi} - N_{fo}} \Rightarrow X \leq \frac{2 \times \sqrt{2} \times Y + \sqrt{8 \times Y^2 - 4 \times (1+h) \times Y^2}}{2 \times (1+h)} \end{aligned}$$

Si se grafica el X mínimo necesario para cada umbral desde $U = N_{fi}$ hasta $U = N_{fo}$, se puede apreciar en la figura 11.4, para umbrales muy bajos el lado mínimo del píxel es aquel en que la fibra ocupa todo el píxel o sea $X \leq Y \times \sqrt{2}$ y para umbrales muy altos el lado máximo del píxel tiende a infinito. La gráfica es paramétrica en Y , ver figura 11.4.




Figura 11.4: Comparación de fibras

En lo que respecta al cálculo de resolución, también hay que calcular la resolución mínima para detectar la diferencia mínima de ancho entre dos fibras coloreadas.

A continuación se muestran algunos casos de resolución (X) contra el diámetro mínimo (Y) capaz de detectar.

En este ejemplo se toman como base algunas de las resoluciones del escáner HP Scanjet 8250. Se muestran los casos más restrictivos (cuando el umbral tiene el mismo valor de gris que la fibra)

- 600 *dpi* $X = 42,33 \Rightarrow Y \geq 59,87$ *micrones*
- 1200 *dpi* $X = 21,17 \Rightarrow Y \geq 29,93$ *micrones*
- 2400 *dpi* $X = 10,58 \Rightarrow Y \geq 14,97$ *micrones*
- 3600 *dpi* $X = 7,06 \Rightarrow Y \geq 9,98$ *micrones*
- 6000 *dpi* $X = 4,23 \Rightarrow Y \geq 5,99$ *micrones*
- 12000 *dpi* $X = 2,12 \Rightarrow Y \geq 2,99$ *micrones*
- 16000 *dpi* $X = 1,59 \Rightarrow Y \geq 2,25$ *micrones*
- 20000 *dpi* $X = 1,27 \Rightarrow Y \geq 1,80$ *micrones*

La tabla anterior muestra que para el peor caso se detectan fibras de diámetro mayor o igual que 29.93 micrones para una resolución de 1200 dpi.

En conclusión, con la resolución seleccionada como óptima para la base de imágenes adquiridas con el método de tolueno (1200 dpi), es suficiente para la detección de las fibras coloreadas, ya que los diámetros de las mismas están entre 20 y 40 micrones.

Capítulo 12

Apéndice C

Material adjunto y requerimientos del sistema

12.1. Contenido del DVD

Esta documentación se complementa con un DVD. El mismo tiene el siguiente contenido:

- Carpeta BasesImágenes, en la cual se encuentran todas las imágenes utilizadas durante el proyecto. En particular se encuentran las bases A, B, C y D (carpetas `BaseA`, `BaseB`, `BaseC` y `BaseD`), adquiridas con la técnica de luz balanceada, y la base adquirida con la técnica que utiliza tolueno (carpeta `Utilizando Tolueno`).
- Carpeta Documentacion, en la cual se encuentran, la documentación del proyecto (en formato PDF `FibrasColoreadasII.pdf`, y fuente LaTeX, carpeta `Documentacion en LaTeX`) y un paper con un resumen de la misma (en formato PDF `FCII_Paper.pdf`, y fuente LaTeX, carpeta `Paper en Latex`).
- Carpeta Presentacion, en la cual se encuentra la presentación final del proyecto (`FCII_Presentacion.ppt`).
- Carpeta Software, en la cual se encuentran dos versiones del software desarrollado durante el proyecto. Una versión para imágenes obtenidas con la técnica de luz balanceada (carpeta `Release 1 - Imágenes sin tolueno`), y otra para imágenes obtenidas con la técnica que utiliza tolueno (carpeta `Release 2 - Imágenes con tolueno`). En estas carpetas se encuentran los archivos ejecutables del software (`FibrasColoreadas.exe` en ambas carpetas), y el código fuente de las dos versiones.
- Portada del DVD, el archivo `index.htm` contiene vínculos a todos los archivos del DVD.

