



Universidad de Oviedo
Universidá d'Uviéu
University of Oviedo

UNIVERSIDAD DE OVIEDO

Programa de Doctorado: Informática
Arquitecturas para sistemas de altas prestaciones

Área de Arquitectura y Tecnología de Computadores

Tesis Doctoral

**Inspección superficial de productos largos
en tiempo real basada en visión por computador**

D. Francisco Javier de la Calle Herrero
Director: D. Daniel Fernando García Martínez
Director: D. Rubén Usamentiaga Fernández

FECHA: Enero de 2020



RESUMEN DEL CONTENIDO DE TESIS DOCTORAL

1.- Título de la Tesis	
Español/Otro Idioma: Inspección superficial de productos largos en tiempo real basada en visión por computador.	Inglés: Surface inspection of long products in real-time based on computer vision.
2.- Autor	
Nombre: Francisco Javier de la Calle Herrero	DNI/Pasaporte/NIE: -
Programa de Doctorado: Informática	
Órgano responsable: Centro Internacional de Postgrado de la Universidad de Oviedo	

RESUMEN (en español)

La industria actual cuenta con unos estándares de calidad cada vez más exigentes. El alto nivel de calidad que fijan los estándares actuales se une a elevadas velocidades de producción generando la necesidad de sistemas automáticos de inspección que sean a la vez eficientes y rápidos.

En el caso de la inspección de productos largos, los sistemas deben situar múltiples sensores que proporcionen información de los productos desde varias perspectivas para obtener mediciones de la pieza en toda su superficie. Esto añade complejidad al desarrollo de nuevos sistemas al incluir en el diseño métodos para fusionar la información de los diferentes sensores.

Un caso particular de producto largo es el carril ferroviario. Las normas internacionales de calidad definen límites en las desviaciones del producto final de un modelo perfecto del carril en varios aspectos, entre los que destaca: superficial, planitud y dimensional.

La inspección superficial es llevada a cabo en la mayoría de los casos mediante técnicas de visión por computador. En este campo el desarrollo de sistemas que realicen esta tarea se divide en dos etapas principales: la adquisición de información y el procesamiento.

En este trabajo se plantean dos alternativas para la adquisición de información, basadas ambas en la reconstrucción en tres dimensiones del producto. La primera técnica utilizada es la fotogrametría estéreo, concretamente el llamado procedimiento de diferenciación de imágenes espectrales. La segunda técnica es la reconstrucción basada en láser.

Una vez obtenida la información de la superficie de los productos, se plantean dos soluciones para su procesamiento. Por un lado se plantea un cauce de procesamiento basado en técnicas de visión por computador que sigue un esquema convencional. Por otro lado se plantea el uso de técnicas basadas por completo en aprendizaje automático, como son las redes neuronales convolucionales.

Durante el desarrollo de la tesis se han desarrollado dos prototipos completos de captura y procesamiento de información relativa a la superficie de carriles ferroviarios. Cada uno de estos sistemas utiliza una de las técnicas mencionadas para realizar la adquisición. Ambos sistemas siguen un cauce tradicional de procesamiento de la información obtenida para la detección de defectos superficiales.

Utilizando como base el sistema de adquisición basado en fotogrametría, se ha estudiado también la aplicación de redes neuronales convolucionales sobre las imágenes generadas para detectar defectos superficiales en los productos.

Dado que las soluciones propuestas tiene como objetivo la industria actual, sus tiempos de funcionamiento han de ser acordes a los requisitos de esta industria. Por ello, se ha estudiado



su aplicabilidad como sistema en tiempo real para garantizar que puedan ser utilizados en líneas de producción reales de alta velocidad.

Los sistemas desarrollados han sido implantados en una línea de producción real y evaluados bajo la supervisión de expertos del sector. Estos dos sistemas han sido comparados con un sistema comercial de inspección superficial superando en ambos casos el rendimiento del sistema comercial.

RESUMEN (en Inglés)

Current industry has some strict quality standards. The quality level set by these standards and the high speed productions generates the need of efficient and fast automatic inspection systems.

In the case of long products, the inspection systems must place multiple sensors around the product in order to acquire the information of the product from several points of view which is needed to acquire its whole surface. This makes the systems more complex as they need to include methods to fusion the information from the different sensors.

A particular case of long product is the train rail. Quality international standards define a set of limit deviations in several aspects as surface, flatness and dimensions that the products must meet.

Surface inspection is usually carried out using computer vision techniques. In this field, the development of systems for surface quality inspection include two important phases: information acquisition and processing.

In this work two alternatives are studied to acquire information, both of them based on three-dimension reconstruction of the product. The first technique is stereo photogrammetry, specifically the method called spectral image differentiation procedure. The second technique is laser reconstruction.

Once the surface information of the products has been acquired, two possible solutions for processing are studied. The first one uses a processing pipeline using computer vision techniques following a traditional scheme. The second one is based only in machine learning techniques, as convolutional neural networks.

In this work, two complete prototypes for surface inspection of rails has been developed, including acquisition and processing. Each one of these systems uses one of the mentioned acquisition techniques. Both systems uses a traditional processing pipeline to process the acquired information in order to detect surface defects.

Based on the information acquired by the system that uses a photogrammetry technique the application of convolutional neural networks has been studied. To do so the images acquired by the system has been processed using a CNN in order to detect surface defects in the products.

The main purpose of the developed solutions is to fulfill the needs of current industry so they must meet the requirements of time set by the production lines. Therefore, their applicability in this context has been studied to ensure that they can be used in real-time in order to be used in real fast production lines.

Both developed systems have been installed in a real production line and tested under the supervision of experts. These two systems have been compared to a commercial surface inspection system bettering its performance in both cases.

Agradecimientos

Han pasado ya casi seis años desde el verano de 2014 en el que empecé en todo este mundo de la investigación. Durante este tiempo me he cruzado con muchas personas que me han ayudado de una u otra forma a llegar hasta aquí, a tener mi tesis acabada (mejor o peor, eso depende de quien la lea). A todos ellos tengo que agradecerles el haber llegado hasta aquí, citando una frase de la tesis de un amigo: "supongo que estarán satisfechos, a más de doctor ya no puedo llegar".

No puedo empezar de otra forma que no sea agradeciendo a mis directores de tesis todo el trabajo, tiempo y esfuerzo que me han dedicado. Daniel y Rubén no me han ayudado solo en esta tesis, llevan apoyándome y enseñándome desde hace años, incluyendo mi trabajo fin de grado y fin de máster. Nunca podré agradecerles todo lo que han hecho durante estos años, en especial a Daniel, para el que no tengo palabras que expresen todo lo que le agradezco. Entre los dos han trabajado conmigo, leído todo lo que escribía y corregido todo lo que que hacía, dándome consejos, sugerencias e ideas que han conseguido que este documento sea algo presentable como una tesis.

También quiero agradecer a Manuel, Joaquín y Julio que me acogieran en sus clases para empezar mi carrera docente. También a Juan Carlos y Javi, compañeros de asignaturas que estos años me ha ayudado a mejorar como profesor. Entre todos me han enseñado a dar clase (quiero pensar que bien) y sobretodo a hacerlo con ganas. En especial quiero mencionar a Manuel, del que he aprendido muchísimo durante estos tres años que he dado clase con él y del que sigo aprendiendo.

No me puedo olvidar de mis compañeros y amigos Pelayo y Bulnes, que me aguantan todos los días (lo cual no es fácil) y consiguen, por muy turbado que esté, sacarme una sonrisa. Entre los dos me convencieron para seguir en la carrera universitaria con frases como "métete a profesor... das tus clases... investigas en tus cosas...". La vida en la universidad no sería la misma sin los cafés con ellos, que me bajan un poco el nivel de estrés, y de vez en cuando me ayudan con alguna idea feliz en la investigación.

También tengo que reservar un par de líneas para todos aquellos que han

pasado durante estos años por los laboratorios del sótano: Álvaro, Adrián, Pedro, Pablo, Iván y Diego. En especial a Álvaro, que es una fuente inagotable de conocimientos y siempre está dispuesto a echar una mano.

No podía dejar de mencionar a mis compañeros de clase, con los que he formado un grupo bastante dispar, pero unido a la vez: Diego, Juárez, Pablo, Jaime, Miguel, Nico y Quirós, que siguen con sus carreras, cada uno por su lado, pero todos dispuestos a ayudar o aconsejar si es necesario.

Por supuesto, tengo que agradecer a los que me han aguantado y han ayudado a desconectar y relajarme siempre han podido. Me refiero a mis Amigos, y digo amigos con mayúscula: Willy, Pablo, Berto, Omar, Bretón, Fredo, Juli, Kike, Luis, Manu, Michi y Borja, con los que se que puedo contar siempre. Y obviamente, a Marta, que en tan poco tiempo se ha convertido en imprescindible, ella ha conseguido que estos últimos meses, en los que el trabajo parecía no acabar y las horas parecían faltar, fueran no solo soportables, sino estupendos.

Por último, pero no menos importante está mi familia. Que me han apoyado en todo, siempre. Mis padres, hermanas (y cuñado), sobrinos, tios y primas que me proporcionan una base sobre la que apoyarme para afrontar cualquier cosa a la que me enfrente. De ellos he aprendido todo lo que sé y lo que soy. En especial de mis padres, que me han inculcado la responsabilidad por el trabajo (bien hecho), sin eso no tendría sentido intentar dedicarme a esto.

A todos hay que reconocerles parte del mérito de esta tesis. Quiero pensar que he aprendido mucho, y no solo a nivel académico. Han sido unos años que recordaré siempre, sobretudo los veranos de ATC en los que las vacaciones han sido digamos... menos vacaciones. Algunos estudios afirman que hacer un doctorado perjudica a la salud mental, yo no puedo negarlo pero creo que sigo igual de *poco cuerdo* que antes, si bien con algo menos de pelo. Aunque al final, cuerdo o no, por fin puedo decir que tengo mi tesis doctoral acabada.

Resumen

La industria actual cuenta con unos estándares de calidad cada vez más exigentes. El alto nivel de calidad que fijan los estándares actuales se une a elevadas velocidades de producción generando la necesidad de sistemas automáticos de inspección que sean a la vez eficientes y rápidos.

En el caso de la inspección de productos largos, los sistemas deben situar múltiples sensores que proporcionen información de los productos desde varias perspectivas para obtener mediciones de la pieza en toda su superficie. Esto añade complejidad al desarrollo de nuevos sistemas al incluir en el diseño métodos para fusionar la información de los diferentes sensores.

Un caso particular de producto largo es el carril ferroviario. Las normas internacionales de calidad definen límites en las desviaciones del producto final de un modelo perfecto del carril en varios aspectos, entre los que destaca: superficial, planitud y dimensional.

La inspección superficial es llevada a cabo en la mayoría de los casos mediante técnicas de visión por computador. En este campo el desarrollo de sistemas que realicen esta tarea se divide en dos etapas principales: la adquisición de información y el procesamiento.

En este trabajo se plantean dos alternativas para la adquisición de información, basadas ambas en la reconstrucción en tres dimensiones del producto. La primera técnica utilizada es la fotogrametría estéreo, concretamente el llamado procedimiento de diferenciación de imágenes espectrales. La segunda técnica es la reconstrucción basada en láser.

Una vez obtenida la información de la superficie de los productos, se plantean dos soluciones para su procesamiento. Por un lado se plantea un cauce de procesamiento basado en técnicas de visión por computador que sigue un esquema convencional. Por otro lado se plantea el uso de técnicas basadas por completo en aprendizaje automático, como son las redes neuronales convolucionales.

Durante el desarrollo de la tesis se han desarrollado dos prototipos completos de captura y procesamiento de información relativa a la superficie de carriles ferroviarios. Cada uno de estos sistemas utiliza una de las técnicas mencionadas para realizar la adquisición. Ambos sistemas siguen un cauce tradicional de procesamiento de la información obtenida para la detección de defectos superficiales.

Utilizando como base el sistema de adquisición basado en fotogrametría, se ha estudiado también la aplicación de redes neuronales convolucionales sobre las imágenes generadas para detectar defectos superficiales en los productos.

Dado que las soluciones propuestas tiene como objetivo la industria actual, sus tiempos de funcionamiento han de ser acordes a los requisitos de esta industria. Por ello, se ha estudiado su aplicabilidad como sistema en tiempo-real para garantizar que puedan ser utilizados en líneas de producción reales de alta velocidad.

Los sistemas desarrollados han sido implantados en una línea de producción real y evaluados bajo la supervisión de expertos del sector. Estos dos sistemas han sido comparados con un sistema comercial de inspección superficial superando en ambos casos el rendimiento del sistema comercial.

Abstract

Current industry has some strict quality standards. The quality level set by these standards and the high speed productions generates the need of efficient and fast automatic inspection systems.

In the case of long products, the inspection systems must place multiple sensors around the product in order to acquire the information of the product from several points of view which is needed to acquire its whole surface. This makes the systems more complex as they need to include methods to fusion the information from the different sensors.

A particular case of long product is the train rail. Quality international standards define a set of limit deviations in several aspects as surface, flatness and dimensions that the products must meet.

Surface inspection is usually carried out using computer vision techniques. In this field, the development of systems for surface quality inspection include two important phases: information acquisition and processing.

In this work two alternatives are studied to acquire information, both of them based on three-dimension reconstruction of the product. The first technique is stereo photogrametry, specifically the method called spectral image differentiation procedure. The second technique is laser reconstruction.

Once the surface information of the products has been acquired, two possible solutions for processing are studied. The first one uses a processing pipeline using computer vision techniques following a traditional scheme. The second one is based only in machine learning techniques, as convolutional neural networks.

In this work, two complete prototypes for surface inspection of rails has been developed, including acquisition and processing. Each one of these systems uses one of the mentioned acquisition techniques. Both systems uses a traditional processing pipeline to process the acquired information in order to detect surface defects.

Based on the information acquired by the system that uses a photogrammetry technique the application of convolutional neural networks has been studied. To do so the images acquired by the system has been processed using a CNN in order to detect surface defects in the products.

The main purpose of the developed solutions is to fulfill the needs of current industry so they must meet the requirements of time set by the production lines. Therefore, their applicability in this context has been studied to ensure that they can be used in real-time in order to be used in real fast production lines.

Both developed systems have been installed in a real production line and tested under the supervision of experts. These two systems have been compared to a commercial surface inspection system bettering its performance in both cases.

Contenido

1	Introducción	11
1.1	Motivación y objetivos	12
2	Contexto industrial	15
2.1	Nomenclatura en carril	15
2.2	Defectología superficial en carril	17
2.3	Tolerancias superficiales	20
3	Trabajo Relacionado	21
4	Desarrollo de la tesis	27
4.1	Fotogrametría estéreo	28
4.1.1	Adquisición	28
4.1.2	Base de verdad	30
4.1.3	Procesamiento	31
4.1.4	Resultados	35
4.2	Reconstrucción láser	36
4.2.1	Adquisición	37
4.2.2	Base de verdad	42
4.2.3	Procesamiento	42
4.2.4	Resultados	45
4.3	Solución neuronal	47
4.3.1	Preparación del dataset	47
4.3.2	Entrenamiento y evaluación	48
4.3.3	Resultados	48
4.4	Resumen de resultados	50
5	Conclusiones	53
5.1	Trabajo futuro	55
5.1.1	Mejora del sistema láser	55
5.1.2	Adición de imagen de documentación	55
5.1.3	Detección en imagen 2D y fusión	56
6	Difusión	57

Contenido

6.1 Publicaciones en revista	57
6.2 Publicaciones en congreso	58
6.3 Publicaciones en periodo de revisión	59
A Lista de características	61
Bibliografía	69

Lista de Tablas

2.1	Equivalencia de términos de zonas	16
4.1	Defectos en la Base de Verdad Fotogramétrica	31
4.2	Resultados de detección en imagen fotogramétrica	35
4.3	Sistemas de prueba	40
4.4	Mediciones de adquisición y alineamiento de perfiles	41
4.5	Comparación de métricas obtenidas de los distintos métodos.	50

Lista de Figuras

2.1 Zonas del carril	16
2.2 Tipos de defectos.	19
4.1 Sistema de iluminación fotogramétrica.	29
4.2 Adquisición de imagen fotogramétrica	29
4.3 Adquisición fotogramétrica de un anagrama	30
4.4 Evolución de la segmentación de una incrustación en una imagen fotogramétrica.	33
4.5 Perceptrón multicapa	34
4.6 Perfilómetro	36
4.7 Instalación para la solución láser.	38
4.8 Problemas derivados del contexto industrial.	39
4.9 Muestras de superficies defectuosas	43
4.10 Representación diferencial de las muestras	44
4.11 Efecto del filtro para la eliminación de defectos dimensionales	44
4.12 Segmentación en imagen topográfica	46

Capítulo 1

Introducción

En la actualidad los procesos industriales se ven obligados, ya sea por normativa o por demanda del sector, a contar con sistemas de inspección de calidad. El objetivo de estos sistemas es evitar que los productos defectuosos lleguen a los clientes. Del mismo modo, una pronta detección de problemas en la cadena de producción puede llevar a subsanarlos, decrementando el coste derivado de éstos.

