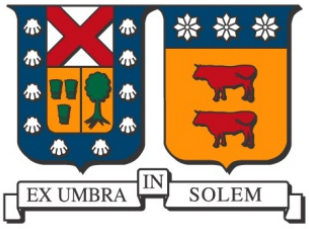
UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INFORMÁTICA
SANTIAGO - CHILE



“DESARROLLO DE UN ALGORITMO DE SEGUIMIENTO DE MÚLTIPLES OBJETOS PARA EL SISTEMA INSTALOG PARA MEJORAR EL CONTEO DE TRONCOS EN CAMIONES DE CARGA”

NICOLÁS VALENTÍN LARA LARA

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL EN INFORMÁTICA

Profesor Guía: Nicolás Rojas
Profesor Correferente: Roberto León

Mayo - 2024

RESUMEN

Resumen—

WoodTech es una empresa que proporciona soluciones tecnológicas para industrias madereras, mineras y otros sectores industriales.

Hasta el momento, WoodTech ha establecido un sistema que detecta y estima troncos a través de imágenes. Sin embargo, su sistema aún no es capaz de realizar un seguimiento coherente de los troncos de una imagen a otra, especialmente cuando estos están momentáneamente ocultos o interrumpidos debido a las características del ambiente o la configuración de los camiones y troncos. Esta ausencia de seguimiento continuo puede provocar una pérdida de información valiosa, lo que da lugar a estimaciones inexactas.

El principal objetivo de este trabajo es abordar específicamente esta problemática. Para ello, se propone la implementación y adaptación del algoritmo SORT, modificándolo para tener en cuenta las características específicas de este sistema y, así, realizar un seguimiento efectivo de los troncos a medida que se suceden las imágenes. Mediante esta estrategia de rastreo, se busca mantener un registro detallado y coherente de cada tronco, garantizando una acumulación precisa de datos y, en consecuencia, una estimación más fiable del número total de troncos transportados.

El algoritmo SORT fue evaluado en el conteo de troncos, contrastando su rendimiento con y sin seguimiento. Los resultados indicaron que, generalmente, no hubo variaciones significativas entre ambos métodos. No obstante, se lograron mejoras en eventos específicos donde el seguimiento alineó mejor el conteo con la cantidad real de troncos. A pesar de estas mejoras, la evaluación cuantitativa sugiere prudencia al interpretar estos resultados, dado que no capturan por completo la complejidad del seguimiento, especialmente cuando el algoritmo genera trayectorias erróneas. En conclusión, aunque el algoritmo fue capaz de rastrear con éxito algunos troncos no detectados inicialmente, las trayectorias incorrectas a menudo deterioraron la estimación general, lo que requiere ajustes antes de su aplicación práctica en Instalog.

Palabras Clave— Seguimiento de objetos; Visión de Computadora;

ABSTRACT

***Abstract*—**

WoodTech is a leading company providing technological solutions for timber, mining, and other industrial sectors.

Up to this point, WoodTech has established a system that detects and estimates logs through images. However, its system is still not capable of consistently tracking logs from one image to the next, especially when these are momentarily obscured or interrupted due to environmental characteristics or the configuration of the trucks and logs. This lack of continuous tracking can lead to the loss of valuable information, resulting in inaccurate estimates.

The main objective of this work is to address this specific issue. For this purpose, the implementation and adaptation of the SORT algorithm is proposed, modifying it to account for the specific characteristics of this system, and thereby achieving effective tracking of the logs as images progress. Through this tracking strategy, the aim is to maintain a detailed and consistent record of each log, ensuring an accurate accumulation of data and, consequently, a more reliable estimate of the total number of logs transported.

The SORT algorithm was evaluated for log counting, comparing its performance with and without tracking. The results showed that, generally, there were no significant variations between the two methods. However, improvements were observed in specific events where tracking more accurately aligned the count with the actual number of logs. Despite these improvements, the quantitative evaluation advises caution in interpreting these results, as they do not fully capture the complexity of tracking, especially when the algorithm produces erroneous trajectories. In conclusion, although the algorithm successfully tracked some initially undetected logs, incorrect trajectories often deteriorated the overall estimation, necessitating adjustments before practical application in Instalog.