12.2. Requerimientos del sistema

12.2.1. Software

- Windows XP.
- Bibliotecas MFC.
- Para leer el contenido del DVD se requieren programas que lean los siguientes formatos: pdf, htm, ppt, jpg, png, zip.

12.2.2. Requerimientos mínimos de hardware

- Procesador de 1000 MHz.
- Memoria RAM de 256 MB.
- Disco duro de 3 GB.

Fibras Coloreadas II

Néstor Clavijo, Heric Martínez, Nicolás Menoni y Esteban Salvo

Resumen—En este documento se describirá el proyecto de fin de carrera Fibras Coloreadas II. El proyecto trata acerca del conteo y clasificación de fibras coloreadas en top de lana, a partir del procesamiento de imágenes digitales. Se desarrollaron algoritmos que insumen poco tiempo de procesamiento, lo cual permite su ejecución sobre imágenes de gran tamaño. Para el conteo de fibras coloreadas, se lograron porcentajes de acierto del 94 por ciento. Para la clasificación por tipo de fibra se logró un porcentaje de acierto de aproximadamente 80 por ciento.

Index Terms—Top de lana, lana sucia, fibras coloreadas, desviación estándar, resolución, píxel, tolueno, Fibrocaptor.

I. INTRODUCCIÓN

El nombre del proyecto es Fibras Coloreadas II. Trata sobre la detección y clasificación de fibras coloreadas en lana.

Las fibras coloreadas son fibras de lana de color oscuro, que tienen la propiedad de mantener su color original luego del proceso de teñido. Esta característica genera un problema en la manufactura de prendas de color claro, dado que estas fibras se pueden visualizar fácilmente como líneas oscuras sobre el fondo claro. Este problema disminuye la calidad de la lana, dificultando el acceso a mercados exigentes. Es por esto que el conteo de fibras coloreadas en lana forma parte del control de su calidad.

Las fibras de lana pueden ser clasificadas con valores del 1 al 8 de acuerdo a sus características. Cuando la clasificación de una fibra es igual o superior a 5, entonces se considera que se trata de una fibra coloreada.

La lana pasa por varias etapas antes de su utilización por parte de la industria textil. La lana sucia es obtenida mediante la esquila del animal, la cual se realiza usualmente una vez al año. Luego, la lana pasa por un proceso de lavado, cardado y peinado, generando de esta forma el

top. Es en este punto del proceso donde se realiza el control de calidad relacionado con el conteo de fibras coloreadas, y por ende es aquí donde se aplica el sistema de conteo y clasificación desarrollado en este proyecto.

II. ESQUEMA GENERAL DEL SISTEMA




Figura 1. Esquema general

En la figura 1 se muestra el esquema general del sistema. En éste se tiene como entrada una imagen de dimensiones $L1 \times L2$.

Dado que un requerimiento del sistema es funcionar en tiempo real, es necesario minimizar las áreas de la imagen que son procesadas. En busca de este objetivo se trata de predetectar las zonas de interés. Estas zonas son las regiones donde existe alta probabilidad de ubicarse una fibra coloreada. El bloque que realiza la predetección, es llamado *Predetección de zonas de interés* y su salida es una imagen binaria de tamaño 64 veces menor a la imagen original. De esta manera se logra una disminución del peso de los datos a procesar.

En el bloque *Obtención de puntos representativos*, se busca identificar a cada fibra mediante un conjunto de puntos. Mediante estos puntos es posible realizar el conteo de las fibras y determinar su posición en la imagen original.

Hasta este punto se trabaja sobre una imagen binaria obtenida en el primer bloque. En el bloque *Determinación de características de las fibras*, se comienza a trabajar nuevamente sobre la imagen original, pero sólo en los lugares predetectados en el bloque *Predetección de zonas de interés*. En estas zonas se extraen las características de las fibras, como por ejemplo ancho, largo y niveles de gris, para su posterior análisis en el bloque *Clasificación*.