La inspección de calidad de los productos puede centrarse en muchos aspectos de su acabado, su composición o sus propiedades. En este trabajo se trata la calidad derivada de la superficie de las piezas producidas. En el contexto industrial al producto definido por una sección transversal en toda su longitud se le denomina producto largo. Este tipo de producto incluye una serie de dificultades para su inspección, siendo la mayor de ellas la necesidad de rodear el producto de cualquier tipo de sensores que permitan su inspección. El desarrollo de sistemas que rodean el producto implica la introducción tanto de mecanismos de sincronización para la captura de información como, *a posteriori*, la composición de un diagnóstico único a partir de dicha información. En este contexto se utiliza el carril de ferrocarril como ejemplo de estudio debido a su importancia.

La calidad superficial necesaria para que un producto sea apto para su uso está definida por estándares internacionales de calidad que especifican la cantidad de defectos que pueden contener los productos y las dimensiones mínimas para que cualquier anomalía superficial pueda ser considerada defecto superficial.

Dentro del campo de la inspección superficial es fundamental el hecho de realizar un examen no intrusivo de las piezas. La inspección puede realizarse de diversas formas utilizando diversos tipos de sensores y tecnologías. La visión por computador es un campo que incluye métodos para adquirir, procesar y analizar datos e imágenes adquiridas del mundo real con el objetivo de obtener información. Existen diversas alternativas para aplicar la visión por computador

a la inspección superficial, en este trabajo se utiliza la reconstrucción 3D para realizar la inspección.

La inspección generalmente es realizada justo antes de que el producto salga de la línea de producción para su almacenamiento y posterior transporte al cliente. En esta situación, la necesidad de una inspección rápida es crucial. La inspección de un producto completo solo puede demorarse hasta la llegada del siguiente producto de la línea de producción, o la producción se verá retrasada. La inspección no puede actuar como cuello de botella de la producción por lo que en su desarrollo deben tenerse en cuenta los tiempos con los que trabaja la industria actual.

1.1 Motivación y objetivos

En la actualidad los procesos de inspección superficial de productos largos son una parte esencial del proceso productivo debido a las estrictas normas internacionales que rigen la calidad de estos productos. Entre los métodos de inspección utilizados destaca la visión por computador, aplicada a imágenes de origen muy diverso.

En este sector se pueden encontrar sistemas comerciales que realizan la inspección superficial utilizando diversas técnicas. Estos sistemas son caros y su configuración compleja. Debido a la limitada oferta de este tipo de sistemas, las empresas productoras de productos largos se ven obligadas a tomar una de estas dos alternativas: comprar uno de estos sistemas comerciales, y pagar su configuración y mantenimiento, o desarrollar sus propios sistemas.

En el desarrollo de esta tesis se estudiarán diferentes alternativas para la inspección superficial en tiempo real de productos largos cubriendo ambas etapas del proceso de inspección: adquisición y procesamiento. Para la adquisición se tendrán en cuenta dos tecnologías que permiten la reconstrucción en tres dimensiones del producto: la reconstrucción láser y la fotogrametría estéreo. En cuanto al procesamiento se encuentran dos vertientes fundamentales que se estudiarán: el enfoque tradicional mediante pipeline de procesamiento de imagen y el enfoque de redes neuronales convolucionales. Los métodos de procesamiento y adquisición deben solventar a la vez el problema de la configuración, haciendo posible que los productores de producto largo puedan configurar los sistemas para adaptarlos a su producción de una manera sencilla.

En el contexto de los métodos de adquisición de información superficial se estudiarán dos posibles soluciones. La primera de ellas se basará en fotogrametría estéreo, concretamente utilizará el método denominado procedimiento de diferenciación de imágenes espectrales. La segunda solución explorará la posibilidad de utilizar la reconstrucción 3D láser de la superficie

para la comparación de la forma adquirida con la forma deseada del producto. Ambos métodos son no invasivos por lo que pueden ser implementados en la propia línea de producción sin riesgo de alterar los productos en el proceso. Una vez adquirida la información de la superficie de los productos se utilizarán métodos de visión por computador para desarrollar algoritmos para detectar los defectos existentes.

Tras desarrollar una estrategia de procesamiento convencional, se evaluará también la posibilidad de utilizar estrategias basadas por completo en aprendizaje automático, como son las redes neuronales convolucionales. Los resultados de esta evaluación serán comparados entonces con los obtenidos siguiendo un enfoque más tradicional. A su vez, se evaluará el esfuerzo de configuración necesario para adaptar un algoritmo de esta naturaleza a un problema concreto.

Por último, las soluciones propuestas serán evaluadas sobre productos reales, obteniendo así medidas sobre su eficacia. Para ello se tratará de instalar prototipos en una línea de producción real con el fin de obtener métricas empíricas de ratios de recuperación de defectos y de falsas detecciones. Estas métricas serán comparadas con las obtenidas al evaluar del mismo modo un sistema de inspección superficial comercial situado en la misma línea de producción.

Dado que la finalidad de estas soluciones es su uso en una línea de producción real, se estudiará que sean capaces de realizar su función en un tiempo apropiado para ser incluidos en sistemas de tiempo real, lo cual es fundamental para su utilización en la industria actual. Para ello, las soluciones propuestas deben ser optimizadas para cumplir con los requerimientos de plazos de ejecución que requiere una línea de producción real.

Capítulo 2

Contexto industrial

En este trabajo se utilizará como ejemplo de estudio el carril ferroviario, un claro ejemplo de producto largo con estrictas restricciones de calidad asociadas a su producción.

El contexto industrial asociado a la región de Asturias tiene como uno de sus agentes fundamentales a la empresa Arcelor-Mittal el mayor productor de acero del mundo con 96.42 millones de toneladas de producción en 2018. En la región se encuentra uno de los pocos trenes de producción de carriles de acero de cabeza endurecida del mundo. Esta factoría requiere de sistemas de inspección que aseguren que sus productos tienen la calidad necesaria para cumplir los requisitos de la normativa internacional.

En este contexto industrial se realiza esta tesis. Los carriles tienen una serie de requerimientos de calidad referentes a su planitud, dimensiones, calidad superficial, propiedades y método de fabricación. Todos los carriles deben ser examinados en base a todos estos requerimientos.

La calidad superficial de los carriles se mide en base a estándares internacionales, de entre los cuales uno de los más restrictivos es la Euronorma [33]. Esta norma define una serie de limitaciones que las anomalías superficiales no deben superar para no ser consideradas defectos.

2.1 Nomenclatura en carril

En la industria del acero se manejan una serie de términos para referirse a las zonas de los carriles que también se manejan en este documento.

Un perfil de carril es una sección del mismo, un corte transversal a la dirección de laminación que define el modelo de carril. Los diferentes modelos se diferencian en sus dimensiones, que pueden ser observadas superponiendo sus perfiles.

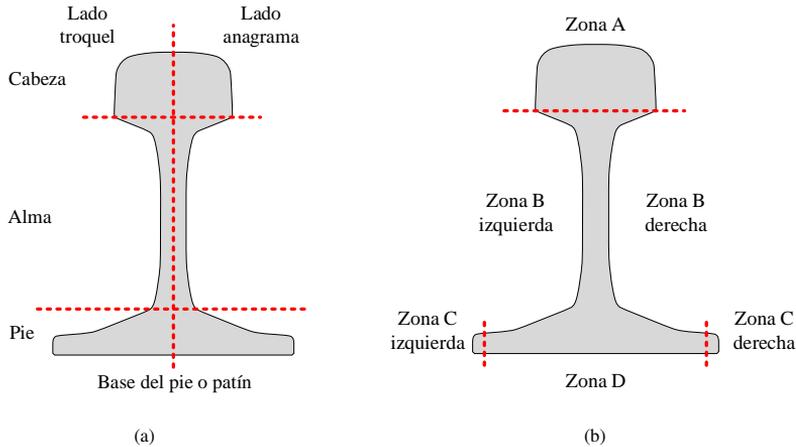


Figura 2.1: Zonas del carril

Nombre común	Equivalente internacional
Cabeza	Zona A
Alma lado troquel	Zona B izquierda
Alma lado anagrama	Zona B derecha
Lateral del pie lado troquel	Zona C izquierda
Lateral del pie lado anagrama	Zona C derecha
Base del pie o patín	Zona D

Tabla 2.1: Equivalencia de términos de zonas

En un perfil se diferencian tres partes: cabeza, alma y pie. Del mismo modo, en determinadas normas internacionales se divide el carril en cuatro zonas denominadas A, B, C y D, cada una de ellas con diferentes tolerancias superficiales. En la Figura 2.1 se puede ver un ejemplo sobre el modelo de carril CAR60E.

En la Tabla 2.1 se recogen las equivalencias de términos referentes a estas dos caracterizaciones de las zonas del carril.

La cabeza es una de las zonas críticas, es la zona superior del perfil que entrará en contacto con las ruedas de los trenes y grúas.

El pie es la zona inferior del perfil. La parte inferior de esta zona se denomina base del pie o patín, y es una zona también crítica según ciertas normas internacionales por ser la superficie sobre la que se asienta el carril en el terreno y por consiguiente le da parte de su estabilidad.

El alma es la zona intermedia del carril, situada entre la cabeza y el pie. En el

alma se sitúan los caracteres identificativos del carril. Al lado izquierdo se sitúa el troquel, compuesto por cifras numéricas estampadas mediante presión sobre la superficie, por lo que su nivel superficial es inferior a la media del carril. Al lado derecho se sitúa el anagrama, compuesto por caracteres alfanuméricos que sobresalen de la superficie del carril, por lo que su nivel superficial es superior a la media del carril.

Es frecuente el uso del término "cabeza de carril" o "cabeza de laminación" para denominar a los primeros metros de carril laminado. En cuanto a los últimos metros es frecuente el uso del término "cola de carril" o "cola de laminación". Es importante distinguir entre estos términos y los referentes a las zonas de un perfil de carril, como la cabeza de rodadura.

2.2 Defectología superficial en carril

La producción de un carril conlleva una serie de pasos desde que el llamado *bloom*, o lingote, sale de los altos hornos hasta que se convierte en un carril. En este proceso de producción se distinguen los defectos en dos grupos dependiendo de la zona del tren en la que se originan: defectos en caliente y defectos en frío.

Los defectos en caliente se originan durante el proceso de laminación cuando el carril entra y sale sucesivas veces en las cajas de laminación para obtener la forma final progresivamente. También se denominan defectos en caliente a los originados después de la salida del carril de la caja de laminación mientras el acero aun está caliente y maleable. Entre los defectos generados en caliente destacan cuatro: las incrustaciones, los pliegues, las marcas de rodillos, el hilo y las faltas de material.

- **Incrustaciones:** las incrustaciones son inclusiones de material no deseado sobre el carril debido a los rodillos de laminación. En una situación ideal, los rodillos de laminación serán perfectamente planos y estarán completamente limpios. Sin embargo, en ocasiones parte del material laminado se queda adherido al metal del rodillo siendo presionado contra el producto en una pasada posterior por la caja de laminación.

El material sobrante se queda incrustado en el producto de tal forma que es casi imperceptible al ojo humano, solo tras encontrar un punto anómalo se puede retirar el material incrustado, dejando en el carril un surco o hendidura allí donde se incrustó el material sobrante. Por ello, las incrustaciones se subdividen en incrustaciones abiertas o cerradas dependiendo de si el material incrustado ha sido ya levantado de la superficie del carril, al menos en parte.

Este tipo de defectos se suele encontrar principalmente en la cabeza de rodadura del carril aunque también es posible localizarlo en las

partes superiores del pie. En la literatura en inglés estos defectos son denominados de muchas formas, siendo las más comunes *inclusion* y *rolled-in-scrap*.

- **Pliegues:** los pliegues son dobleces en el material que posteriormente es laminado generando un hueco o cavidad interna o externa en el producto. El pliegue suele corresponderse con una línea, generalmente, recta a lo largo de la longitud del producto.
- **Marcas de rodillo:** los rodillos de laminación y los cilindros sobre los que se mueve y es enderezado el producto pueden desgastarse con el uso o contener pequeñas porciones de material pegados que generan, al paso del producto, pequeños surcos o hendiduras en la superficie. Estas marcas se denominan marcas de cilindro o rodillo. Se trata de un defecto periódico en su mayor parte dado que el material adherido al rodillo no se suelta de este con facilidad generando una marca cada revolución del cilindro.
- **Hilo:** el defecto denominado hilo es una pequeña forma de incrustación. Se trata de filamentos de acero que se quedan adheridos al material del producto al salir de las cajas de laminación. Es un defecto fácilmente subsanable.
- **Falta de material:** las faltas de material, como su propio nombre indica, son ausencias de acero sobre la superficie del producto. Puede originarse debido a tres causas: debido a la extracción del material sobrante en una incrustación, debido a la rotura de una zona del producto o debido a un comportamiento inesperado del acero durante el proceso de laminación que hace que éste no rellene correctamente todos los huecos de la matriz o molde definido en el rodillo de laminación.

Los defectos en frío son aquellos que se producen una vez el metal no se encuentra tan caliente. Aun así, este está lo suficientemente caliente como para no haberse endurecido por completo. Hay muchos tipos de defectos en frío, pero a efectos prácticos, solo dos pueden ser detectados durante el proceso de inspección dado que el resto se producen durante su almacenamiento y transporte aun siendo imputables al tren. Los defectos en frío que pueden ser detectados son las grietas y las marcas de enderezadora.