***Keywords*—** Object tracking; Computer vision;

ÍNDICE DE CONTENIDOS

RESUMEN I

ABSTRACT II

ÍNDICE DE FIGURAS V

ÍNDICE DE TABLAS VII

CAPÍTULO 1: INTRODUCCIÓN 1

CAPÍTULO 2: DEFINICIÓN DEL PROBLEMA 2
2.1 Contexto 2
2.2 Organización 6
2.3 Situación actual 6
2.4 Objetivos 7
2.4.1 Objetivo General 7
2.4.2 Objetivos Específicos 7

CAPÍTULO 3: MARCO CONCEPTUAL 8
3.1 Definiciones y Nomenclatura 9
3.2 Visión por Computadora (Computer Vision) 9
3.3 Teorema de Bayes 12
3.4 Detección de Objetos con YOLO 12
3.5 Seguimiento de Múltiples Objetos (Multiple Object Tracking, MOT) 13
3.5.1 Ciencias de la computación 13
3.6 Cámara Estereoscópica 15
3.6.1 Aplicaciones de Visión Estereoscópica 16
3.6.2 Ventajas 17
3.6.3 Desventajas 17
3.7 Procesamiento de Imágenes 18
3.8 Filtro de Kalman 20
3.8.1 Fundamentos 21
3.8.2 Modelo del Sistema 22
3.8.3 Ruido y Covarianza 24
3.8.4 Aplicaciones de Filtro de Kalman 24
3.9 Filtro de Kalman Extendido (EKF) 25
3.9.1 Funcionamiento del EKF 25
3.9.2 Ventajas y Limitaciones 26
3.10 Filtro de Partículas (FP) 26
3.10.1 Fundamentos 26
3.10.2 Modelo del Sistema 27
3.10.3 Aplicaciones de Filtro de Partículas 28

3.11 Aplicaciones de la Visión por Computadora en la Industria Maderera 29
3.11.1 Identificación Automática de Especies de Árboles 30
3.12 Algoritmos de Seguimiento de Objetos en Tiempo Real 32
3.12.1 Simple Online and Realtime Tracking (SORT) 32
3.12.2 DeepSORT 33
3.12.3 FairMOT 34
3.12.4 MOTDT 35
3.12.5 CenterTrack 36
3.12.6 ByteTrack 36

CAPÍTULO 4: PROPUESTA DE SOLUCIÓN 39
4.1 INSTALOG en la Actualidad 39
4.2 Criterios de Selección de Algoritmos 41
4.3 Selección del Algoritmo 42
4.4 Implementación del Algoritmo 44

CAPÍTULO 5: VALIDACIÓN DE LA SOLUCIÓN 55
5.1 Escenario Experimental 55
5.2 Recopilación de Datos 55
5.3 Selección y Ajuste de Hiperparámetros 56
5.4 Análisis de Resultados 59
5.4.1 Metodología de Evaluación 60
5.4.2 Resultados Cuantitativos 60
5.4.3 Resultados Cualitativos 63
5.4.4 Integración de Análisis 80

CAPÍTULO 6: CONCLUSIONES 82
6.1 Contribución a la Industria Maderera 82
6.2 Análisis de Errores y Recomendaciones de Mejoras del Algoritmo 83
6.2.1 Error de Velocidad Inicial: 83
6.2.2 Error de Asociación: 88
6.3 Conclusiones Finales 92

ANEXOS 93

REFERENCIAS BIBLIOGRÁFICAS 99

ÍNDICE DE FIGURAS

1 Un ejemplo de la obstrucción de troncos(marcados en naranjo) 4

2 Un ejemplo de la obstrucción de troncos (marcados en naranjo) 5

3 Ejemplo de Oclusiones Parciales. Tipo (a): Oclusión Parcial, Tipo (b) Oclusión Completa 10

4 Ejemplo de Oclusion Completa 10

5 Ejemplo imágenes tomadas por cámara estereoscópica. 15

6 Diagrama de funcionamiento de cálculo de profundidad. 16

7 Comparación de contraste, Imagen izquierda tiene menor contraste a la derecha. 19

8 Comparación de brillo, Imagen izquierda tiene mayor brillo que la derecha. . . 19

9 Comparación de disminución de ruido, Imagen izquierda tiene mayor ruido que la derecha. 20

10 Ejemplo de segmentación de una imagen. 21

11 Ejemplo de tronco que aparece en un frame n, pero no en un frame n+1, manteniendo el conteo de troncos. Bounding Box azul representa un tronco detectado, mientras que un tronco rellenado en color negro representa que no fue detectado debido a una obstrucción. 41