N. Clavijo

Estudiante de la carrera Ingeniería Eléctrica
Universidad de la República, Uruguay
Teléfono: (598 2) 619-6548, e-mail: ndclavijo@adinet.com.uy

H. Martínez

Estudiante de la carrera Ingeniería Eléctrica
Universidad de la República, Uruguay
Teléfono: (598 2) 400-5598, e-mail: hericmc2@adinet.com.uy

N. Menoni

Estudiante de la carrera Ingeniería Eléctrica
Universidad de la República, Uruguay
Teléfono: (598 2) 419-4242, e-mail: nmenoni@yahoo.com

E. Salvo

Estudiante de la carrera Ingeniería Eléctrica
Universidad de la República, Uruguay
Teléfono: (598 2) 712-1156, e-mail: ersd@adinet.com.uy

III. BASES DE IMÁGENES UTILIZADAS

Para el desarrollo y prueba del sistema implementado, se utilizaron dos bases diferentes de imágenes.

La primer base utilizada es la adquirida durante el proyecto de fin de carrera *Fibras Coloreadas*, realizado en el año 2003. Esta base fue adquirida con un dispositivo llamado *Fibrocaptor* el cual se basa en la técnica de luz balanceada para la adquisición. Esta base cuenta con un total de 199 imágenes. Cada imagen fue estudiada por un técnico, el cual indicó el tipo y la cantidad de fibras coloreadas presentes. La base presenta algunos problemas que se deben al método de adquisición utilizado, y que pueden ser solucionados. Uno de los problemas es que el nivel de gris del fondo de cada imagen no es uniforme.

Para solucionar estos problemas, se realizó la adquisición de una nueva base de imágenes utilizando una técnica con tolueno (Metil-Benceno). El tolueno tiene un índice de refracción similar al de la lana, logrando, al mezclarlos, que las fibras claras se traslucen y, por lo tanto, las fibras oscuras se visualizan más claramente. Esta técnica trae aparejados algunos problemas debido a la alta toxicidad del tolueno, los cuales fueron tenidos en cuenta en el momento de la adquisición. En este método las imágenes se adquirieron con un escáner, resolviendo de esta forma el problema de la iluminación no uniforme. Luego de una serie de pruebas con imágenes de distintas resoluciones, se decidió que las imágenes que presentaban mejor relación entre tiempo de adquisición y resolución era la de 1200 puntos por pulgada, para un área de adquisición de 17 centímetros de largo y 13 centímetros de ancho. Fue con esta resolución y área de adquisición que se trabajó para el desarrollo del sistema.

IV. DETECCIÓN

Debido al pequeño espesor que tienen las fibras (entre 23 y 28 micrómetros), se hace necesario trabajar con imágenes de alta resolución para poder diferenciar los distintos tipos de fibras. Esto implica que los algoritmos que se ejecutan sobre estas imágenes consumen un tiempo considerable de procesamiento.

Para evitar este problema, se realiza una predetección de zonas que tienen alta probabilidad de contener fibras coloreadas, para luego realizar un estudio detallado de estas zonas y así descartar de antemano las zonas de poco interés.

La predetección consiste en un conjunto de algoritmos, los cuales se describen brevemente a continuación.

Detección de las zonas de interés: este algoritmo es el principal y es el encargado de submuestrear la imagen original y presentar las zonas que probablemente contengan fibras coloreadas.

El método de detección desarrollado utiliza el hecho que, cuando en una región de una imagen, aparece una gran variación en el nivel de gris de los píxeles, se produce un aumento de la varianza en la región.

El nivel de gris de los píxeles que conforman una fibra oscura es significativamente inferior al del resto de la imagen, por lo que la varianza del nivel de gris de una zona que contenga una porción de fibra coloreada, va a ser mayor que la de una zona sin fibras coloreadas.

El método de detección ubica entonces las zonas donde se produce un aumento de la varianza y las selecciona como zonas donde probablemente se pueda ubicar una fibra coloreada. Con respecto a los umbrales utilizados, los mismos se calculan localmente, o sea, se procesa una región de la imagen a la vez y dicho umbral se calcula a partir de la media y varianza de la región, y un parámetro llamado α . La salida de este primer paso es una imagen binaria de tamaño 64 veces menor a la imagen original.