- **Grietas:** las grietas son surcos o hendiduras en la superficie del carril producto de choques contra algún elemento de la línea de producción.
- **Marcas de enderezadora:** la enderezadora es una máquina incluida dentro del proceso de producción de carril que se encarga de, como su nombre indica, enderezar el producto para que éste adquiriera la forma recta requerida, forma que puede haber perdido durante la laminación. Esta

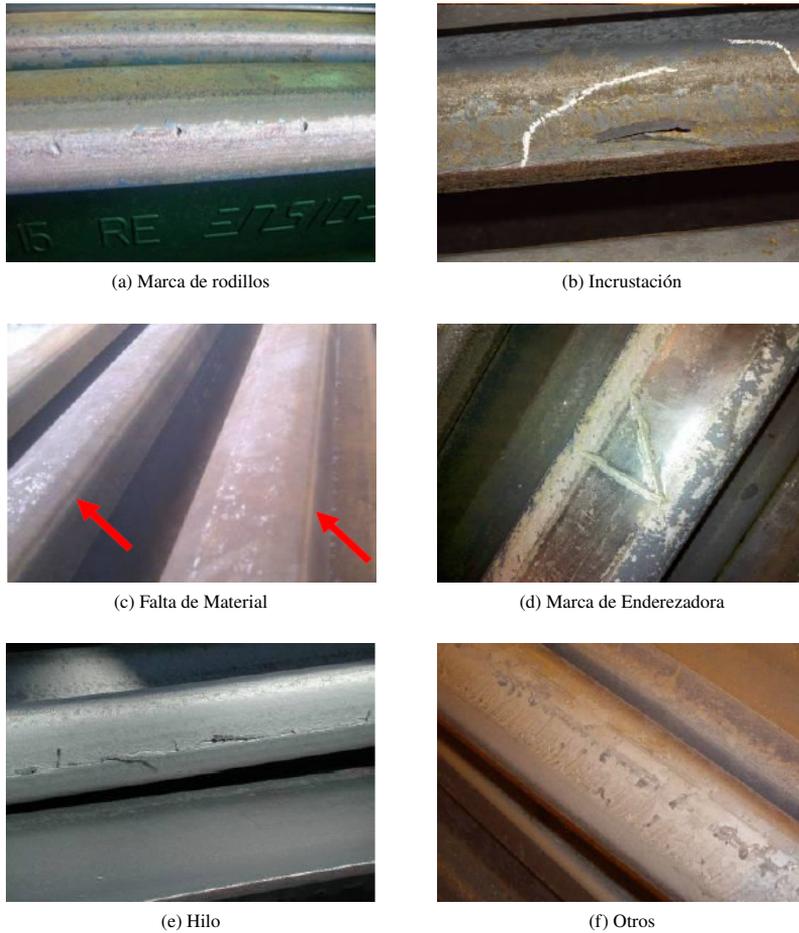


Figura 2.2: Tipos de defectos.

máquina puede generar varios tipos de marcas, las marcas longitudinales generadas por esta máquina están permitidas en la norma siempre que no superen unos límites bastante amplios. Por otro lado, existe un tipo de marca que esta máquina genera de forma aleatoria sobre la cabeza de rodadura del carril, al inicio de éste. Esta marca no es demasiado importante dado que los extremos del carril son saneados antes de su almacenamiento y envío.

En la Figura 2.2 se recogen algunos ejemplos de los defectos más comunes.

2.3 Tolerancias superficiales

Las tolerancias definidas en las normas internacionales varían. Existen normas muy permisivas que admiten anomalías del orden de milímetros en la superficie del producto. Sin embargo, las normas más utilizadas son similares a la Euronorma [33]. Este estándar de calidad define una serie de tolerancias superficiales para diversas zonas del carril. Entre estas tolerancias se encuentran reglas para delimitar anchuras, longitudes, relaciones entre anchura y longitud, profundidades y alturas de los posibles defectos.

En este trabajo se toma como referencia la tolerancia más estricta definida en las normas en base a la profundidad o altura de las marcas. No se tienen en cuenta medidas de longitud, anchura o relaciones entre éstas ya que esto último puede ser desarrollado fácilmente con una regla de exclusión de detecciones.

Así, las tolerancias de profundidad y altura aplicables en este caso son las definidas en la Euronorma. Estas son: 0.35 milímetros en altura o profundidad en cualquier marca definida en la cabeza de rodadura y 0.5 milímetros en el resto de la superficie del carril. Esta es la norma más utilizada así como la más restrictiva. Solo en un aspecto existe una norma más restrictiva que la Euronorma, ésta es la norma India para carriles asimétricos (IRST-12 [27]) que define una tolerancia de 0 milímetros en altura en las zonas C y D.

Capítulo 3

Trabajo Relacionado

La inspección superficial basada en visión por computador puede aplicarse a muchos campos y materiales distintos. En la literatura es posible encontrar ejemplos de este tipo de técnicas y algoritmos aplicados a diversos campos [34] [26]. Estos algoritmos y estas técnicas se usan frecuentemente para inspeccionar productos en busca de defectos de producción en metal [23], pero también hay muchas aplicaciones en otros campos como telas [19] o circuitos impresos [36].

La inspección superficial basada en visión por computador puede realizarse con diferentes técnicas. Las técnicas más utilizadas son adquisición de imágenes 2D y la reconstrucción 3D. En el caso de los productos largos surge una complicación añadida, toda la superficie del producto debe ser inspeccionada, por lo que el producto debe ser rodeado de sensores para ello. Este es el caso de carriles [6] o troncos [5]. Este requisito hace que las aplicaciones sean más complejas ya que se requiere que la información de todos los sensores se sincronice y se fusione.

Algunas de estas técnicas permiten la inspección de los productos, no solo en la línea de producción, sino también en su situación final. Esto es una gran ventaja en productos como los carriles [20] [38] o tuberías [8], que deben ser inspeccionados periódicamente para comprobar su estado por cuestiones de seguridad.

La cantidad de sistemas comerciales aplicables a la inspección superficial de productos largos es muy reducida. Esto fuerza a los fabricantes a desarrollar sus propios sistemas o a comprarlos a las pocas empresas que los comercializan.

El método más tradicional de inspección superficial utiliza una única fuente de luz para iluminar el producto que se desea inspeccionar y obtener imágenes 2D tradicionales para ser procesadas posteriormente. En el caso de la industria del metal las imágenes obtenidas suelen tratarse de imágenes en nivel de gris. Las imágenes resultantes se procesan para detectar variaciones de nivel de gris

en los píxeles que pueden sugerir la existencia de un defecto [17] [2]. Uno de los sistemas comerciales más potentes en la inspección superficial de planchas de metal es Parsytec de la empresa ISRA. Parsytec utiliza este método para detectar defectos. Basa su ejecución en la división de la imagen en pequeñas zonas rectangulares, denominadas azulejos o *tiles*, para después analizar cada una en busca de valores anómalos.

La reconstrucción de productos en tres dimensiones se puede realizar utilizando diferentes técnicas. Dos de las más importantes son la fotogrametría estéreo [35] [14] [37] y la reconstrucción láser [38]. Ambas técnicas se engloban dentro del campo de la luz estructurada [28]. En la fotogrametría estéreo varias fuentes de luz con propiedades conocidas se sitúan en posiciones conocidas iluminando la pieza a inspeccionar mientras que en el caso de la reconstrucción láser se utiliza una única fuente de luz (láser) para iluminar la pieza.

La fotogrametría estéreo basa la reconstrucción de la pieza en la utilización de varias cámaras cuya posición es conocida. Utilizando la información obtenida por las cámaras sobre la luz reflejada por el objeto inspeccionado (ya sea una o varias fuentes de luz) es posible estimar la profundidad en la superficie del objeto y la orientación de la superficie. Para ello es indispensable conocer la posición de las fuentes de luz y su intensidad así como la posición de las cámaras, por esta razón estos métodos son, en mayor o menor medida, susceptibles al ruido producido por luz ambiental. Utilizando esta información se reconstruye la superficie de la pieza. Dependiendo del número y la posición de las fuentes de luz se pueden utilizar diversas técnicas.

En el caso de los productos largos, una técnica fotogramétrica utilizada se denomina Procedimiento de Diferenciación de Imágenes Espectrales (Spectral Image Differentiation Procedure, SIDP) [6]. Esta técnica utiliza únicamente dos fuentes de luz enfrentadas para generar sombras a ambos lados de las anomalías superficiales de una pieza. Como las fuentes de luz utilizadas son de diferente color, solo es necesaria una cámara lineal a color para capturar la superficie y extraer las imágenes correspondientes a las diferentes fuentes de luz. Mediante la diferenciación de los dos canales de color obtenidos por la cámara es posible determinar subidas y bajadas en la superficie de una pieza móvil.

La reconstrucción láser necesita de dos componentes fundamentales, un emisor láser y una cámara matricial. Estos componentes deben estar calibrados para poder extraer la distancia del emisor a la proyección de la línea láser sobre el objeto a partir de las coordenadas de la imagen obtenida de la cámara matricial. Estos dos componentes se fabrican en la actualidad integrados en un único dispositivo, ya calibrado, denominado perfilómetro (*profilometer* o *profiler* en inglés). Hay muchos fabricantes de sensores de este tipo entre los que destacan LMI Technologies, Keyence o Automation Technologies. Estos

fabricantes desarrollan diversos modelos de este tipo de sensores para adecuarse a las necesidades de diferentes aplicaciones, generalmente variando la amplitud de visión y la distancia de medición.

Los sistemas de inspección basados en reconstrucción láser son aplicables a muchos campos en la industria ya que proporcionan de una forma rápida una nube de puntos precisa que define el perfil de la pieza inspeccionada. Muchos de estos sistemas son también muy rápidos, lo que permite incluirlos en líneas de producción con requerimientos de tiempo real. En base a las nubes de puntos obtenidas por estos sistemas se pueden desarrollar diversas aplicaciones.

En muchas ocasiones, este tipo de reconstrucción utilizando láser se aplica en la industria para obtener una reconstrucción completa de un objeto utilizando brazos robóticos [30] o adquiriendo secciones transversales de la pieza mientras se mueven el grupo de sensores o la propia pieza [29]. En muchas ocasiones el propósito de estos sistemas es la medición de diversas características del objeto, como el volumen [22] o la rugosidad [13].

Cuando la reconstrucción 3D láser se realiza sobre un producto largo, éste pasa bajo el grupo de sensores que adquieren secciones transversales denominadas perfiles. De cada perfil se obtiene una nube de puntos que puede ser utilizada para medir sus dimensiones [25], o su planitud [24]. Para esto las nubes de puntos se aproximan a modelos de fabricación. Un modelo de fabricación es una colección de arcos y segmentos que definen la forma deseada del producto en una sección o perfil.

El análisis de las nubes de puntos obtenidas se puede realizar de dos formas: aproximando los puntos obtenidos a formas geométricas para compararlos con el modelo de fabricación o utilizando la información directa de los puntos.

Las nubes de puntos obtenidas se pueden aproximar a una superficie para reconstruir una forma y evaluar un objeto. Esta técnica es utilizada, por ejemplo, para la evaluación de la estabilidad estructural de puentes [39], pero conlleva la pérdida de la información base, es decir, la posición de cada punto obtenido de la nube, lo que puede ocasionar la pérdida de pequeños detalles. Esta técnica es útil para evaluar dimensiones o formas ya que proporciona resultados muy precisos sobre la forma general del objeto, pero pierde los detalles que son vitales para la inspección superficial ya que alisa las superficies.

Si la información utilizada es la posición de los puntos hay también dos alternativas para comparar el perfil con la forma deseada. La primera consiste en calcular el punto mas cercano en la forma deseada a cada punto de la nube adquirida [38]. Esto proporciona resultados precisos sobre la diferencia entre la posición del punto obtenido y la posición en la que debería haber sido obtenido

idealmente. La segunda alternativa consiste en muestrear la forma deseada para generar una nube de puntos de referencia. La distancia desde cada uno de estos puntos de referencia al más cercano en la nube adquirida proporciona una medida comparable entre mediciones distintas ya que el mismo punto de la nube de referencia puede ser comparado en sucesivas mediciones.

Otra alternativa en la detección de defectos utilizando la nube de puntos consiste en la medición de las distancias entre cada punto de la nube y sus vecinos, de tal forma que el modelo de la forma deseada no es utilizado. Las distancias obtenidas se miden teniendo en cuenta la resolución de los sensores para detectar anomalías en la superficie [31]. Esta técnica obtiene buenos resultados en cuanto a la detección de anomalías en la superficie pero no puede asegurar el cumplimiento de ningún estándar internacional que se base en una forma predefinida.

Sea cual sea el método para generar la información sobre la pieza, el procesamiento de toda esta información en tiempo real puede llegar a ser una tarea compleja. Utilizando nubes de puntos esta tarea es todavía un reto en el caso de reconstrucciones densas para robótica [12] o reconocimiento de objetos [32]. En muchos casos el procesamiento de toda esta información se lleva a cabo con hardware específico como GPUs [10] o FPGAs [11]. Cuando este procesamiento debe ser realizado en una máquina sin aceleradoras gráficas, el algoritmo utilizado debe estar lo suficientemente optimizado para cumplir los requerimientos de tiempo real, ya sea reduciendo el número de operaciones o la cantidad de información a procesar [18].

Los procedimientos de detección de defectos sobre la información obtenida pueden realizarse de diversas formas. Tradicionalmente, la información en forma de imágenes se procesa utilizando algoritmos de visión por computador que se basan en filtros, umbrales y reglas para alisar la imagen y detectar anomalías sobre ella o ciertas formas o texturas. Esta alternativa requiere un conocimiento detallado sobre las imágenes y los métodos utilizados para poder desarrollar un algoritmo que se adapte al tipo de imagen obtenido y a la aplicación deseada de la mejor forma posible [2] [16].

Por otra parte, en los últimos años se han publicado diversos estudios relacionados con el procesamiento de imagen utilizando técnicas de inteligencia artificial y aprendizaje automático. Este es el caso del procesamiento basado en CNNs (Convolutional Neural Network) y R-CNNs (Region-based Convolutional Neural Network) que utilizan como única entrada una imagen para, después de pasar por un grupo de capas de convolución, obtener un conjunto de características que luego son evaluadas en una red neuronal fully-connected para clasificar la imagen. Esta técnica es utilizada en muchos campos ya que requiere de poco aprendizaje para su uso y proporciona buenos resultados

cuando las regiones buscadas están bien caracterizadas en las imágenes o se dispone de un conjunto de ejemplos muy amplio. Algunos ejemplos de aplicación de estos métodos se pueden encontrar en diversos campos, como circuitos impresos [4], fundición [21] o columnas de hormigón [7].

El uso de cualquiera de estos métodos requiere de una colección de ejemplos tanto de defectos como de zonas no defectuosas. En la mayoría de los casos este conjunto de ejemplos no está balanceado, ya que siempre se encontrarán mas ejemplos de productos correctos que defectuosos. En este caso se ha de tratar con un problema recurrente en la literatura: el desbalanceamiento de clases [3] [1]. Existen muchos métodos para paliar este problema, como la generación de nuevos ejemplos utilizando los existentes o el muestreo de los ejemplos más abundantes, pero su idoneidad de uso y eficacia dependen del problema a tratar.

Capítulo 4

Desarrollo de la tesis

Durante el desarrollo de esta tesis doctoral se ha utilizado como ejemplo de producto largo el carril ferroviario. Las aplicaciones desarrolladas han sido probadas en instalaciones reales en el tren de carril de Veriña, propiedad de ArcelorMittal.

El desarrollo de la tesis se puede dividir en dos grandes apartados correspondientes a las dos tecnologías de adquisición de información utilizadas: la fotogrametría y la reconstrucción láser. Estas dos secciones a su vez se dividen en los apartados correspondientes a las fases de su desarrollo: desarrollo de la solución de adquisición, recolección de muestras, desarrollo de la solución de procesamiento y resultados obtenidos.

Una última sección se corresponde con las pruebas realizadas sobre las imágenes relacionadas con la utilización de redes neuronales convolucionales.

4.1 Fotogrametría estéreo

La fotogrametría estéreo es una técnica que permite obtener una representación en tres dimensiones de un objeto utilizando varias cámaras y fuentes de luz.

Midiendo la luz reflejada de cada fuente en varios puntos del objeto basándose en las imágenes de las cámaras se pueden calcular las normales de las superficies que conforman el objeto. A mayor cantidad de puntos mayor será la precisión con la que se reconstruya el objeto.

El contenido de esta sección se corresponde con la publicación:

Inspection System for Rail Surfaces Using Differential Images

F. Javier de la Calle Herrero, D. F. García and R. Usamentiaga, "Inspection System for Rail Surfaces Using Differential Images", in IEEE Transactions on Industry Applications, vol. 54, no. 5, pp. 4948-4957, Sept.-Oct. 2018. doi: 10.1109/TIA.2018.2832606

4.1.1 Adquisición

Como técnica de adquisición se utiliza el ya mencionado Procedimiento de Diferenciación de Imágenes Espectrales. Esta técnica se utiliza para detectar anomalías volumétricas en la superficie de una pieza.