12 Ejemplo de Detección de Caras de Tronco en INSTALOG 46

13 Ejemplo de Ajuste de Covarianzas. Azul: Detección, Verde: Predicción, Rojo: Estado Obtenido. 48

14 Ejemplo de Visualización Cualitativa Estado Inicial. 65

15 Ejemplo de Visualización Cualitativa Estado Inicial y Predicciones. 65

16 Ejemplo de Visualización Cualitativa Predicciones y Observaciones. 66

17 Ejemplo de Visualización Cualitativa Asociaciones. 66

18 Ejemplo de Visualización Cualitativa Nuevo Estado, Predicciones y Observaciones. 67

19 Ejemplo de Visualización Cualitativa Nuevo Estado, Predicciones y Observaciones. 67

20 Ejemplo de Mejora Cualitativa - Evento C1B1, Estado Inicial. 69

21 Ejemplo de Mejora Cualitativa - Evento C1B1, Estado Inicial y Predicción. 69

22 Ejemplo de Mejora Cualitativa - Evento C1B1, Predicción y Observación. 70

23 Ejemplo de Mejora Cualitativa - Evento C1B1, Asociación. 70

24 Ejemplo de Mejora Cualitativa - Evento C1B1, Nuevo Estado, Predicción y Observación. 71

25 Ejemplo de Mejora Cualitativa - Evento C1B1, Nuevo Estado. 71

26 Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Estado Inicial. 73

27 Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Estado Inicial y Predicciones. 73

28 Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Predicciones y Observaciones. 74

29 Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Asociaciones. 75

30 Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Nuevo Estado, Predicciones y Observaciones. 75

31 Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Nuevo Estado. 76

32 Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Estado Inicial. 77

33 Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Estado Inicial y Predicción. 78

34 Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Predicción y Observación. 78

35 Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Asociaciones. 79

36 Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Nuevo Estado, Predicciones y Observaciones. 80

37 Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Nuevo Estado. 80

38 Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Estado Inicial. 85

39 Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Estado Inicial y Predicciones. 86

40 Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Predicciones y Observaciones 86

41 Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Asociaciones. 87

42 Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Nuevo Estado, Predicciones y Observaciones. 87

43 Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Nuevo Estado. 88

44 Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Estado Inicial. 89

45 Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Estado Inicial y Predicciones. 90

46 Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Predicciones y Observaciones. 90

47 Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Asociaciones. 91

48 Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Nuevo Estado, Predicciones y Observaciones. 91

49 Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Nuevo Estado. 92

ÍNDICE DE TABLAS

1 Resumen de Criterios por Algoritmo - Símbolos utilizados: ✓ Cumplimiento Básico, ✓✓ Buen Rendimiento, y ✓✓✓ Rendimiento Excepcional. 44

2 Número de bancos de troncos evaluados según la precisión del conteo de troncos que entrega la detección en INSTALOG. 56

3 Resumen de Resultados Cuantitativos del Algoritmo de Seguimiento - Vida Máxima = 2 62

4 Resumen de Resultados Cuantitativos del Algoritmo de Seguimiento - Vida Máxima = 3 63

5 Resultados Análisis Cualitativo. 68

6 Resumen de la reevaluación de eventos inicialmente categorizados como “Mejor” y “Peor” en el análisis cuantitativo, comparados con los resultados del análisis cualitativo - Vida Máxima 2. 81

7 Resumen de la reevaluación de eventos inicialmente categorizados como “Mejor” y “Peor” en el análisis cuantitativo, comparados con los resultados del análisis cualitativo - Vida Máxima = 3. 81