Dependiendo del valor de α , la imagen binaria obtenida puede mostrar la fibras sin cortes, pero con ruido de fondo, o puede presentar cortes en las fibras y no presentar ruido de fondo.

Se calculan dos imágenes binarias, en la primera se utiliza un valor bajo de α (umbral bajo) con lo cual se predetectará buena parte de la fibra, en general toda, pero como contraparte aparecen marcadas zonas que no pertenecen a la fibra, como se muestra en la figura 2.




Figura 2. Imagen Inferior

La segunda imagen se calcula con un valor alto de α (umbral alto). De esta forma sólo las regiones que presentan mayor varianza, que en general pertenecen a la fibra, son predetectadas, pero como contraparte la fibra

queda muy seccionada, como se muestra en la figura 3.




Figura 3. Imagen Superior

A partir de las dos imágenes, se realiza un proceso iterativo en donde se toman los puntos detectados en la imagen superior y se desbordan por las zonas en donde la imagen inferior detectó la presencia de fibras. El resultado de este proceso se muestra en la figura 4.



Figura 4. Resultado de la iteración

Eliminación de cúmulos: una vez finalizado el proceso anterior, es posible que las zonas predetectadas presenten desbordes (cúmulos) que agregan zonas que no son de interés dado que no marcan la presencia de fibras. Un ejemplo de un cúmulo se puede apreciar en la figura 5




Figura 5. Cúmulo

Para eliminar dichas regiones se trabaja con la diferencia de forma que presentan los cúmulos respecto a las fibras. Se pueden clasificar los píxeles pertenecientes a la zona predetectada de la siguiente forma: se traza un cuadrado centrado en cada píxel y contando el área ocupada por los píxeles predetectados, si los mismos ocupan más de determinado porcentaje del área del cuadrado, se marca

dicho píxel para eliminar, de lo contrario se mantiene igual, figura 6.




Figura 6. Discriminación de puntos

Detección de puntas: este algoritmo tiene el objetivo de encontrar las puntas de las fibras. El método se basa en la forma que tiene la fibra. Se procede de la siguiente manera: en cada píxel detectado se traza una circunferencia y se cuentan las zonas conexas de intersección de la circunferencia y la fibra. Se discrimina en tres casos: ninguna intersección, entonces se marca la zona del píxel para luego eliminarlo. Una intersección, entonces se marca el píxel como una punta. Dos o más intersecciones, entonces no se marca el píxel. En la figura 7 se aprecian los tres casos.




Figura 7. Detección de puntas

Unión de fibras: en algunos casos la fibra queda seccionada en pequeños segmentos, ya sea porque el método de detección de zonas de interés no encontró totalmente la fibra, o por causa del método de eliminar cúmulos. Para solucionar la mayoría de estos seccionamientos, se procede de la siguiente manera: se agrupan parejas de puntas que no pertenezcan a la misma zona y disten menos de cierta distancia $2 \times R$, figura 8.

Luego se verifica si las pendientes de las fibras cerca de estos extremos son similares entre sí y también si son similares respecto al segmento que une a los dos extremos, figura 9. Si se cumplen estos requisitos, entonces se unen las dos puntas con un segmento.

Detección de puntos representativos: este algoritmo tiene como objetivo obtener un conjunto de puntos




Figura 8. Puntas cercanas




Figura 9. Pendientes

que permita individualizar cada fibra. Se procede de la siguiente manera: partiendo de un extremo A, se traza una circunferencia centrada en la misma, y se encuentra la intersección con la fibra, punto B, éste pertenece al conjunto de puntos representativos. Con los dos puntos anteriores se traza un segmento y una semicircunferencia centrada en B y simétrica respecto al segmento. Se encuentra la intersección de dicha semicircunferencia y la fibra, y se marca como otro punto representativo, figura 10.




Figura 10. Puntos representativos

Este proceso se repite hasta no encontrar más cortes entre la semicircunferencia y la fibra. En dicho caso se traza una circunferencia en el último punto encontrado y se eliminan las puntas que disten menos de R de dicho punto, para evitar realizar dos veces el proceso sobre la misma fibra. De esta forma se obtiene entonces una lista de puntos que individualizan cada fibra. Por su construcción este método permite individualizar las fibras incluso cuando se producen cruces, figura 11.