Esta técnica funciona de la siguiente manera. Dos fuentes de luz se sitúan en el camino del carril. Entre estas fuentes se sitúa un anillo de cámaras lineales a color. Las fuentes de luz deben ser de diferente color para que el método tenga sentido, en este caso se sitúan una luz azul y una luz roja. Las superficies planas reflejarán la misma cantidad de luz de la fuente azul que de la roja, independientemente de su textura. Por el contrario, las superficies con algún tipo de anomalía volumétrica reflejarán mas luz de una u otra fuente debido a las sombras producidas por la anomalía. Utilizando una cámara a color es posible dividir la imagen en los canales rojo y azul y comparar la luz reflejada por ambas fuentes.

Asumiendo que las dos fuentes de luz emiten la misma cantidad de luz sobre la superficie y que el carril tiene las mismas propiedades sobre toda su superficie (reflectividad principalmente), la diferencia entre el canal rojo y el canal azul será cero en las superficies planas y distinto de cero en las anomalías o defectos.

El sistema de iluminación formado por dos fuentes de luz se puede ver en la Figura 4.1, en la que se pueden observar dos soportes circulares para una serie de leds de colores. Estos soportes tienen un orificio central para el paso del



Figura 4.1: Sistema de iluminación fotogramétrica.

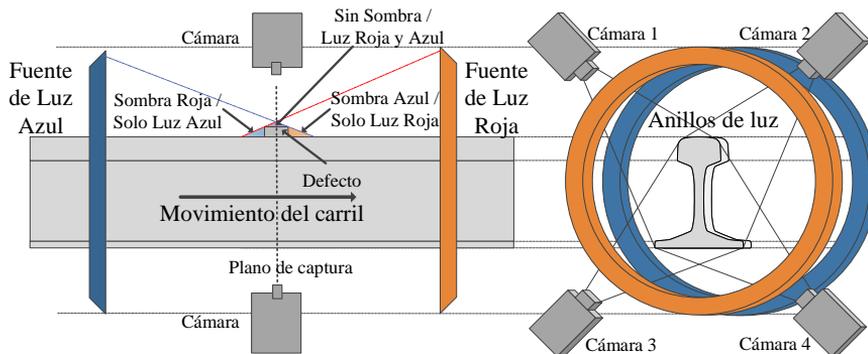


Figura 4.2: Adquisición de imagen fotogramétrica

carril, de esta forma iluminan toda la superficie del carril de manera uniforme durante su paso por la zona de inspección.

Un esquema del funcionamiento de este método se puede ver en la Figura 4.2. En este esquema se puede observar como justo antes y después de una anomalía volumétrica (un defecto) la luz reflejada por ambas fuentes es distinta, mientras que cuando no hay variación de altura tampoco hay diferencia entre la luz reflejada de ambas fuentes.

Las imágenes resultantes de la ejecución del método son imágenes

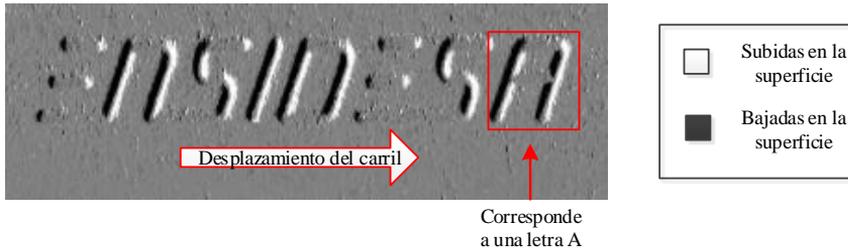


Figura 4.3: Adquisición fotogramétrica de un anagrama

diferenciales. En estas imágenes se pueden observar las subidas y bajadas del nivel superficial en el carril a lo largo de la dirección de laminación. En la Figura 4.3 se puede ver un ejemplo del resultado de aplicar este método sobre el anagrama de *ENSIDESA*. En esta figura también se observa la interpretación de las zonas sin cambios de nivel, como son los segmentos de las letras E, que impiden determinar con precisión las dimensiones de los defectos si son paralelos a este eje y su comienzo y fin están distantes.

Los píxeles de las imágenes resultantes del método tendrían valores en el intervalo $[-255,+255]$, resultado de restar los dos canales de de las imágenes. Con el objetivo de que las imágenes sean comprensibles al ojo humano, se mueve este rango a uno representable en escala de grises. Este nuevo rango se obtiene comprimiendo el rango original al rango $[-127,+127]$ y sumando una constante 127 a los valores resultantes. De este modo se obtienen imágenes en el rango $[0,255]$, un rango representable en escala de grises de forma directa pero que ofrece menos información que las imágenes originales.

4.1.2 Base de verdad

En el desarrollo de un algoritmo de detección de defectos es necesaria la existencia de una Base de Verdad. En esta Base de Verdad se recogen las ocurrencias existentes de los objetos que se desean detectar en las imágenes.

Para ello es necesario revisar de forma exhaustiva un conjunto de carriles lo suficientemente grande como para representar las posibles detecciones pero a la vez realizable en un tiempo limitado. Como conjunto para revisión se toma la decisión de escoger todos los carriles que presenten algún defecto marcado por un operador. Además, gracias a una aplicación realizada a tal efecto, un experto en inspección superficial ha sido capaz de clasificar algunos de estos defectos y posicionar correctamente la región detectada para que se ajuste bien al defecto real. Con esta decisión se asume que los carriles sin marcas no

Tipo de defecto	Instancias finales
Marca de rodillos	147
Incrustación	1425
Falta de material	19
Marcas de enderezadora	153
Hilo	247
Otros	26
Total	2017

Tabla 4.1: Defectos en la Base de Verdad Fotogramétrica

presentan defectos, por lo que cualquier anomalía detectada en sus imágenes será contabilizada como una detección errónea. Esta asunción tiene un cierto error asociado, ya que en ciertos lotes de productos, un mismo defecto se repite hasta que se descubre su causa y en estas situaciones los operarios únicamente marcan los primeros carriles con el defecto.

Siguiendo las directrices mencionadas, un conjunto de carriles procedentes del tren de laminación de carril de ArcelorMittal en Veriña son revisados exhaustivamente. De estos carriles se han obtenido imágenes mediante un sistema de inspección que sigue el método de adquisición definido en la Sección 4.1.

El conjunto de carriles revisado contiene un total de 245 carriles de entre 45 y 90 metros de largo cada uno. Cada imagen de cada uno de estos carriles es revisada para detectar todas las posibles ocurrencias de defectos. El conjunto de regiones sospechosas detectadas es contrastada por un experto. Bajo la supervisión de dicho experto en inspección superficial de carril, se clasifica cada una de las regiones detectadas obteniendo así las instancias expuestas en la Tabla 4.1.

4.1.3 Procesamiento

El procesamiento de las imágenes tiene dos objetivos: la detección de los defectos y su clasificación.

La detección de defectos se realiza utilizando varios algoritmos de visión por computador trabajando sobre imágenes diferenciales. Para la clasificación se utilizan redes neuronales como clasificadores.

El proceso de detección de defectos sobre este tipo de imagen se explica en detalle en [16].

A grandes rasgos el proceso se divide en cuatro etapas: extracción del primer plano, segmentación, selección y filtro neuronal.

En la extracción del primer plano se persiguen dos objetivos, recuperar la imagen en su formato diferencial para obtener información sobre qué zonas representan protuberancias y qué zonas representan hendiduras y al mismo tiempo filtrar el ruido en la imagen. Para realizar esto se utiliza un filtro de mediana, restando a cada píxel la mediana del valor de los píxeles vecinos. La definición de lo que se considera un vecino, el entorno, determinará la cantidad de ruido y posibles defectos que se filtran.

Tras la extracción del primer plano se procede a la segmentación. Durante la segmentación se realizan varias operaciones:

1. Umbralizado: se seleccionan únicamente los píxeles que sobrepasan un umbral, ya sean protuberancias o hendiduras.
2. Apertura: se somete a las regiones resultantes del umbralizado a una apertura, es decir, una erosión seguida de una dilatación. Esto elimina píxeles solitarios y regiones muy pequeñas.
3. Cierre: las regiones restantes después de la apertura se someten a un cierre. El cierre es la operación inversa a la apertura: una dilatación seguida de una erosión. La finalidad de esto es unir los defectos que se hayan detectado por partes (subida de nivel y bajada de nivel).
4. Filtro de área: Tras estudiar la base de verdad se realiza un filtro para eliminar todas las regiones detectadas con un área inferior a la del menor defecto detectado en la base de verdad.

La evolución de la imagen de una incrustación siguiendo las operaciones de la segmentación se muestra en la Figura 4.4.

Tras la segmentación las regiones resultantes pasan por un proceso de selección basado en reglas. Estas reglas comparan el defecto con su entorno para determinar si se trata de una detección de una parte de una zona ruidosa o un defecto propiamente dicho. Si la región se parece a su entorno probablemente sea una falsa detección. Otro tipo de regla se basa en las propiedades de la región. Concretamente se utiliza el volumen de la región para determinar si se trata o no de un defecto.

El último paso de la detección consiste en un filtrado basado en redes neuronales. Las regiones pasan por dos redes neuronales sucesivas que eliminan los anagramas y las detecciones erróneas (como cascarillas o agua) respectivamente.

Para clasificar las detecciones se extraen 41 características de cada región detectada, estas características son las 41 primeras del Anexo A. Entre estas

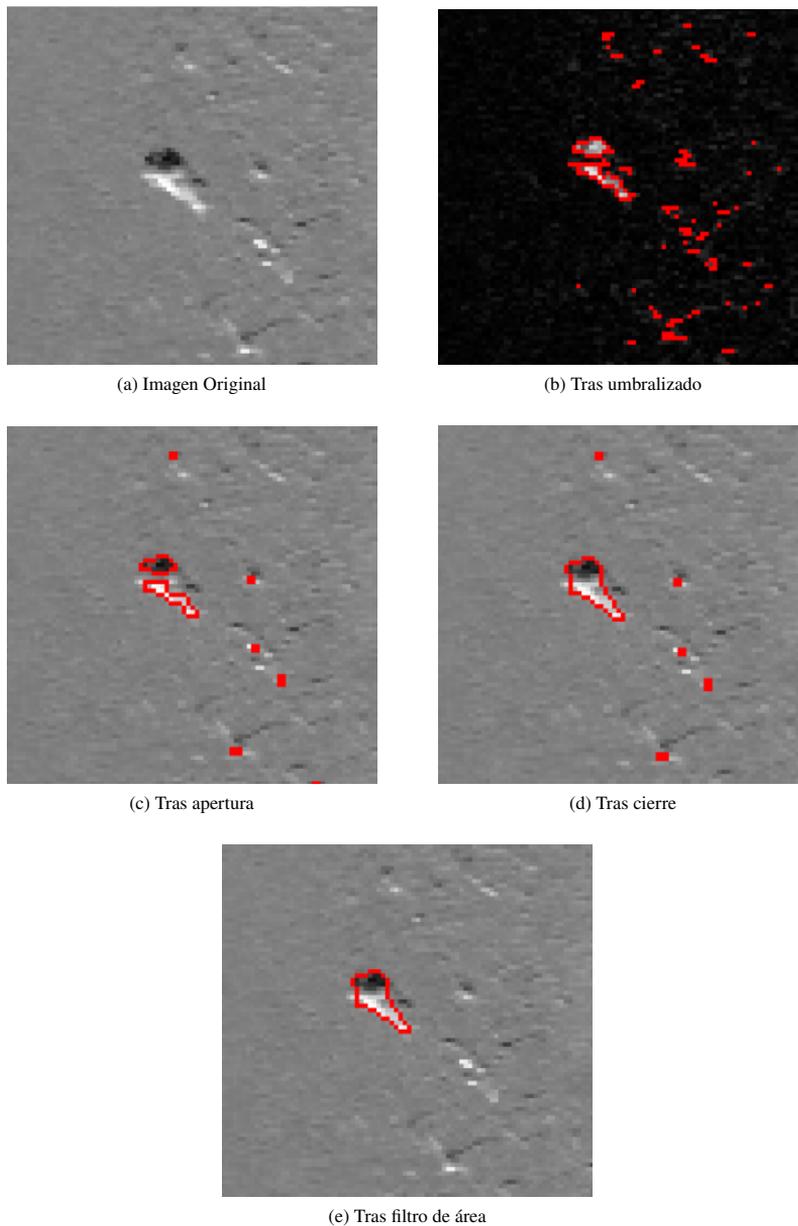


Figura 4.4: Evolución de la segmentación de una incrustación en una imagen fotogramétrica.

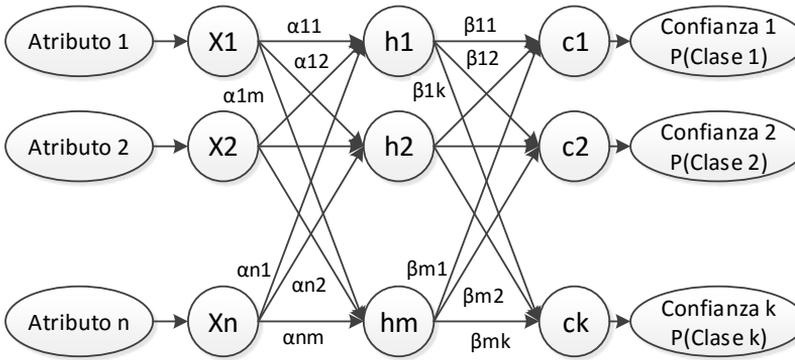


Figura 4.5: Perceptrón multicapa

características se encuentran: tamaño, valor medio, valores mínimo y máximo, centro de gravedad, homogeneidad, contraste, etc. Estas características son la entrada a las redes neuronales. Las redes neuronales utilizadas siguen el diseño de un perceptrón multicapa como el mostrado en la Figura 4.5. Como función de activación se utiliza una tangente hiperbólica en la capa oculta (4.1), donde la matriz α y el vector b^1 son los pesos de la capa de entrada y la base respectivamente.

$$h_j = \tanh\left(\sum_{i=1}^n \alpha_{i,j}x_i + b_j^1\right), j = 1 \dots m \quad (4.1)$$

Los valores de la capa oculta se obtienen utilizando diferentes funciones de activación. Esta función es una función exponencial normalizada mostrada en (4.2) y (4.3), donde la matriz β y el vector b^2 son los pesos de la capa oculta y la base respectivamente.

$$a_j = \sum_{i=1}^m \beta_{i,j}h_i + b_j^2, j = 1 \dots k \quad (4.2)$$

$$c_l = \frac{e^{a_l}}{\sum_{t=1}^k e^{a_t}}, l = 1 \dots k \quad (4.3)$$

La capa de salida se compone de k nodos. Cada uno de estos nodos representa una clase. La salida de cada nodo es la confianza o la probabilidad de que una

instancia pertenezca a dicha clase. Así, la suma de las confianzas de todas las clases debe ser 1 para cada instancia clasificada. La clase elegida para cada instancia será aquella representada por el nodo con mayor valor de salida, es decir, la mayor confianza en la clasificación.

La red neuronal descrita no utiliza como entrada las características directamente. La entrada a estas redes es la salida de un preprocesamiento de las características mediante un Análisis de Componentes Principales (PCA). Este análisis se realiza para obtener las características más relevantes para la clasificación, las cuales serán la entrada para las redes neuronales. De las 41 características, solo n componentes principales se utilizan para la clasificación.

4.1.4 Resultados

Los resultados obtenidos del procesamiento de las imágenes fotogramétricas con el algoritmo descrito y configurado se validan con los resultados que ofrece un sistema comercial instalado en las mismas instalaciones. Las imágenes obtenidas provienen originalmente de este sistema una vez procesadas, por lo que permiten comparar la eficacia de la solución de procesamiento. Para realizar esta comparativa se utiliza la base de verdad descrita en la Sección 4.1.2.

Para realizar esta comparativa es necesario definir métricas. Las dos métricas utilizadas en este caso son el *Recall* y la cantidad de Falsos Positivos (*FP*) por carril inspeccionado. El *Recall* se define como el número de detecciones correctas, *TP* (True Positive), en relación con el número de detecciones que se deberían haber realizado correctamente, es decir la suma de *TP* y *FN* (False Negative). De esta forma el *Recall* se define en (4.4).

$$Recall = \frac{TP}{TP + FN} \quad (4.4)$$

En la Tabla 4.2 se muestran los resultados de procesar la base de verdad con los dos sistemas.