8 Resultados Cuantitativos Detallados por Evento - Vida Máxima = 2 - Parte 1 . . 93

9 Resultados Cuantitativos Detallados por Evento - Vida Máxima = 2 - Parte 2 . . 94

10 Resultados Cuantitativos Detallados por Evento - Vida Máxima = 2 - Parte 3 . . 95

11 Resultados Cuantitativos Detallados por Evento - Vida Máxima = 3 - Parte 1 . . 96

12 Resultados Cuantitativos Detallados por Evento - Vida Máxima = 3 - Parte 2 . . 97

13 Resultados Cuantitativos Detallados por Evento - Vida Máxima = 3 - Parte 3 . . 98

CAPÍTULO 1
INTRODUCCIÓN

La industria maderera juega un rol crucial en la economía global, alimentando sectores desde la construcción hasta la producción de papel. Sin embargo, este sector tradicional enfrenta desafíos modernos, particularmente en la logística y el conteo de troncos, procesos que aún dependen en gran medida de métodos manuales o semi-automatizados. En este contexto, la presente memoria aborda un desafío tecnológico específico: la optimización del sistema Instalog de WoodTech para el conteo preciso de troncos a través de tecnologías de visión por computadora.

La investigación surge de una necesidad identificada dentro de WoodTech, una empresa vanguardista en soluciones tecnológicas para la industria maderera, que busca mejorar su sistema Instalog. Este sistema, destinado al conteo y estimación de troncos en camiones de carga, presenta limitaciones en su capacidad para realizar un seguimiento coherente de los troncos a través de imágenes secuenciales, especialmente en situaciones de obstrucciones visuales.

El trabajo se estructura en torno a varios ejes centrales: un análisis detallado de las problemáticas específicas del conteo y seguimiento de troncos, una revisión de las metodologías de seguimiento de múltiples objetos aplicables, y el desarrollo e implementación de un algoritmo adaptado a las necesidades del sistema Instalog. A través de este enfoque, la memoria busca no solo superar las limitaciones identificadas sino también contribuir a la transformación digital en curso en la industria maderera.

Los capítulos que componen este trabajo se despliegan de la siguiente manera: tras una introducción que establece el escenario y justifica la investigación, el Capítulo 2 delinea la definición del problema, resaltando el contexto de la industria maderera y los desafíos específicos de WoodTech. El Capítulo 3 introduce el marco conceptual, ofreciendo una base teórica sobre visión por computadora, seguimiento de múltiples objetos y las tecnologías implicadas. En el Capítulo 4 se presenta la propuesta de solución, detallando la selección, adaptación e implementación del algoritmo elegido. Finalmente, el Capítulo 5 valida la solución propuesta, evaluando su desempeño y destacando tanto los logros como las áreas de mejora.

Esta memoria representa un esfuerzo por cerrar la brecha entre las necesidades operativas de la industria maderera y las soluciones tecnológicas avanzadas, demostrando cómo la visión por computadora puede contribuir significativamente a optimizar procesos tradicionales. A través de este trabajo, se espera no solo resolver un problema técnico específico sino también abrir caminos hacia futuras innovaciones en el sector.

CAPÍTULO 2
DEFINICIÓN DEL PROBLEMA

2.1. Contexto

La industria forestal-maderera se dedica a la explotación, transformación y comercialización de productos derivados de los bosques. Esta industria comprende desde la extracción de madera en bruto hasta la producción y venta de productos acabados, como muebles, papel y materiales de construcción. Su impacto económico es significativo, y su existencia ha sido fundamental para el desarrollo de muchas civilizaciones a lo largo de la historia [1].

La industria maderera ha experimentado una expansión robusta y sostenida a nivel mundial. Esta expansión ha sido alimentada por una creciente demanda doméstica en diferentes regiones, así como por un floreciente comercio internacional. El panorama global de la industria forestal en 2019 estuvo dominado por ciertos actores clave en términos de producción y consumo. Los productos forestales pueden segmentarse en varias categorías, y las naciones dominantes en cada segmento varían [2].

En el segmento de combustible de madera, India lideró tanto en consumo como en producción con el 16 % mundial, seguida de China y Brasil. Para la madera en rollo industrial, Estados Unidos encabezó el consumo con un 19 % y la producción con un 18 %. Brasil, aunque se destacó en varias categorías, fue especialmente prominente en el carbón vegetal de madera, liderando el consumo y la producción con un 12 %.

Los pellets de madera y otros productos aglomerados tuvieron al Reino Unido como el principal consumidor con un 21 %, mientras que Estados Unidos lideró la producción con un 19 %. China fue particularmente dominante en el segmento de madera aserrada y tableros a base de madera, representando el 27 % y el 37 % del consumo global respectivamente, y el 18 % y 40 % de la producción.