En el caso que se expone en la figura, la semicircunferencia tiene tres intersecciones, se elige la intersección más cercana a la intersección del segmento con la semicircun-




Figura 11. Cruces de fibras

ferencia.

En este punto, ya se cuenta con una imagen binaria con las zonas predetectadas, y una lista de puntos por cada fibra, por lo que es posible realizar el conteo. Sigue entonces la clasificación de las fibras en los distintos tipos.

Para realizar la clasificación, es necesario realizar un muestreo en la imagen original para poder determinar las principales características de las fibras. Se procede de la siguiente manera: se reestablece la imagen binaria a las dimensiones de la imagen original. A partir de cada punto representativo se traza un segmento perpendicular a la fibra, luego se obtienen los píxeles de la imagen original pertenecientes a dicho segmento. Si se observa un gráfico del perfil se puede observar claramente el quiebre que se produce en el nivel de gris perteneciente a la fibra, de este perfil se obtienen datos como el mínimo valor de gris, la media y el ancho, para su posterior clasificación.

V. VALIDACIÓN DEL ALGORITMO.

La validación del algoritmo se realizó utilizando la base de imágenes obtenidas con el Fibrocaptor, la cual contiene un total de 199 imágenes. En este grupo de imágenes existen 40 fibras tipo 5, 55 tipo 6, 84 tipo 7 y 68 tipo 8.

Se considera que el algoritmo funciona correctamente si es posible detectar uno o más puntos representativos de cada fibra. Se dice que existe un falso positivo cuando se detectan puntos representativos en un lugar donde no existen fibras. Se considera que existe un falso negativo cuando no son detectados puntos representativos en un lugar donde debería haber fibras.

En la tabla I se muestran los porcentajes de acierto para cada tipo de fibra.

El porcentaje total de acierto es del 94.42 por ciento.

Si se observa la tabla I se puede apreciar que las fibras tipos 5 son las que presentan un menor porcentaje de acier-

TABLE I
PORCENTAJES DE ACIERTO

Tipo de fibra	Porcentaje de acierto
Fibras Tipo 5	81.25
Fibras Tipo 6	95.56
Fibras Tipo 7	95.59
Fibras Tipo 8	100.00

to. Esto es de esperarse debido a que muchas de las fibras tipo 5 tienen un nivel de gris similar a fibras que no son detectadas por la experta. Las fibras tipo 8, que son las más claramente distinguibles, presentan el mejor porcentaje de acierto.

VI. CLASIFICACIÓN DE FIBRAS

A. Introducción

En la etapa de clasificación se busca ubicar las fibras coloreadas detectadas en uno de los cuatro tipos posibles: 5, 6, 7 u 8.

B. Planteo del problema

En los laboratorios, la detección, conteo y clasificación de fibras coloreadas son tareas desarrolladas por técnicos que comparan la muestra de lana con un patrón, determinando el tipo de una fibra coloreada por similitud con alguna de las muestras del patrón.

No existen estándares sobre las características de los distintos tipos de fibra (ancho, longitud, color, etc.). Esto lleva a que el proceso de clasificación sea subjetivo y pueda dar resultados diferentes si es realizado por técnicos diferentes. Para poder realizar la clasificación mediante un software de forma automática, se debe tener bien definido cuándo una fibra es de determinado tipo y, dado lo planteado anteriormente, la clasificación por tipo de fibra se torna difícil. Además, los porcentajes de clasificación obtenidos se relativizan, debido a que las bases de imágenes utilizadas fueron evaluadas sólo por un experto.

A continuación, se detallan los métodos ensayados para lograr la clasificación, con sus respectivos resultados.

C. Métodos utilizados

Se buscó diferenciar los distintos tipos de fibras a partir de las características de las mismas: ancho, nivel de gris o color (según si se trabaja con imágenes en escala de gris o color) y longitud.