Métrica	Sistema Comercial	Sistema Desarrollado
Defectos Detectados	756	946
Defectos Totales	2017	2017
Recall	0.3748	0.4690
FP/Carril Media	27.10	8.86
FP/Carril Mediana	24	7

Tabla 4.2: Resultados de detección en imagen fotogramétrica

4.2 Reconstrucción láser

La reconstrucción 3D mediante láser se realiza con pares de dispositivos emisor-cámara que actualmente pueden adquirirse integrados y precalibrados en un solo dispositivo denominado perfilómetro.

Esta tecnología se basa en la proyección de una línea láser sobre un objeto. La cámara matricial captura la línea láser proyectada sobre el objeto y obtiene una imagen. Sobre esta imagen se calcula la posición de la línea láser y mediante transformaciones geométricas se traducen las coordenadas de la imagen a coordenadas del mundo físico, obteniendo la distancia entre el emisor láser y los puntos de la línea proyectada.

Todo este procedimiento sólo es posible si se cuenta con dispositivos calibrados entre sí. En este sentido, el uso de perfilómetros simplifica enormemente el desarrollo al ser dispositivos calibrados en fábrica. Un esquema de estos dispositivos se muestra en la Figura 4.6.

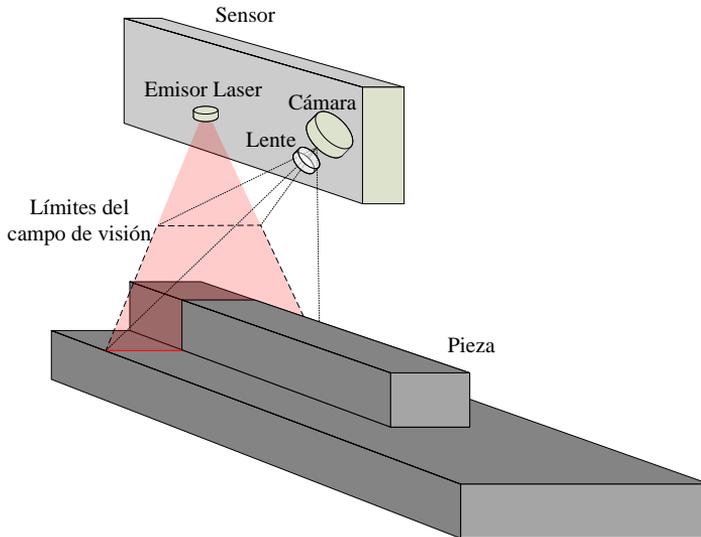


Figura 4.6: Perfilómetro

El contenido de esta sección se corresponde con las publicaciones:

Real-Time Inspection of Long Steel Products Using 3-D Sensors: Calibration and Registration

R. Usamentiaga, D. F. Garcia and F. J. de la Calle Herrero, "Real-Time Inspection of Long Steel Products Using 3-D Sensors: Calibration and Registration", in IEEE Transactions on Industry Applications, vol. 54, no. 3, pp. 2955-2963, May-June 2018. doi: 10.1109/TIA.2018.2795562

Geometric Reconstruction and Measurement of Long Steel Products Using 3-D Sensors in Real Time

R. Usamentiaga, D. F. Garcia and F. J. d. Herrero, "Geometric Reconstruction and Measurement of Long Steel Products Using 3-D Sensors in Real Time," in IEEE Transactions on Industry Applications, vol. 55, no. 5, pp. 5476-5486, Sept.-Oct. 2019. doi: 10.1109/TIA.2019.2924871

Generation of differential topographic images for surface inspection of long products

F. Javier de la Calle Herrero, D. F. García and R. Usamentiaga, "Generation of differential topographic images for surface inspection of long products", in Journal of Real-Time Image Processing. 2019. doi: 10.1007/s11554-018-0844-2

A Non-Invasive Technique for Surface Defect Detection on Long Products

F. Javier de la Calle Herrero, D. F. García and R. Usamentiaga, "A Non-Invasive Technique for Surface Defect Detection on Long Products", Journal of Nondestructive Evaluation. (En revisión)

4.2.1 Adquisición

La adquisición de información útil para la inspección superficial a partir de perfilómetros pasa por la comparación de los perfiles obtenidos con el modelo de carril, es decir, la forma ideal que debería tener el producto. Una descripción detallada del procedimiento de adquisición y comparación de los perfiles con el modelo se encuentra en [15].

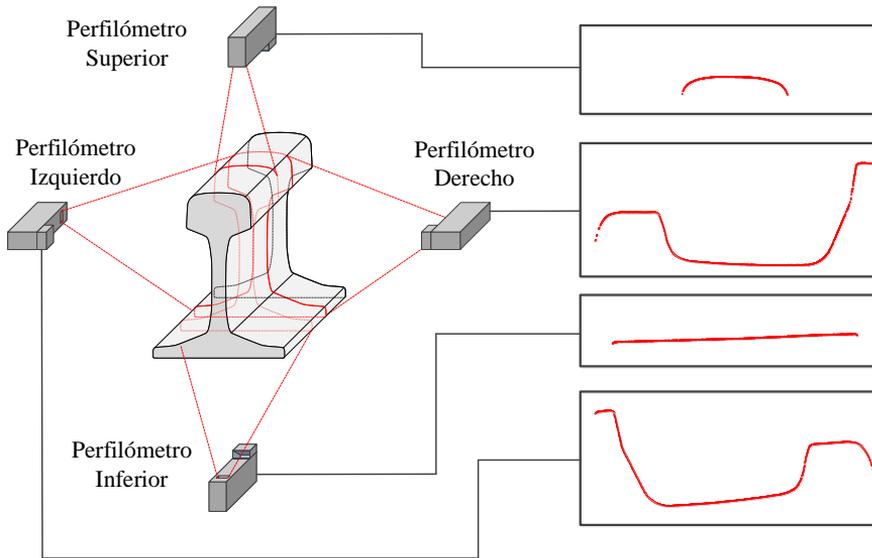


Figura 4.7: Instalación para la solución láser.

Para realizar la adquisición de perfiles se ha desarrollado un prototipo de captura que se ha instalado en la misma planta que el prototipo fotogramétrico. Este prototipo cuenta con cuatro perfilómetros que rodean el carril. Estos perfilómetros se sitúan en cruz alrededor de éste formando dos planos de medición. La existencia de dos planos de medición es necesaria para evitar que los sensores detecten de forma errónea las líneas láser proyectadas por sus vecinos.

La situación de los sensores y la obtención de líneas láser a partir de cada uno de ellos se muestra en la Figura 4.7. La instalación mostrada en la Figura 4.7 proporciona cuatro perfiles correspondientes a cuatro partes distintas del carril. Los sensores han sido situados de tal forma que pueden ser relacionados casi en su totalidad con las zonas del carril vistas en la Figura 2.1b.

Una vez los perfiles son obtenidos es necesario compararlos con el modelo de carril que se esté produciendo en ese momento. Para realizar esta comparación es necesario alinear el perfil y el modelo. En este caso la alineación se realiza de forma parcial, es decir, cada perfil obtenido se alinea con la parte del modelo que puede ver el sensor. Para poder hacer esto de forma automática se definen cuatro modelos parciales a partir de cada modelo de carril.

Para realizar la alineación se utiliza un procedimiento de alineación en dos fases. En una primera fase se aproxima la nube de puntos al modelo de una forma gruesa o aproximada para realizar, en una segunda fase, una alineación

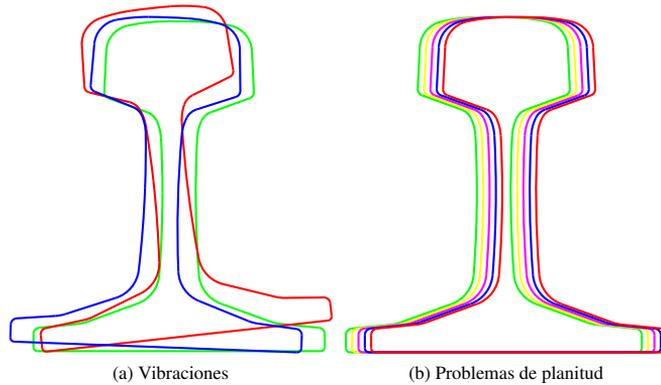


Figura 4.8: Problemas derivados del contexto industrial.

más fina mediante un procedimiento iterativo.

La alineación inicial gruesa se basa en la alineación de los centroides y orientaciones de la nube y el modelo. El centroide se calcula como la posición media de todos los puntos mientras que para el cálculo de la orientación se recurre a un análisis de componentes principales para calcular la normal a la superficie.

La segunda alineación se realiza mediante el algoritmo ICP (Iterative Closest Point). Este algoritmo estima la correspondencia de cada punto de la nube y el modelo buscando el punto más cercano en el modelo a cada punto de la nube. Una vez calculados, se realiza una transformación rígida para acercar los puntos de la nube a sus correspondencias. El algoritmo repite este procedimiento hasta que converge a una solución al problema. Esta convergencia solo se da cuando se parte de una situación cercana, por lo que la alineación gruesa es fundamental.

La alineación de la nube al modelo debe realizarse para cada perfil obtenido ya que el producto puede moverse durante su paso bajo los sensores. Esto hace que la transformación de una nube no sea válida para la siguiente, pero sí que puede utilizarse como punto de partida, es decir, como transformación inicial para la alineación gruesa. La alineación nube a nube se realiza fundamentalmente por dos causas, las vibraciones y los problemas de planitud que se ejemplifican en la Figura 4.8.

Una vez las nubes se han alineado con el modelo, se realiza una comparación punto a punto para obtener una representación diferencial de la superficie inspeccionada. Se parte de un punto común a todos los modelos de carril, la esquina inferior derecha del pie del carril. Cada punto de la nube es transformado

Tabla 4.3: Sistemas de prueba

Identificador	Procesador	Memoria
Sistema A	Intel Core I7 4790 3.60 GHz	16 GB
Sistema B	Intel Xeon E5-2687w v4 3.00 GHz	32 GB

en otro cuyas coordenadas representarán su posición en el contorno del carril y su diferencia respecto al modelo. La primera coordenada se calcula midiendo la longitud de arco desde el origen (esquina inferior derecha del pie) hasta su correspondencia en el modelo (su punto más cercano). La segunda coordenada se calcula mediante la distancia euclídea del punto a su correspondencia añadiendo si se trata de una distancia negativa o positiva utilizando para ello la normal al modelo.

Los datos obtenidos no pueden ser visualizados utilizando herramientas convencionales. Para subsanar este problema y condensar la información del carril se transforman en imágenes en escala de grises donde se utilizan las columnas para representar el contorno del carril y el nivel de gris para representar la dimensión de altura o profundidad. Este tipo de representación se puede denominar una representación plana de la superficie del carril.

Durante todo este procedimiento se procesan cantidades muy grandes de información en muy poco tiempo. La inspección debe realizarse en tiempo real para que sea útil a la empresa fabricante por lo que el algoritmo se paraleliza, se optimiza código y se reduce la cantidad de información necesaria para realizar cada paso con el objetivo de que cumpla con los requisitos de tiempo real. Para comprobar que se cumplen estos objetivos se realizan mediciones sobre dos plataformas mostradas en la Tabla 4.3.

Los resultados de las mediciones se muestran en la Tabla 4.4. Estos sensores obtienen un perfil cada 2 milisegundos, por lo que el requisito de tiempo real se resume en: realizar todo el procesamiento de un perfil en menos de 2 milisegundos, es decir, antes de que el siguiente perfil sea adquirido.

Tabla 4.4: Mediciones de adquisición y alineamiento de perfiles

Sistema A						
Métrica	Con mejoras			Sin mejoras		
	Media	Percentil 95	Percentil 99	Media	Percentil 95	Percentil 99
T. de alineación (ms)	0.137	0.271	0.709	0.138	0.407	0.686
T. de cálculo de diferencias (ms)	0.391	0.559	1.087	0.475	0.700	0.983
T. total de procesamiento (ms)	0.591	1.025	1.528	0.652	1.037	1.471
Métrica	Media	Percentil 95	Percentil 99			
Distancia media nube-modelo (mm)	0.140	0.143	0.144			
T. de generación de fila (ms)	0.098	0.453	0.960			
T. de generación de imagen (ms)	2001	2004	2450			
Sistema B						
Métrica	Con mejoras			Sin mejoras		
	Media	Percentil 95	Percentil 99	Media	Percentil 95	Percentil 99
T. de alineación (ms)	0.142	0.276	0.780	0.162	0.449	0.778
T. de cálculo de diferencias (ms)	0.378	0.614	1.094	0.523	0.625	1.083
T. total de procesamiento (ms)	0.590	1.016	1.625	0.729	1.063	1.655
Métrica	Media	Percentil 95	Percentil 99			
Distancia media nube-modelo (mm)	0.140	0.142	0.144			
T. de generación de fila (ms)	0.213	0.924	1.767			
T. de generación de imagen (ms)	2000	2438	2484			

Dos ejemplos de la generación de este tipo de imágenes se muestran en la Figura 4.9 y Figura 4.10.

4.2.2 Base de verdad

Para desarrollar un algoritmo de procesamiento para estas imágenes es necesario obtener una base de referencia o base de verdad. Las imágenes obtenidas no son propicias para que un inspector determine qué es o no es un defecto debido a que únicamente indican la diferencia contra el modelo. Por esta razón se ha utilizado el sistema fotogramétrico desarrollado previamente como sistema que permite guiar el proceso de inspección. Los defectos marcados en el sistema fotogramétrico se han buscado en las imágenes obtenidas mediante reconstrucción láser para obtener la base de verdad.

Siguiendo la filosofía mencionada se han revisado las imágenes de 65 carriles producidos durante un mes que contienen 105 defectos superficiales, en su mayoría incrustaciones. En estos carriles se han encontrado también etiquetas de identificación que serán detectadas como una anomalía superficial conocida pero que realmente no se corresponden con un defecto de fabricación.

4.2.3 Procesamiento

El procesamiento de este tipo de imágenes parte del conocimiento de que representan unas determinadas dimensiones físicas. Los píxeles de las imágenes representan 0.25×2 milímetros de carril. El algoritmo desarrollado ha de tener esto en cuenta al realizar las operaciones que sean necesarias.

El algoritmo desarrollado sigue la misma línea que el propuesto en la sección fotogramétrica. En un primer paso se realiza un filtrado de la imagen para eliminar zonas ruidosas y cierto tipo de defectos no superficiales. Estos defectos eliminados son los llamados defectos dimensionales, faltas de material continuadas en una zona del carril que producen que este no tenga las dimensiones especificadas en la norma. Aun así la superficie de estas zonas debe ser inspeccionada, sin tener en cuenta la desviación dimensional.

En este filtrado se resta a cada píxel la mediana de la columna (o fibra) en la que se encuentra. Cuando un defecto dimensional esté presente en la imagen, estará presente en toda su longitud (columna) por lo que el filtrado de mediana a lo largo de la columna elimina este defecto resaltando las imperfecciones superficiales que existan en dicha zona.

Un ejemplo del resultado de este filtro se muestra en la Figura 4.11 en la que se muestran en azul las zonas que se encuentran a mayor profundidad de la permitida en la norma y en rojo aquellas zonas con mayor altura de la permitida en la norma. En esta imagen se puede observar como un defecto dimensional



(a) Muestra A



(b) Muestra B

Figura 4.9: Muestras de superficies defectuosas

en la altura del carril se muestra en varias zonas de la imagen.

Tras este filtro se realiza la segmentación, muy similar a la realizada en el algoritmo fotogramétrico. Como paso inicial se realiza un umbralizado de la imagen utilizando como valor de umbral el valor más restrictivo de tolerancia superficial existente en las normas internacionales, este es 0.3 milímetros.