El panorama de la pulpa para papel estuvo encabezado por Estados Unidos en términos de consumo y producción con un 26 %. Mientras que el consumo y producción de papel recuperado y papel y cartón estuvo dominado por China, con Estados Unidos también desempeñando un papel significativo.

En términos de comercio internacional, el mercado maderero ha visto un crecimiento exponencial, con un flujo continuo de exportaciones e importaciones entre las principales regiones productoras y consumidoras [3].

En el caso de Chile, el país se ha establecido como uno de los principales productores y exportadores de madera y productos derivados en América Latina. La industria maderera chilena ha experimentado un auge en las últimas décadas, gracias a la combinación de vastos recur-

sos forestales, políticas gubernamentales de apoyo y la entrada de inversiones extranjeras. Aunque el mercado interno chileno también ha crecido, la exportación sigue siendo un pilar fundamental para la industria, con destinos que abarcan desde países vecinos hasta mercados en Asia y Europa [4].

A medida que crece la demanda, también lo hace la competencia, lo que lleva a las empresas a realizar optimizaciones en cada eslabón de su cadena de suministro. Mientras otras industrias han avanzado rápidamente hacia la automatización y la digitalización, ciertas operaciones dentro de la industria forestal, como la estimación del volumen de troncos, la clasificación según el tipo y calidad de madera, y la inspección de la salud de los árboles, han permanecido sorprendentemente arraigadas en métodos manuales [5]. Estos procesos, basados en habilidades humanas, presentan desventajas significativas. Las Figuras 1 y 2 ilustran de manera clara una de estas situaciones: un camión cargado de troncos capturado en una imagen, donde se aprecia la dificultad de contar y estimar el volumen de troncos debido a la obstrucción de ellos. Esta obstrucción no solo dificulta la visibilidad, sino que también puede conducir a inexactitudes en la estimación manual.

La dependencia actual de la evaluación manual para estas tareas claves no solo es anacrónica, sino que viene acompañada de una serie de desventajas intrínsecas que limitan la capacidad de la industria para mantenerse al día con los estándares de producción y sostenibilidad contemporáneos. Entre estas desventajas, se destacan las siguientes:

- **Variabilidad:** La medición y conteo manual de troncos pueden variar ampliamente dependiendo de la habilidad y experiencia del operador. Esta variabilidad puede llevar a incoherencias en las mediciones, donde dos operadores podrían proporcionar estimaciones diferentes para el mismo lote de troncos.
- **Falta de Precisión:** Los métodos manuales pueden no ser tan precisos como los métodos automatizados, lo que podría resultar en una subestimación o sobreestimación del volumen de madera, afectando directamente la rentabilidad y la planificación.
- **Lentitud y Eficiencia:** El ritmo de trabajo manual no suele coincidir con las demandas de la industria moderna. Esto puede llevar a cuellos de botella en el proceso, ralentizando la cadena de suministro y aumentando los costos operativos.
- **Fatiga y Error Humano:** La naturaleza repetitiva de ciertas tareas, como el conteo, puede llevar a la fatiga, aumentando el riesgo de errores que, a su vez, pueden tener implicaciones costosas para las empresas.

Las consecuencias de estas desventajas van más allá de lo operativo. Inexactitudes pueden causar desacuerdos comerciales, desconfianza entre partes, y pérdidas económicas. De hecho, una planificación basada en datos erróneos puede llevar a ineficiencias en la gestión de recursos y producción [6].



Figura 1: Un ejemplo de la obstrucción de troncos(marcados en naranjo)

No obstante, con el avance tecnológico y creación de nuevas herramientas de hardware, la inteligencia artificial y la visión por computadora emergen como soluciones prometedoras para automatizar y mejorar estos procesos.

Estas innovaciones no solo potencian la eficiencia directa, sino que también tienen un impacto cascada en las operaciones subsiguientes, desde la planificación logística hasta la determinación de rentabilidad, basándose en datos precisos. Sin embargo, a pesar de estos avances, la implementación de tecnologías emergentes en la industria forestal no está exenta de desafíos. La precisión y uniformidad de las mediciones, aunque mejoradas con herramientas digitales, todavía enfrentan retos específicos:

- **Variabilidad de condiciones:** Los bosques y zonas de tala no siempre ofrecen condiciones estandarizadas. Factores como la luz ambiental, el clima o la densidad del follaje pueden afectar la capacidad de los sensores y cámaras para obtener lecturas precisas.