Se implementaron métodos de clasificación utilizando las características mencionadas anteriormente en forma independiente, y también utilizando información conjunta

de ancho y nivel de gris. Para esto último se utilizaron redes neuronales y mínimos cuadrados. Para extraer la información de ancho y nivel de gris de las fibras, se utilizaron los perfiles trazados sobre las mismas. Para la determinación de la longitud, se sumaron las distancias euclidianas entre los diferentes puntos representativos de la fibra.

Ancho: se tomó como ancho de cada perfil de una fibra, la desviación estándar de la aproximación del perfil por la densidad de probabilidad de una distribución Gaussiana.

Existe un problema al utilizar los anchos para clasificar, y es que éstos son muy variables. Si se toman todos los anchos calculados en los distintos perfiles, el rango de valores es prácticamente el mismo para los cuatro tipos de fibras.

Esto se debe a varias causas:

- Las fibras coloreadas están entrecruzadas con el resto de la lana.
- Los perfiles trazados no son totalmente perpendiculares a las fibras.
- El método de cálculo del ancho: al tomar como ancho la desviación estándar de una Gaussiana, zonas con la fibra colorada cubierta por lana pueden dar un ancho grande debido a que un perfil trazado en una de esas zonas es bastante homogéneo, produciendo una Gaussiana aplanada.

Se utilizaron varios métodos de clasificación utilizando el ancho de las fibras:

- Se tomaron en cuenta los perfiles con un ancho en cierto entorno del ancho máximo. Luego se calculó el promedio de esos valores para todas las fibras de un mismo tipo y se eliminaron aquellos valores que están fuera del rango $[Media - desviación\ estándar, Media + desviación\ estándar]$. A los valores que sobrevivieron a este proceso se les calculó el promedio como valor representativo del ancho de las fibras de un tipo dado.
- Se consideró realizar la clasificación tomando alguna medida de la variación de los anchos. En particular se tomó la desviación estándar de los mismos, calculados en todos los perfiles de cada fibra, como medida para diferenciar los diferentes tipos de fibras coloreadas.

Nivel de gris: otra característica que a priori permitiría clasificar las fibras es el nivel de gris, ya que como a simple vista las fibras tipo 5 son más tenues que las tipo 8, se puede esperar encontrar alguna diferencia en el nivel de gris de los distintos tipos de fibras coloreadas. En esta

etapa surge el problema de la iluminación no uniforme. Se pueden observar diferentes niveles de iluminación en diferentes imágenes y también dentro de una misma imagen, por lo que los niveles mínimos de gris en cada perfil (que son los valores de los que se está seguros que pertenecen a la fibra) varían mucho considerando fibras de un solo tipo, y se mezclan estos valores si se consideran los diferentes tipos de fibras.

Se utilizaron arios métodos de clasificación:

- Para independizarse de la iluminación se buscó algún indicador que midiera variaciones, más que valores absolutos. El más adecuado resultó ser la desviación estándar de los mínimos niveles de gris de los perfiles de cada fibra. El mínimo nivel de gris en un perfil es un punto que tiene gran probabilidad de pertenecer a la fibra, es mas, en torno a él es que se calcula el ancho de la misma. Luego de tener todos los mínimos de los perfiles de una fibra, se calcula su desviación estándar. Con estos datos no se pudo encontrar un umbral para clasificar todos los tipos de fibra, pero si se encontró uno que permite clasificar las fibras agrupándolas en dos categorías, tipo 5 y 6 por un lado, y tipo 7 y 8 por otro.
- Se utilizó la diferencia entre la media del nivel de gris y el mínimo de cada perfil. De esta forma se obtiene un mínimo relativo a la iluminación local. Luego de tener esas diferencias para cada perfil, se calculó la desviación estándar de las mismas, tomando ese valor para clasificar las fibras en dos categorías: fibras tipo 5 y 6 por un lado, y 7 y 8 por otro, usando un umbral adecuado.

Ancho y nivel de gris: se utilizaron dos métodos para relacionar la información de nivel de gris y ancho: Redes Neuronales y Mínimos Cuadrados.