Tras el umbralizado se aplica un filtro de ruido. Determinadas zonas de la imagen, debido a la posición de los sensores alrededor del carril, son muy ruidosas debido a que la línea láser incide de forma oblicua sobre dichas superficies. Estas zonas son detectadas y filtradas automáticamente detectando concentraciones de píxeles solitarios fuera de norma en una misma columna.

El siguiente paso es la realización de operaciones morfológicas. En este paso se realiza una apertura para eliminar regiones muy pequeñas y un cierre para unir las regiones de un mismo defecto. Las máscaras utilizadas para la realización de estas operaciones no son máscaras circulares como las utilizadas en el algoritmo fotogramétrico. En este caso las máscaras son rectangulares para poder adaptarse a las condiciones reales que representan los píxeles, es

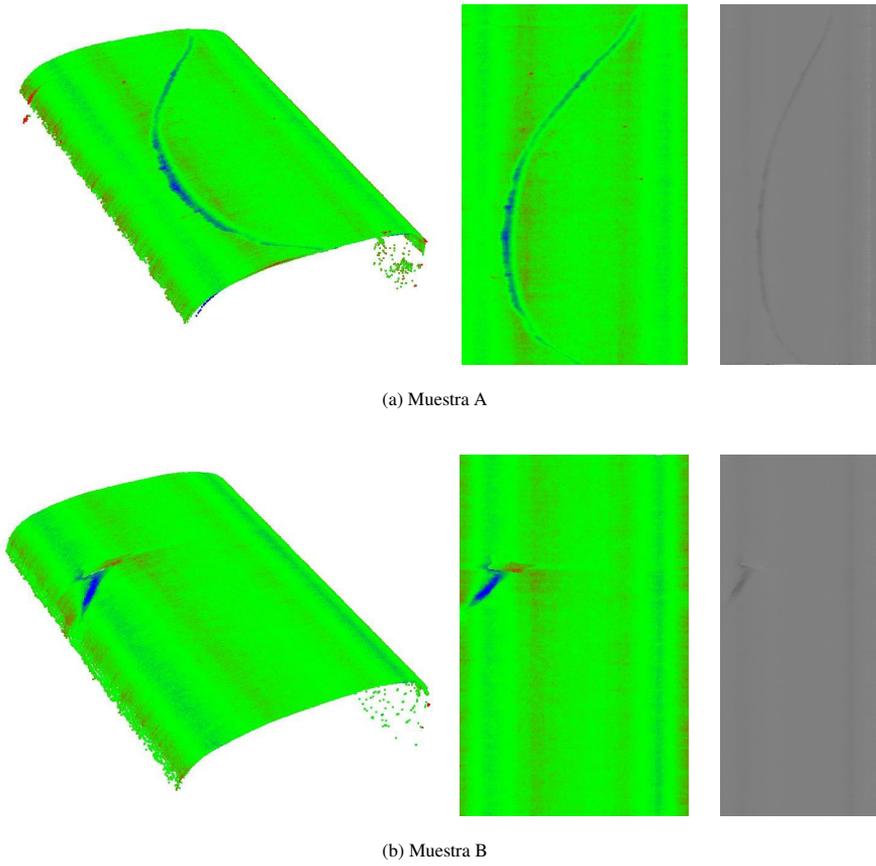


Figura 4.10: Representación diferencial de las muestras

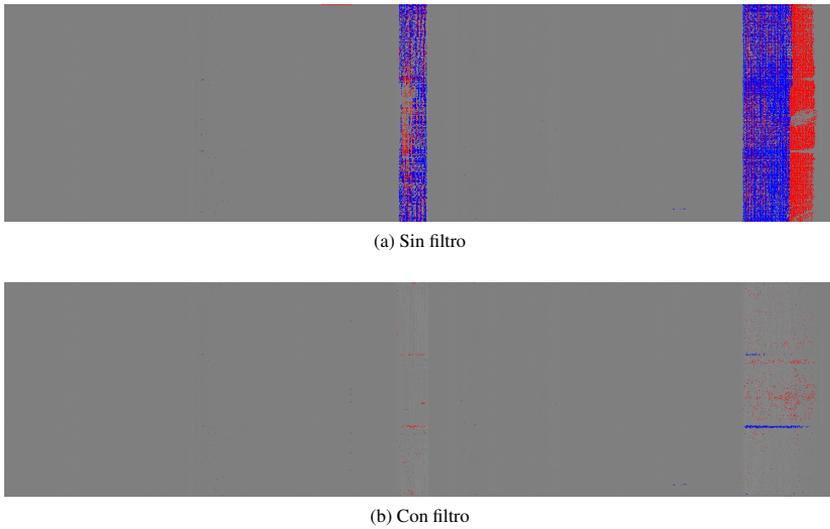


Figura 4.11: Efecto del filtro para la eliminación de defectos dimensionales

decir, diferentes medidas de longitud y anchura en milímetros.

El proceso de segmentación de este algoritmo se ejemplifica con una incrustación en la Figura 4.12.

Tras este proceso de segmentación se realiza una selección basada en el entorno y en determinadas características, tanto del defecto como de su entorno. Esta selección se lleva a cabo discriminando la zona del carril en la que se ha encontrado el defecto para realizar un filtrado dependiente de las condiciones de la zona del carril.

Como último paso del proceso de detección se filtran de nuevo las regiones detectadas utilizando una red neuronal análoga a la vista en la Sección 4.1.3. En este caso la red neuronal utiliza como entrada las 44 características incluidas en el Anexo A utilizando también un análisis de componentes principales como preprocesamiento. Esta red neuronal tiene como objetivo la eliminación de cascarilla, etiquetas y suciedad en general del conjunto de detecciones generadas por el sistema.

4.2.4 Resultados

El algoritmo descrito es evaluado sobre la base de verdad obteniendo un valor de *Recall* de 0.63 y 6 falsos positivos por carril.

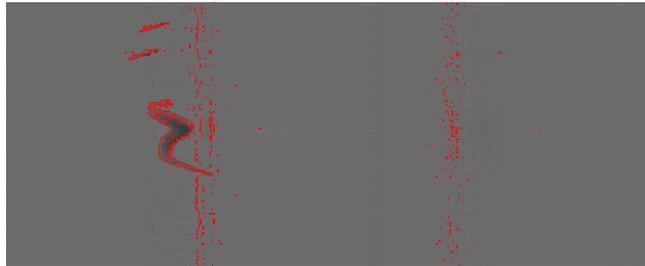
Como carril de validación se utiliza un carril patrón. El patrón es un carril con unos defectos superficiales conocidos marcados a mano. El patrón utilizado tiene once defectos longitudinales y cuatro transversales. En este caso los defectos transversales con anómalos dada la naturaleza del tren. El sistema de adquisición no obtendrá correctamente una imagen de los defectos transversales debido a la frecuencia de trabajo de los sensores. Sin embargo, los defectos longitudinales si deberían ser detectados.

De los defectos longitudinales del patrón, diez son detectados correctamente antes del filtro neuronal, de los que solo seis se mantienen después de dicho filtro. El ratio de detección de los defectos del patrón confirma el resultado obtenido de la base de verdad. En el caso de las detecciones erróneas el valor obtenido en el patrón es de ocho detecciones erróneas, lo cual se encuentra próximo al valor obtenido sobre la base de verdad.

Es importante destacar que las dimensiones de los defectos marcados en el patrón no representan el grueso de los defectos de producción del carril, siendo estos últimos de mayores dimensiones.



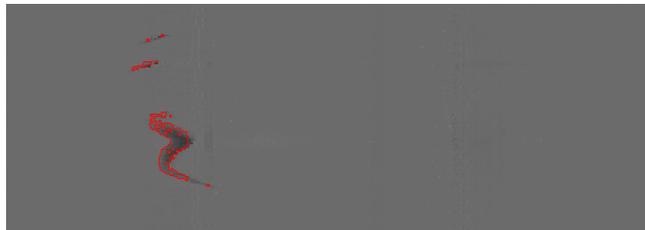
(a) Imagen original



(b) Tras umbralizado



(c) Tras filtro de ruido



(d) Tras apertura



(e) Tras cierre

Figura 4.12: Segmentación en imagen topográfica

4.3 Solución neuronal

Con el objetivo de simplificar la labor de desarrollo de los sistemas de inspección superficial, se ha evaluado la posibilidad de utilizar un enfoque más orientado al aprendizaje automático mediante el uso de redes neuronales convolucionales.

Una red neuronal convolucional obtiene como entrada un conjunto de datos organizado como un volumen en tres dimensiones. Esto es una gran ventaja para el uso con imágenes ya que la imagen en sí misma es un volumen 3D compuesto por sus dimensiones ancho y largo más una tercera dimensión de profundidad definida por el número de canales de la imagen.

Las capas de una red convolucional reciben como entrada un volumen 3D como el descrito. A la primera capa se le suministra un conjunto de datos de entrada que transforma en otro que servirá como entrada para la segunda capa, y así sucesivamente. Cuando se aplica una capa a un volumen de entrada, se genera un volumen de salida que puede variar tanto los valores en sí mismos como las propias dimensiones del volumen (dependiendo del tipo de capa).

El proceso de convolución de las primeras capas de la red genera un *resumen* de la imagen en un vector final de valores conocido como vector de características. Este vector de características servirá como entrada para la red neuronal clásica (perceptrón multicapa) con la que finaliza la red convolucional. Esta última red neuronal sirve para clasificar la imagen entre las diferentes clases que conforman el conjunto de entrenamiento.

Como datos para este pequeño estudio se ha utilizado la base de verdad descrita en la Sección 4.1.2. Esta sección se corresponde con la publicación:

A Configuration Approach for Convolutional Neural Networks Used for Defect Detection on Surfaces

D. F. García, I. García, F. J. delaCalle and R. Usamentiaga, "A Configuration Approach for Convolutional Neural Networks Used for Defect Detection on Surfaces", 2018 5th International Conference on Mathematics and Computers in Sciences and Industry (MCSI), Confu, Greece, 2018, pp. 44-51. doi: 10.1109/MCSI.2018.00019

4.3.1 Preparación del dataset

Las herramientas disponibles, en la mayoría de los casos, no permiten trabajar directamente con imágenes de un tamaño similar al de las presentes en la base de verdad. Por este motivo las imágenes disponibles deben de ser divididas en sub-imágenes más pequeñas para su clasificación.

Al dividir las imágenes se plantea el problema de etiquetarlas de forma automática. Como solución a este problema se plantea la utilización, en parte, del algoritmo de procesamiento desarrollado para estas imágenes. Conocida la situación de un defecto real (marcado en la base de verdad) se procesa la zona rectangular marcada en la base de verdad para detectar en ella el defecto utilizando el algoritmo descrito en la Sección 4.1.3 de forma adaptativa hasta el paso de segmentación. Una vez detectado el defecto se obtiene una máscara que se utilizará para etiquetar las sub-imágenes.

Cada sub-imagen se compara con la máscara generada para dicha imagen (si en la imagen en cuestión existe defecto). De existir una intersección entre la sub-imagen y la máscara, ésta será marcada como defectuosa. Las sub-imágenes que no intersecan con ninguna máscara son marcadas como libres de defectos.

4.3.2 Entrenamiento y evaluación

El entrenamiento de las redes neuronales probadas se realiza utilizando el método SGDM (Stochastic Gradient Descent Method) utilizando como función de pérdida la entropía cruzada (cross-entropy). En cada iteración del proceso de optimización un conjunto aleatorio de 128 sub-imágenes es utilizado.

Los resultados obtenidos del proceso de evaluación de la red convolucional deben ser traducidos a resultados comparables con otros métodos de detección. Por ello las sub-imágenes definidas como defectuosas se comparan con los defectos presentes en la base de verdad para generar unos valores de TP, FP y FN comparables con los obtenidos por otros métodos. Para realizar esta comparación se unen las sub-imágenes que se han clasificado como defectuosas que se encuentren adyacentes para generar *regiones defectuosas*. A partir de estas regiones el procedimiento de evaluación es el mismo que el utilizado en otros métodos.

Una explicación detallada del proceso de entrenamiento y configuración se encuentra en [9].

4.3.3 Resultados

Tras la evaluación de varias redes con arquitecturas distintas, la mejor solución obtenida presenta unas métricas de 0.71 para el *Recall* y 9 detecciones erróneas por carril.

Se ha de añadir que la detección realizada por este método marca como defectuosas zonas demasiado grandes. La reducción del tamaño de estas zonas aumenta de forma exponencial el tamaño del problema al ser necesario el entrenamiento y test de las redes con muchas más sub-imágenes mucho mas pequeñas. El hardware disponible actualmente no nos permite realizar este tipo

de pruebas en un tiempo razonable.

4.4 Resumen de resultados

En esta tesis se han desarrollado varios métodos de inspección superficial para productos largos, y concretamente, para carriles de ferrocarril. Los resultados obtenidos comparados con los de un sistema de inspección superficial de carril comercial (DIRIS NextSense) se resumen en la Tabla 4.5.

Método	Recall	FP/Carril
Sistema comercial DIRIS	0.37	27
Sistema fotogramétrico	0.46	9
Sistema láser 3D	0.63	6
CNN fotogramétrica	0.71	9

Tabla 4.5: Comparación de métricas obtenidas de los distintos métodos.

El sistema fotogramétrico descrito en la Sección 4.1 obtiene unos resultados sensiblemente superiores a los obtenidos por el sistema comercial. Este sistema obtiene imágenes en las que la medición cuantitativa del defecto no es posible. Las zonas planas de los defectos se muestran como zonas *libres de defecto* en la imagen, lo cual lleva a confusión a los inspectores.

La red neuronal desarrollada utilizando dichas imágenes, Sección 4.3, obtiene unos resultados superiores en cuanto a nivel de detección. Este método conlleva la utilización de hardware muy costoso para su desarrollo. Las detecciones obtenidas mediante este método son, para los inspectores, muy vagas. Esto se resume en que para que este sistema resulte útil para los inspectores de calidad, el tamaño de las sub-imágenes utilizadas para la clasificación de las imágenes debe ser muy inferior. Este cambio conlleva un incremento notable tanto en el coste del hardware necesario como en el tiempo de desarrollo.

El sistema láser, Sección 4.2 proporciona unos resultados de detección bastante buenos y un bajo número de detecciones erróneas por carril. Además, los defectos obtenidos por este sistema pueden ser medidos con precisión y adaptar su detección a la norma internacional utilizada. Sin embargo, este sistema produce un tipo de imágenes que no son adecuadas para su visualización por parte de un inspector de calidad. Se trata de imágenes demasiado artificiales para que resulten comprensibles fácilmente por los inspectores de calidad y, en última instancia, por los clientes.

Todos los métodos desarrollados tienen ventajas derivadas de su uso. La solución que aporta más funcionalidad es la utilización de la reconstrucción por láser, siendo posible la medición precisa de las anomalías y su comparación con las reglas de aceptación definidas en las normas internacionales. De todas formas, la solución ideal sería la integración de este sistema con un sistema de adquisición de imágenes tradicionales, calibrado conjuntamente,

para proporcionar a los inspectores de calidad una imagen tradicional de la superficie del producto sobre la que se pueda medir con precisión utilizando la información de la imagen topográfica proporcionada por el sistema láser.

Capítulo 5

Conclusiones

En el desarrollo de esta tesis se han presentado varias soluciones aplicables a la inspección superficial de productos largos en tiempo real. En concreto, se ha estudiado la aplicabilidad de distintos métodos de captura y procesamiento de información en el contexto industrial de la producción de carril ferroviario.

El primer prototipo desarrollado se basa en fotogrametría usando un método de adquisición denominado Procedimiento de Diferenciación de Imágenes Espectrales para obtener imágenes diferenciales de la superficie de los productos. Una vez obtenidas las imágenes, son procesadas mediante un algoritmo de detección de defectos desarrollado específicamente para este tipo de imagen.