Figura 2: Un ejemplo de la obstrucción de troncos (marcados en naranjo)

- **Complejidad del material:** La madera, al ser un material natural, presenta variaciones en cuanto a tamaño, forma, y características superficiales. Esto puede dificultar la calibración de herramientas automatizadas para lograr una precisión constante.
- **Integración tecnológica:** Fusionar nuevas tecnologías con sistemas existentes en las operaciones forestales puede ser complejo. La adaptación y el entrenamiento necesarios para que el personal se familiarice con herramientas avanzadas pueden requerir tiempo y recursos.
- **Costo y mantenimiento:** Aunque la inversión inicial en tecnología puede resultar en ahorros a largo plazo, las empresas deben considerar los costos de mantenimiento, actualizaciones y posibles reparaciones de equipos avanzados.

Estos desafíos subrayan la importancia de una adopción cuidadosa y bien planificada de la tecnología en la industria maderera, así como la necesidad de investigación y desarrollo con-

tinuos para adaptar y mejorar estas herramientas para satisfacer las demandas específicas del sector.

2.2. Organización

WOODTECH se ha consolidado como una vanguardista en el sector maderero. Fundada en Chile, ha expandido su presencia no solo a Latinoamérica, sino que también ofrece sus soluciones avanzadas a mercados tan diversos como Estados Unidos, Alemania, Australia, y recientemente Indonesia. La firma se ha caracterizado por su fuerte compromiso con la investigación y el desarrollo, reinvirtiendo entre el 15 % y el 20 % de sus ingresos en proyectos que buscan innovar y enfrentar desafíos presentes en la industria maderera y en sectores relacionados [7].

Dentro de su gama de productos, WOODTECH ha destacado por el sistema LOGMETER, una herramienta que, mediante el uso de cámaras láser, ofrece mediciones precisas del volumen y características de troncos de madera transportados en camiones [8]. Sin embargo, reconociendo la diversidad de necesidades de sus clientes y la demanda por soluciones más accesibles, la firma tomó la iniciativa de desarrollar INSTALOG. Este producto emergente busca proporcionar un sistema más sencillo pero eficiente para contar y medir troncos, utilizando cámaras estereoscópicas. Es en este producto, INSTALOG, en el cual este trabajo estará enfocado.

La capacidad de WOODTECH para adaptarse y responder a las demandas cambiantes del mercado la posiciona no solo como una empresa líder en su sector, sino también como una fuente de innovación y adaptabilidad. El compromiso continuo de la empresa con la mejora y adaptación tecnológica refleja su misión de ofrecer soluciones que combinen precisión con rentabilidad, buscando siempre la satisfacción y el éxito de sus clientes.

2.3. Situación actual

INSTALOG, en su fase de desarrollo dentro de WOODTECH, se está posicionando como una herramienta vanguardista para el conteo y estimación del diámetro de troncos en camiones. Durante sus pruebas preliminares, el sistema ha demostrado ser eficaz en la detección de troncos y en la estimación del diámetro de sus caras cuando un camión, con su carga ya establecida, pasa directamente frente a la cámara.

No obstante, presenta desafíos significativos en ciertos contextos. Un desafío emergente es su capacidad para gestionar obstrucciones en las imágenes capturadas. Estas obstrucciones, que pueden ser causadas por otros troncos, equipos u otros objetos presentes en la estructura del camión o en su entorno inmediato, pueden dificultar la identificación precisa de cada tronco individual. Si un tronco es detectado en una imagen pero se obstruye en una subsi-

guiente, ello conduce a inconsistencias en el conteo y en la estimación de los diámetros.

A pesar de que INSTALOG aún no ha sido incorporado al catálogo oficial de productos de WOODTECH, su potencial es innegable. Los resultados alentadores obtenidos en las pruebas iniciales sugieren que, tras la refinación y superación de los desafíos actuales, podría transformar significativamente el proceso de conteo y medición en la industria maderera.