- Redes Neuronales. El hecho que la red neuronal ajuste muchos parámetros (pesos y umbrales), y siga un proceso de entrenamiento (aprendizaje), podría permitir encontrar relaciones entre los datos de entrada (diferentes combinaciones de ancho y nivel de gris), que a su vez permitirían clasificar las fibras. Se probaron varios tipos de redes neuronales: back-propagation (feed-forward, cascada, Elman, Time-delay), regresión generalizada, Hopfield, LVQ, perceptrón, probabilísticas, radialbasis y competitivas. También se investigó la posibilidad de clasificar en dos grupos, por ejemplo fibras tipo 5 y 6 por un lado, y tipo 7 y 8 por otro.
- Mínimos cuadrados. Se utilizó el método de mínimos cuadrados para aproximar funciones lineales de dos variables, ancho y nivel de gris.

Color. Se investigó si existía alguna diferencia significativa en la intensidad luminosa de las fibras coloreadas utilizando los diferentes canales (R, G, y B) o alguna relación entre dichos canales y el tipo de fibra.

Longitud Se hizo una comparación entre los largos de las fibras de los distintos tipos para ver si se encontraba alguna diferencia que pudiera permitir la clasificación.

D. Resultados y Análisis

En esta sección se detallarán los resultados cuantitativos de los métodos explicados en la sección anterior.

Ancho: utilizando datos del ancho de las fibras no se encontró ninguna forma de clasificación de las mismas.

Nivel de gris: se encontraron dos métodos que permiten clasificar las fibras dividiéndolas en dos grupos: fibras tipo 5 y 6 por un lado, y 7 y 8 por otro. El primero utiliza la desviación estándar del mínimo nivel de gris de todos los perfiles de cada fibra como forma de clasificación. Los resultados se muestran en la tabla II.

TABLE II
RESULTADOS DE CLASIFICACIÓN.

	Tipo 5-6	Tipo 7-8
Aciertos	72.5 por ciento	81.9 por ciento
Errores	27.5 por ciento	18.1 por ciento

El segundo utiliza la desviación estándar de la diferencia entre la media y el mínimo de gris en cada perfil como forma de clasificación. Los resultados se muestran en la tabla III.

TABLE III
RESULTADOS DE CLASIFICACIÓN.

	Tipo 5-6	Tipo 7-8
Aciertos	85 por ciento	79.1 por ciento
Errores	15 por ciento	20.9 por ciento

Ancho y nivel de gris: no se encontraron redes neuronales, ni se logró aproximar funciones por mínimos cuadrados, que permitieran clasificar las fibras

Color: se descubrió que el canal verde es el que permite mejor diferenciación entre los distintos tipos de fibras. Sin embargo los resultados obtenidos con este canal aplicando

los métodos de clasificación que se explicaron anteriormente, no fueron superiores a los que se obtuvieron con imágenes en escala de gris.

Longitud: no se encontró una diferencia significativa entre las longitudes de los distintos tipos de fibras, por lo que no se pudo clasificarlas utilizando esta característica.

VII. CONCLUSIONES

Se investigó lo que existía hasta el momento en este tema, poniendo énfasis en el proyecto de fin de carrera *Fibras Coloreadas* del año 2003. De dicho proyecto se utilizaron únicamente las bases de imágenes adquiridas con la técnica de luz balanceada.

Se diseñó y presupuestó un sistema completo de adquisición utilizando la técnica con tolueno. Este sistema trata de resolver todas las dificultades que surgen al trabajar con esta sustancia y asegura un procesamiento continuo para una determinada cantidad de top de lana.

El software desarrollado mejora los tiempos de ejecución y la capacidad de analizar imágenes de mayores dimensiones con respecto al proyecto anterior (procesa un área 60 veces mayor en un tiempo similar).

Se resuelve el problema de los cruces de fibra, esto es, se logra identificar cada fibra por separado aun cuando éstas se cruzan.

El porcentaje de acierto para el conteo de fibras fue del 94.4 por ciento. El cual es similar al obtenido en el proyecto de fin de carrera anterior.