El segundo prototipo desarrollado utiliza la reconstrucción láser para obtener información de la superficie del producto y compararla con el modelo de fabricación. De esta forma se obtiene una imagen topográfica de la superficie del producto en la que es posible medir las anomalías de forma directa. Para realizar la detección de defectos en este tipo de imágenes se ha desarrollado un algoritmo de procesamiento que tiene en cuenta los factores dimensionales que definen las imágenes. De esta forma es posible realizar la detección de defectos utilizando como base las normas internacionales que rigen la calidad superficial del producto.

Para ambos métodos se ha conseguido el objetivo previsto sobre su configurabilidad. Cada método de detección desarrollado es acompañado de un método de configuración sistemático desarrollado en esta tesis. Esto permite a los fabricantes de carril utilizar este método y adaptarlo a su producción.

Tras un proceso de optimización basado en la reducción de datos, el cacheado y la algoritmia, se cumple el objetivo de que los métodos propuestos cumplan el objetivo de realizar su tarea cumpliendo los plazos de ejecución impuestos por el proceso de fabricación de los productos.

Ambos prototipos han sido instalados en un tren de laminación de carril de cabeza endurecida propiedad de la empresa ArcelorMittal. En estas instalaciones se han obtenido datos suficientes para realizar una evaluación de ambos sistemas. Para realizar esta evaluación se conformó una base de verdad de defectos para cada uno de los sistemas bajo la supervisión de expertos en inspección superficial de la empresa. Utilizando estas bases de verdad ha sido posible la evaluación de los algoritmos de detección desarrollados en esta tesis y su comparación con un sistema de inspección superficial comercial situado en la misma línea de producción. Esta comparativa muestra que los prototipos desarrollados cumplen también el objetivo de mejorar el rendimiento de un sistema de inspección superficial comercial que se ha utilizado como referencia. Esta mejora es observable tanto en el ratio de detección de defectos como en el ratio de detecciones erróneas. Ambos prototipos han sido configurados para llegar a un equilibrio entre la detección de defectos y la no-detección de regiones detectadas erróneamente como defecto.

Otro de los objetivos de esta tesis era la evaluación de una solución de detección de defectos basado en aprendizaje automático, concretamente en redes neuronales convolucionales. Para ello, la base de verdad producida para la evaluación del primer prototipo ha sido utilizada también para desarrollar una variante de detección basada en redes neuronales convolucionales. Esta variante ha demostrado ser eficaz en la detección de defectos obteniendo unas métricas de rendimiento similares a las de los otros dos prototipos. No obstante, para que el método pueda realizarse de una forma útil para los inspectores de calidad se requeriría de hardware más costoso y de más tiempo de desarrollo. La necesidad de ampliación de la capacidad de cómputo para hacer viable la utilización de este tipo de métodos en la inspección superficial hace que su desarrollo y configuración no sea abordable por el productor de carril.

El prototipo basado en fotogrametría proporciona unas imágenes fácilmente interpretables por un inspector de calidad o un cliente. Sin embargo, estas imágenes propocionan una detección cualitativa de los defectos, lo cual es una gran desventaja a la hora de medirlos. Por otro lado, el prototipo basado en reconstrucción 3D láser proporciona una detección cuantitativa de los defectos, sobre la cual es posible medirlos. Al contrario que el anterior, las imágenes producidas por éste no son directamente interpretables ni por los inspectores de calidad ni por los clientes. La solución óptima se encontraría en la fusión de ambos sistemas proporcionando una detección cuantitativa y unas imágenes interpretables por un inspector humano, a costa de incrementar el coste del sistema por la necesidad de mantener la infraestructura de ambos prototipos.

La solución con mejores prestaciones de entre lo evaluado para la inspección superficial es la reconstrucción láser. Ésta proporciona una detección

cuantitativa de los defectos de carril con unos ratios de detección aceptables para los fabricantes de carril. La gran ventaja es que proporciona la posibilidad de realizar la detección de defectos siguiendo directamente los parámetros de las normas internacionales. Sin embargo, este sistema se ha de fusionar con algún tipo de sistema de documentación gráfica de la superficie del carril para ser vista por inspectores y clientes.

5.1 Trabajo futuro

El trabajo futuro en la línea de la tesis comprende tres ramas bien diferenciadas que se recogen a continuación.

5.1.1 Mejora del sistema láser

En primer lugar existe un problema con la alineación de los perfiles obtenidos por el sistema láser. Los perfiles se alinean de forma rígida contra un modelo parcial, pero esto no es del todo correcto puesto que se está asumiendo que la superficie inspeccionada tiene, en cierta forma, las mismas medidas que el modelo deseado. El hecho de que esta presunción no se cumpla no es en sí misma un defecto superficial, sino un defecto dimensional. Esto se pretende subsanar realizando una alineación piramidal orientada a la alineación local. Es decir, alinear el perfil contra el modelo parcial para en un segundo paso alinear correctamente los puntos correspondientes a cada pequeña zona. De este modo las superficies se evalúan sin tener en cuenta las dimensiones, erróneas o no, del producto.

Por otro lado se plantea la posibilidad de ampliar el tamaño de los píxeles generados en las imágenes para disminuir el ruido y poder aplicar unos parámetros de sensibilidad superior en el algoritmo de procesamiento.

5.1.2 Adición de imagen de documentación

Las imágenes producidas por el sistema de reconstrucción 3D láser instalado en la factoría no representan la superficie que ve directamente ni el inspector de calidad ni el cliente final, por lo que es necesario un proceso de aprendizaje para su correcta comprensión. Es necesario incluir un sistema de cámaras lineales para generar una imagen tradicional del carril que complemente la información de la imagen topográfica generada por el sistema de reconstrucción 3D láser.

Este sistema debe calibrarse para conseguir la identificación de cada píxel de las imágenes producidas con una zona del carril de forma inequívoca. De esta forma será posible utilizarlas conjuntamente con las imágenes topográficas para documentar el estado de la superficie de un carril.

5.1.3 Detección en imagen 2D y fusión

A partir del sistema de documentación basado en imagen tradicional es posible realizar un segundo procesamiento basándose en un algoritmo como el empleado en el sistema Parsytec [2] para detectar defectos que únicamente son visibles, o son más diferenciables, por la coloración del metal.

Con esta segunda detección sería posible realizar una fusión de información, tanto para medir lo detectado en el sistema 2D como para documentar correctamente lo detectado en el sistema 3D. De esta forma, se realizaría una fusión de la detección cualitativa del sistema 2D (hay defecto/no hay defecto) con la detección cuantitativa del sistema 3D (medición del defecto), haciendo más robusta la detección de defectos. Con estos dos sistemas trabajando conjuntamente se podría dar a los inspectores de calidad una documentación visual y medible de la superficie de las piezas.

Capítulo 6

Difusión

En esta sección se incluyen las publicaciones realizadas durante el periodo de tesis así como una última publicación en periodo de revisión.

6.1 Publicaciones en revista

- **Inspection System for Rail Surfaces Using Differential Images**
 - **Autores:** F. Javier de la Calle Herrero, D. F. García and R. Usamentiaga
 - **Título:** Inspection System for Rail Surfaces Using Differential Images
 - **Revista:** IEEE Transactions on Industry Applications, vol4, no.5, pp. 4948-4957
 - **Año:** 2018
 - **doi:** 10.1109/TIA.2018.2832606
 - **Impact Factor (2018):** 3.347
 - **Cuartil en índice JCR (2018):** Q1 (16/88)
- **Real-Time Inspection of Long Steel Products Using 3-D Sensors: Calibration and Registration**
 - **Autores:** R. Usamentiaga, D. F. Garcia and F. J. de la Calle Herrero
 - **Título:** Real-Time Inspection of Long Steel Products Using 3-D Sensors: Calibration and Registration
 - **Revista:** IEEE Transactions on Industry Applications, vol. 54, no. 3, pp. 2955-2963
 - **Año:** 2018
 - **doi:** 10.1109/TIA.2018.2795562
 - **Impact Factor (2018):** 3.347

- **Cuartil en índice JCR (2018):** Q1 (16/88)
- **Geometric Reconstruction and Measurement of Long Steel Products Using 3-D Sensors in Real Time**
 - **Autores:** R. Usamentiaga, D. F. Garcia and F. J. d. Herrero
 - **Título:** Geometric Reconstruction and Measurement of Long Steel Products Using 3-D Sensors in Real Time
 - **Revista:** IEEE Transactions on Industry Applications, vol. 55, no. 5, pp. 5476-5486
 - **Año:** 2019
 - **doi:** doi: 10.1109/TIA.2019.2924871
 - **Impact Factor (2018):** 3.347
 - **Cuartil en índice JCR (2018):** Q1 (16/88)
- **Generation of differential topographic images for surface inspection of long products**
 - **Autores:** F. Javier de la Calle Herrero, D. F. García and R. Usamentiaga
 - **Título:** Generation of differential topographic images for surface inspection of long products
 - **Revista:** Journal of Real-Time Image Processing, pp 1-14
 - **Año:** 2019
 - **doi:** 10.1007/s11554-018-0844-2
 - **Impact Factor (2018):** 2.588
 - **Cuartil en índice JCR (2018):** Q2 (10/28)

6.2 Publicaciones en congreso

- **A Configuration Approach for Convolutional Neural Networks Used for Defect Detection on Surfaces**
 - **Autores:** D. F. García, I. García, F. J. delaCalle and R. Usamentiaga
 - **Título:** A Configuration Approach for Convolutional Neural Networks Used for Defect Detection on Surfaces
 - **Conferencia:** 2018 5th International Conference on Mathematics and Computers in Sciences and Industry (MCSI), Confu, Greece, 2018, pp. 44-51.
 - **doi:** 10.1109/MCSI.2018.00019

6.3 Publicaciones en periodo de revisión

- **A Non-Invasive Technique for Surface Defect Detection on Long Products**
 - **Autores:** F. Javier de la Calle Herrero, D. F. García and R. Usamentiaga
 - **Título:** A Non-Invasive Technique for Surface Defect Detection on Long Products
 - **Revista:** Journal of Nondestructive Evaluation
 - **Impact Factor (2018):** 2.139
 - **Cuartil en índice JCR (2018):** Q2 (12/33)

Anexo A

Lista de características

Para el uso de una red neuronal es necesario definir una serie de características para cada una de las zonas que se desean clasificar. Estas características se enumeran a continuación:

1. Área: Área de la región que forma el defecto utilizando el nivel de gris de cada pixel para el cálculo. Esto lo podría aproximar más al “volumen de gris” de la región en la imagen. Siendo el nivel de gris de cada píxel $g(row, column)$ se define el área en la ecuación (A.1).

$$\sum_{(r,c) \in R} g(r, c) \quad (A.1)$$

2. Fila de centro de gravedad: El centro de gravedad se obtiene también en base al nivel de gris de los píxeles, definido por los dos primeros momentos normalizados del nivel de gris $(m_{1,0}, m_{0,1})$. Esta característica se define en la ecuación (A.2).

$$m_{p,q} = \frac{1}{A} \sum_{(r,c) \in R} r^p c^q g(r, c) \quad (A.2)$$

3. Columna de centro de gravedad: Columna del centro de gravedad correspondiente a la fila de la característica anterior.
4. Altura: Altura del defecto. Dimensión del defecto en el eje longitudinal.
5. Anchura: Anchura del defecto. Dimensión del defecto en el eje transversal.
6. Fila del centro del defecto en la imagen: Fila en la que se encuentra el centro del rectángulo que contiene el defecto dentro de la imagen original.
7. Columna del centro del defecto en la imagen: Columna en la que se encuentra el centro del rectángulo que contiene el defecto dentro de la imagen original.

Las cuatro características siguientes se obtienen a partir de una matriz de coocurrencia. Una matriz de coocurrencia (co-ocurrence matrix) es, a grandes rasgos, una matriz cuadrada que muestra cuantas veces se repite la adyacencia $i - j$ en una dirección dada y coloca este valor en la celda (i, j) de la matriz. En este caso la matriz esta modulada para distinguir entre seis niveles de gris. Un ejemplo de esta matriz con 4 valores podría ser la que se muestra en la ecuación (A.3).

$$A = \begin{bmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{bmatrix} \text{coocurrencia} A0^0 = \begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix} \quad (\text{A.3})$$

$width$ = Anchura de matriz de coocurrencia

$c_{i,j}$ = Entrada en la matriz de coocurrencia

$$\begin{aligned} u_x &= \sum_{i,j=0}^{width} i * c_{i,j} \\ u_y &= \sum_{i,j=0}^{width} j * c_{i,j} \\ s_x^2 &= \sum_{i,j=0}^{width} (i - u_x)^2 * c_{i,j} \\ s_y^2 &= \sum_{i,j=0}^{width} (j - u_y)^2 * c_{i,j} \end{aligned} \quad (\text{A.4})$$

8. Energía de los valores de gris: Utilizando las ecuaciones definidas en (A.4) se define la energía en la ecuación (A.5).

$$\text{Energy} = \sum_{i,j=0}^{width} c_{i,j}^2 \quad (\text{A.5})$$

9. Correlación de los valores de gris: Medida de la dependencia de valores de gris. Utilizando las ecuaciones definidas en (A.4) se define la correlación en la ecuación (A.6).

$$\text{Correlation} = \frac{\sum_{i,j=0}^{width} (i - u_x)(j - u_y)c_{i,j}}{s_x s_y} \quad (\text{A.6})$$

10. Homogeneidad local de los valores de gris: Utilizando las ecuaciones definidas en (A.4) se define la homogeneidad local en la ecuación (A.7).

$$Homogeneity = \sum_{i,j=0}^{width} \frac{1}{1 + (i - j)^2} c_{i,j} \quad (A.7)$$

11. Contraste de los valores de gris: Medida de la cantidad de diferencias de intensidad. Utilizando las ecuaciones definidas en (A.4) se define el contraste en la ecuación (A.8).

$$Contrast = \sum_{i,j=0}^{width} (i - j)^2 c_{i,j} \quad (A.8)$$

12. Eje mayor de la elipse: Longitud del eje mayor de la elipse que engloba la región del defecto con la misma orientación y el mismo “aspect ratio” (relación entre ejes).
13. Eje menor de la elipse: Longitud del eje menor de la elipse que engloba la región del defecto con la misma orientación y el mismo “aspect ratio” (relación entre ejes).
14. Orientación de la elipse: Orientación de la elipse que engloba la región del defecto con la misma orientación y el mismo “aspect ratio” (relación entre ejes), determinada por el ángulo entre su eje mayor y el eje x de la imagen.
15. Convexidad: Siendo F_c el área de la envolvente convexa de la región y F_0 el área de la región, la convexidad C se define en la ecuación (A.9).

$$C = \frac{F_0}{F_c} \quad (A.9)$$

16. Compacidad (compactness): Si L es la longitud del contorno de la región y F es el área del defecto, la compacidad C se define en la ecuación (A.10).

$$C = \frac{L^2}{4F\pi} \quad (A.10)$$

17. Media del nivel de gris: Si R es una región, p un píxel de R , $g(p)$ el valor de gris del píxel p de R y F la cardinalidad del conjunto de píxeles de la región tal que ($F = |R|$), se define la media del nivel de gris en la ecuación (A.11).

$$Mean = \frac{\sum_{p \in R} g(p)}{F} \quad (A.11)$$

18. Desviación estándar del nivel de gris: Si R es una región, p un píxel de R , $g(p)$ el valor de nivel de gris del píxel p de R y F la cardinalidad del conjunto de píxeles de R tal que ($F = |R|$), se define la desviación estándar en la ecuación (A.12).

$$Deviation = \sqrt{\frac{\sum_{p \in R} (g(p) - Mean)^2}{F}} \quad (A.12)$$

19. Varianza del nivel de gris: Cuadrado de la desviación estándar del nivel de gris, definida en la ecuación (A.12).
20. Mínimo nivel de gris de la región: Nivel de gris más pequeño que se encuentra en la región del defecto.
21. Máximo nivel de gris de la región: Nivel de gris más alto que se encuentra en la región el defecto.
22. Entropía: A partir del histograma de niveles de gris de la región que contiene el defecto, se calcula la entropía como (A.13) utilizando los valores definidos en (A.14).

$$Entropy = - \sum_0^{255} rel[i] * \log_2(rel[i]) \quad (A.13)$$

$rel[]$ = Histograma de frecuencias relativas de niveles de gris

i = Valor de gris de la imagen [0, 255]

k = menor valor posible de nivel de gris con $\sum_0^k rel[i] \geq 0.5$ (A.14)

23. Anisotropía: De forma análoga al cálculo de al entropía se calcula la anisotropía en la ecuación (A.15) utilizando los valores definidos en (A.14).

$$Anisotropy = \frac{\sum_0^k rel[i] * \log_2(rel[i])}{Entropy} \quad (A.15)$$

24. Entropía difusa: Medida de la aproximación de la imagen a blanco o negro considerandola un conjunto difuso.
25. Desviación plana: Cálculo de la desviación de los niveles de gris de la imagen con los niveles de gris del plano aproximado. El plano se define en la ecuación (A.16) siendo α y β los gradientes del nivel de gris en las direcciones de filas y columnas respectivamente, μ el valor medio de gris y Row y Column los índices de la fila y columna referenciada. Según este plano F , con sus parámetros α , β y μ , su centro en (r^2, c^2) y $g(r, c)$ el

valor de gris del píxel situado en la posición (r, c) , la desviación plana se define en la ecuación (A.17).

$$\alpha(r - Row) + \beta(c - Column) + \mu \quad (A.16)$$

$$Deviation = \sqrt{\frac{\sum_{(r,c) \in Regions} ((\alpha(r - r') + \beta(c - c') + \mu) - g(r, c))^2}{F}} \quad (A.17)$$

26. Perímetro difuso: Medida de las diferencias entre la pertenencia difusa de un píxel con sus vecinos. Definido en la ecuación (A.18) donde M y N son las dimensiones de la imagen y utilizando una implementación de la función de pertenencia difusa según la función "Zadeh's Standar-S function" definida en la ecuación (A.19), utilizando para dicha función los valores $a = 0$, $c = 255$ y $b = 127.5$.

$$p(X) = \sum_{m=1}^{M-1} \sum_{n=1}^{N-1} |\mu_x(x_{m,n}) - \mu_x(x_{m,n+1})| + \sum_{m=1}^{M-1} \sum_{n=1}^{N-1} |\mu_x(x_{m,n}) - \mu_x(x_{m+1,n})| \quad (A.18)$$

$$\mu_x(x) = \begin{cases} 0 & x \leq a \\ 2 \left(\frac{x-a}{c-a} \right) & a < x \leq b \\ 1 - 2 \left(\frac{x-a}{c-a} \right) & b < x \leq c \\ 1 & c \leq x \end{cases} \quad (A.19)$$

27. Momento de las filas del defecto: Momento de los niveles de gris de las filas del defecto, definido en la ecuación (A.20).

$$MRow = \frac{1}{F^2} \sum_{(r,c) \in Regions} (r - \bar{r})(g(r, c) - Mean) \quad (A.20)$$

28. Momento de las columnas del defecto: Momento de los niveles de gris de las columnas del defecto, definido en la ecuación (A.21)

$$MCol = \frac{1}{F^2} \sum_{(r,c) \in Regions} (c - \bar{c})(g(r, c) - Mean) \quad (A.21)$$

29. Gradiente del plano de aproximación en líneas: Parámetro α de al aproximación de los niveles de gris de la imagen a un plano, definido en la ecuación (A.22).

$$\alpha = \frac{MRow * F * m_{02} - m_{11} * MCol}{F} m_{20} * m_{02} - m_{11}^2 \quad (A.22)$$

30. Gradiente del plano de aproximación en columnas: Parámetro β de la aproximación de los niveles de gris de la imagen a un plano, definido en la ecuación (A.23).

$$\beta = \frac{m_{20} * MCol * F - MRow * F * m_{11}}{m_{20}m_{02} - m_{11}^2} \quad (A.23)$$

31. Parámetro Alpha de regresión a una superficie de segundo orden: Parámetro α de la aproximación mediante regresión de los valores de gris de la imagen a una superficie de segundo orden definida en la ecuación (A.24), siendo r_{center} y c_{center} las coordenadas de la intersección entre la región a tratar y la imagen completa.

$$\begin{aligned} Image(r, c) = & \alpha(r - r_{center})^2 + \\ & \beta(c - c_{center})^2 + \\ & \gamma(r - r_{center})(c - c_{center}) + \\ & \delta(r - r_{center}) + \\ & \epsilon(c - c_{center}) + \zeta \end{aligned} \quad (A.24)$$

32. Parámetro Beta de regresión a una superficie de segundo orden: Parámetro β de la superficie de segundo orden definida en la ecuación (A.24).
33. Parámetro Gamma de regresión a una superficie de segundo orden: Parámetro γ de la superficie de segundo orden definida en la ecuación (A.24).
34. Parámetro Delta de regresión a una superficie de segundo orden: Parámetro δ de la superficie de segundo orden definida en la ecuación (A.24).
35. Parámetro Epsilon de regresión a una superficie de segundo orden: Parámetro ϵ de la superficie de segundo orden definida en la ecuación (A.24).
36. Parámetro Zeta de regresión a una superficie de segundo orden: Parámetro ζ de la superficie de segundo orden definida en la ecuación (A.24).
37. M_{11} : Momento M_{11} (Momento de inercia). Siendo Z_0 y S_0 las coordenadas del centro de la región, los momentos se definen según la ecuación (A.25).

$$M_{i, j} = \sum_{(Z, S) \in R} (Z_0 - Z)^i (S_0 - S)^j \quad (A.25)$$

38. M_{20} : Momento M_{20} , definido según la ecuación (A.25).
39. M_{02} : Momento M_{02} , definido según la ecuación (A.25).

40. I_a : Eje A de inercia. Siendo h definido según la ecuación (A.26), se define el eje A de inercia en la ecuación (A.27).

$$h = \frac{M_{20} + M_{02}}{2} \quad (\text{A.26})$$

$$I_a = h + \sqrt{h^2 - M_{20} * M_{02} + M_{11}^2} \quad (\text{A.27})$$

41. I_b : Eje B de inercia. Siendo h definido según la ecuación (A.26), se define el eje B de inercia en la ecuación (A.28).

$$I_b = h - \sqrt{h^2 - M_{20} * M_{02} + M_{11}^2} \quad (\text{A.28})$$

42. Área real: Área real de la región que forma el defecto. Se define el área en la ecuación (A.29).

$$A = \sum_{(r,c) \in R} 1 \quad (\text{A.29})$$

43. Fracción del defecto por encima del umbral: Sea T un valor de umbral se define U como la cantidad de píxeles que sobrepasa ese umbral dentro de la región R . El porcentaje de la región por encima del umbral se define en la ecuación (A.30) siendo A el Área real de la región definida en (A.29).

$$f(x) = \begin{cases} 0 & x < T \\ 1 & x \geq T \end{cases}$$

$$U = \sum_{(r,c) \in R} f(x) \quad (\text{A.30})$$

$$UP = U/A$$

44. Fracción del defecto por debajo del umbral: Sea T un valor de umbral se define D como la cantidad de píxeles que tienen un valor inferior a ese umbral dentro de la región R . El porcentaje de la región por debajo del umbral se define en la ecuación (A.31) siendo A el Área real de la región definida en (A.29).

$$f(x) = \begin{cases} 0 & x > T \\ 1 & x \leq T \end{cases}$$

$$D = \sum_{(r,c) \in R} f(x) \quad (\text{A.31})$$

$$Down = D/A$$

Bibliografía

- [1] A. Ali, S. M. Shamsuddin, A. L. Ralescu, et al. Classification with class imbalance problem: a review. *Int. J. Advance Soft Compu. Appl*, 7(3):176–204, 2015.
- [2] F. G. Bulnes, D. F. García, F. J. de la Calle, R. Usamentiaga, and J. Molleda. A non-invasive technique for online defect detection on steel strip surfaces. *Journal of Nondestructive Evaluation*, 35(4):54, Sep 2016.
- [3] N. V. Chawla. *Data mining for imbalanced datasets: An overview*, pages 875–886. Springer, 2009.
- [4] L. K. Cheong, S. A. Suandi, and S. Rahman. Defects and components recognition in printed circuit boards using convolutional neural network. In *10th International Conference on Robotics, Vision, Signal Processing and Power Applications*, pages 75–81. Springer, 2019.
- [5] R. W. Conners, C. W. Mcmillin, K. Lin, and R. E. Vasquez-Espinosa. Identifying and locating surface defects in wood: Part of an automated lumber processing system. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-5(6):573–583, Nov 1983.
- [6] E. Deutschl, C. Gasser, A. Niel, and J. Werschonig. Defect detection on rail surfaces by a vision based system. In *IEEE Intelligent Vehicles Symposium, 2004*, pages 507–511, June 2004.
- [7] M. S. Dizaji and D. K. Harris. 3d inspectionnet: a deep 3d convolutional neural networks based approach for 3d defect detection on concrete columns. In *Nondestructive Characterization and Monitoring of Advanced Materials, Aerospace, Civil Infrastructure, and Transportation XIII*, volume 10971, page 109710E. International Society for Optics and Photonics, 2019.
- [8] O. Duran, K. Althofer, and L. D. Seneviratne. Automated pipe defect detection and categorization using camera/laser-based profiler and artificial neural network. *IEEE Transactions on Automation Science and Engineering*, 4:118–126, 2007.

- [9] D. F. García, I. García, R. Usamentiaga, et al. A configuration approach for convolutional neural networks used for defect detection on surfaces. In *2018 5th International Conference on Mathematics and Computers in Sciences and Industry (MCSI)*, pages 44–51. IEEE, 2018.
- [10] T. Garrett, R. Radkowski, and J. Sheaffer. Gpu-accelerated descriptor extraction process for 3d registration in augmented reality. In *2016 23rd International Conference on Pattern Recognition (ICPR)*, pages 3085–3090, Dec 2016.
- [11] Q. Gautier, A. Shearer, J. Matai, D. Richmond, P. Meng, and R. Kastner. Real-time 3d reconstruction for fpgas: A case study for evaluating the performance, area, and programmability trade-offs of the altera opencl sdk. In *2014 International Conference on Field-Programmable Technology (FPT)*, pages 326–329. IEEE, 2014.
- [12] W. S. Grant, R. C. Voorhies, and L. Itti. Finding planes in lidar point clouds for real-time registration. In *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pages 4347–4354, Nov 2013.
- [13] J. Hoła, L. Sadowski, J. Reiner, and S. Stach. Usefulness of 3d surface roughness parameters for nondestructive evaluation of pull-off adhesion of concrete layers. *Construction and Building Materials*, 84, 06 2015.
- [14] O. Ikeda and Y. Duan. Color photometric stereo for albedo and shape reconstruction. In *2008 IEEE Workshop on Applications of Computer Vision*, pages 1–6. IEEE, 2008.
- [15] F. J. delaCalle, F. D. Garcia, and R. Usamentiaga. Generation of differential topographic images for surface inspection of long products. *Journal of Real-Time Image Processing*, 01 2019.
- [16] F. Javier de la Calle Herrero, D. F. García, and R. Usamentiaga. Inspection system for rail surfaces using differential images. *IEEE Transactions on Industry Applications*, 54(5):4948–4957, Sep. 2018.
- [17] Y. Jeon, D. Choi, J. P. Yun, C. Park, and S. W. Kim. Detection of scratch defects on slab surface. In *2011 11th International Conference on Control, Automation and Systems*, pages 1274–1278, Oct 2011.
- [18] N. Kehtarnavaz and M. Gamadia. *Real-time image and video processing: from research to reality*, volume 2. Morgan & Claypool Publishers, 2006.
- [19] A. Kumar. Computer-vision-based fabric defect detection: A survey. *IEEE Transactions on Industrial Electronics*, 55(1):348–363, Jan 2008.
- [20] J. L. Rose, M. J. Avioli, P. Mudge, and R. Sanderson. Guided wave inspection potential of defects in rail. *NDT and E International*, 37:153–161, 03 2004.

- [21] J. H. Lee, H. M. Oh, and M. Y. Kim. Deep learning based 3d defect detection system using photometric stereo illumination. In *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIC)*, pages 484–487. IEEE, 2019.
- [22] H. li, Y. Qian, P. Cao, W. Yin, F. Dai, F. Hu, and Z. Yan. Calculation method of surface shape feature of rice seed based on point cloud. *Computers and Electronics in Agriculture*, 142:416–423, 11 2017.
- [23] F. M. Megahed and J. A. Camelio. Real-time fault detection in manufacturing environments using face recognition techniques. *Journal of Intelligent Manufacturing*, 23(3):393–408, Jun 2012.
- [24] J. Molleda, R. Usamentiaga, D. F. García, and F. G. Bulnes. Real-time flatness inspection of rolled products based on optical laser triangulation and three-dimensional surface reconstruction. *J. Electronic Imaging*, 19:031206, 2010.
- [25] J. Molleda, R. Usamentiaga, . F. Millara, D. F. García, P. Manso, C. M. Suárez, and I. García. A profile measurement system for rail manufacturing using multiple laser range finders. In *2015 IEEE Industry Applications Society Annual Meeting*, pages 1–8, Oct 2015.
- [26] E. N Malamas, E. Petrakis, M. Zervakis, L. Petit, and J.-D. Legat. A survey on industrial vision systems, applications and tools. *Image and Vision Computing*, 21:171–188, 02 2003.
- [27] G. of India Ministry of Railways. *Indian railway standard specification for flat bottom rails, IRST-12-2009*. 2009.
- [28] J. Salvi, S. Fernandez, T. Pribanic, and X. Llado. A state of the art in structured light patterns for surface profilometry. *Pattern recognition*, 43(8):2666–2680, 2010.
- [29] Y. Santur, M. Karaköse, and E. Akin. A new rail inspection method based on deep learning using laser cameras. In *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, pages 1–6, Sep. 2017.
- [30] S. Seçil, K. Turgut, O. Parlaktuna, and M. Özkan. 3-d visualization system for geometric parts using a laser profile sensor and an industrial robot. In *2014 IEEE International Symposium on Robotics and Manufacturing Automation (ROMA)*, pages 160–165, Dec 2014.
- [31] S. Sharifzadeh, I. Biro, N. Lohse, and P. Kinnell. Abnormality detection strategies for surface inspection using robot mounted laser scanners. *Mechatronics*, 51:59 – 74, 05 2018.

- [32] K. A. Skinner and M. Johnson-Roberson. Towards real-time underwater 3d reconstruction with plenoptic cameras. In *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 2014–2021, Oct 2016.
- [33] E. Standards. *BS EN 13674-1:2011+A1:2017 Railway applications. Track. Rail Vignole railway rails 46 kg per m and above*. 2017.
- [34] W. Wei-han. Product quality control and its applications in industry [j]. *Acta Simulata Systematica Sinica S*, 1, 2001.
- [35] R. Woodham. Photometric method for determining surface orientation from multiple images. *Optical Engineering*, 19, 01 1992.
- [36] C.-H. Wu, D.-Z. Wang, W. Ip, D. Wang, C. Chan, and H.-F. Wang. A particle swarm optimization approach for components placement inspection on printed circuit boards. *Journal of Intelligent Manufacturing*, 20:535–549, 10 2008.
- [37] L. Xin, H. Wenguang, and S. Haoliang. The theory and application of structured light photogrammetry with known angle. In *XXIst ISPRS Congress Technical Commission V July*, pages 3–11. Citeseer, 2008.
- [38] Z. Xiong, Q. Li, Q. Mao, and Q. Zou. A 3d laser profiling system for rail surface defect detection. *Sensors*, 17:1791, 08 2017.
- [39] C. Ye, S. Acikgoz, S. Pendrigh, E. Riley, and M. DeJong. Mapping deformations and inferring movements of masonry arch bridges using point cloud data. *Engineering Structures*, 173:530–545, 10 2018.