Se estudiaron diferentes formas de realizar la clasificación, presentando el mejor método un 80 por ciento de efectividad. Teniendo en cuenta la dificultad de validar el algoritmo debido a la subjetividad de la clasificación del experto, se considera que este porcentaje es aceptable.

VIII. PASOS SIGUIENTES.

Los pasos a seguir en el futuro serían, implementar el dispositivo de adquisición, entrenar el software para realizar la clasificación para las imágenes adquiridas mediante la técnica con tolueno.

Otro punto sería buscar un sustituto para el tolueno que no sea tóxico. Las características que debería cumplir el sustituto son: que no sea tóxico, que tenga un índice de refracción similar a la lana y que se encuentre en estado líquido a temperatura ambiente.

Investigar la detección de fibras coloreadas en lana sin lavar. Además sería deseable encontrar un método para la detección de otras impurezas que no son fibras coloreadas pero que presentan la misma propiedad de no poder ser teñidas.

Realizar un cruce de resultados del método de clasificación actual de fibras (que se realiza mediante un experto) para observar si existe coherencia entre los resultados.

REFERENCIAS

- [1] Kernighan, B.W., Ritchie, D.M.: El lenguaje de programación C, Prentice - Hall, 1991.
- [2] Ceballos, F.J.: Curso de programación C++, Addison - Wesley, 1991.
- [3] Williams, M.: La esencia de Visual C++ 4, Prentice - Hall, 1996.
- [4] Schildt, H.: C Manual de referencia, McGraw - Hill, 1990.
- [5] Eckel, B.: Aplique C++, McGraw - Hill, 1991.
- [6] Lozano, E.: Tópicos en reconocimiento de patrones, funciones de base radial, Universidad de Puerto Rico, Recinto Universitario de Mayagüez, Departamento de Matemáticas, 2002, disponible en: <http://math.uprm.edu/elio-li/radial.pdf>, Agosto 2006.
- [7] Bose, N.K., Liang, P.: Neural Networks Fundamentals with graphs, algorithms and applications, McGraw - Hill, 1996
- [8] González, R.C., Woods, R.E.: *Tratamiento Digital de Imágenes* Addison-Wesley/Diaz De Santos, 1992.
- [9] Bazerque, J.A., Ciambelli, J.C., Lafon, S.J.: *FibroCaptor: Manual de Usuario, Detección de Fibras Coloreadas en Lana* Proyecto de fin de carrera, Facultad de Ingeniería(IIE), Universidad de la Republica, 2003.
- [10] Bazerque, J.A., Ciambelli, J.C., Lafon, S.J.: *Detector de Fibras coloreadas en Lana: Manual del Instalador, Detección de Fibras Coloreadas en Lana* Proyecto de fin de carrera, Facultad de Ingeniería(IIE), Universidad de la Republica, 2003.
- [11] Bazerque, J.A., Ciambelli, J.C., Lafon, S.J.: *FotoResaltador: Características Técnicas, Detección de Fibras Coloreadas en Lana* Proyecto de fin de carrera, Facultad de Ingeniería(IIE), Universidad de la Republica, 2003.
- [12] Perera, G.: *Probabilidad y Estadística Matemática, un primer encuentro*, Centro de Publicaciones del Centro de Estudiantes de Ingeniería, 2001.



Néstor Clavijo Nació en Treinta y Tres, Uruguay, el 3 de septiembre de 1982. Actualmente cursa quinto año de Ingeniería Eléctrica, Facultad de Ingeniería, Universidad de la República.



Nicolás Menoni Nació en Salto, Uruguay, el 4 de febrero de 1983. Actualmente cursa quinto año de Ingeniería Eléctrica, Facultad de Ingeniería, Universidad de la República.



Heric Martínez Nació en Treinta y Tres, Uruguay, el 24 de mayo de 1972. Actualmente cursa quinto año de Ingeniería Eléctrica, Facultad de Ingeniería, Universidad de la República.



Esteban Salvo Nació en Montevideo, Uruguay, el 28 de noviembre de 1982. Actualmente cursa quinto año de Ingeniería Eléctrica, Facultad de Ingeniería, Universidad de la República.