Ante estos desafíos, se vislumbra la necesidad de una solución avanzada que pueda mantener y utilizar la información de los troncos detectados de manera consistente, incluso frente a posibles obstrucciones. Es así que se plantea la idea de implementar un algoritmo de seguimiento de múltiples objetos en una secuencia de imágenes, con el objetivo de mejorar la precisión del conteo y estimación de diámetros, algo que se desarrollará en detalle en las secciones subsiguientes.

2.4. Objetivos

2.4.1. Objetivo General

Desarrollar un algoritmo de seguimiento de múltiples objetos para el sistema INSTALOG para mejorar el conteo de troncos en camiones de carga.

2.4.2. Objetivos Específicos

- Analizar y documentar las limitaciones actuales del sistema INSTALOG en relación al conteo de troncos, en particular en contextos con obstrucciones visuales.
- Investigar técnicas y metodologías existentes de seguimiento de objetos que puedan ser adaptadas al entorno específico de detección de troncos en INSTALOG.
- Diseñar e implementar un algoritmo de seguimiento de múltiples objetos que asegure una detección y conteo de troncos a lo largo de una secuencia de imágenes.
- Evaluar el rendimiento del algoritmo propuesto en diferentes escenarios y comparar su eficacia con el enfoque actual de INSTALOG.

CAPÍTULO 3
MARCO CONCEPTUAL

La industria forestal se encuentra en medio de una transformación tecnológica, persiguiendo constantemente herramientas y técnicas que mejoren y optimicen sus operaciones. Dentro de este vasto ámbito, uno de los desafíos recurrentes es la exactitud en el conteo de troncos. Esta tarea, aunque pueda parecer sencilla a simple vista, tiene enormes implicancias en la gestión de recursos, la planificación logística y, evidentemente, en las transacciones comerciales. Es aquí donde INSTALOG emerge como una prometedora solución propuesta por WOODTECH, valiéndose de la visión por computadora como piedra angular.

La visión por computadora es una rama interdisciplinaria que se apoya en la intersección entre la óptica y la informática, enfocada en otorgar a las máquinas la habilidad de interpretar y tomar decisiones basadas en imágenes y vídeos. Es el nexo perfecto entre la percepción visual y el entendimiento computacional. Esta es la razón por la que su aplicación en la industria forestal, y en especial en INSTALOG, resulta ser tan crucial.

El seguimiento de múltiples objetos (MOT) se presenta como otro concepto esencial. En la industria, no es suficiente con identificar un tronco; se necesita seguir su trayectoria, garantizar su correcto registro y evitar duplicidades. Esto se traduce en operaciones más fluidas y datos más confiables para la empresa.

Las cámaras estereoscópicas son una pieza central de esta ecuación. A través de la simulación de la visión humana binocular, estas cámaras permiten calcular la profundidad y ofrecer una percepción tridimensional del entorno. Su importancia radica en la precisión que otorgan, siendo una herramienta indispensable para INSTALOG.

El Filtro de Kalman, su variante extendida y el Filtro de Partículas, son herramientas que permiten predecir y corregir errores en tiempo real, brindando a INSTALOG una ventaja en términos de precisión y eficacia.

Finalmente están los distintos tipos de algoritmos existentes para realizar seguimiento de múltiples objetos, teniendo cada uno sus ventajas y desventajas que serán claves para decidir cual de ellos implementar en el sistema INSTALOG.

En este capítulo se presentará un examen detallado de las tecnologías y metodologías clave que sustentan el sistema INSTALOG, incluyendo la visión por computadora, el seguimiento de múltiples objetos (MOT, Multi-Object Tracking), y el uso de cámaras estereoscópicas. Se discutirán sus principios fundamentales, sus aplicaciones relevantes para el proyecto, y cómo estos elementos se integran para superar los desafíos del conteo y seguimiento preciso de troncos. Este análisis no solo mostrará la relevancia de estas tecnologías en el contexto de la industria forestal, sino que también establecerá la base teórica para las innovaciones propuestas en los capítulos subsiguientes, enfocándose en la mejora de la precisión y eficiencia

del conteo de troncos en camiones de carga.

3.1. Definiciones y Nomenclatura

Dentro del contexto de este estudio, es crucial definir claramente los términos y la nomenclatura utilizada para describir los elementos clave del sistema de seguimiento. Esto asegura una comprensión uniforme y evita ambigüedades en la interpretación de los datos y resultados.

- **Camión:** Se refiere a la unidad completa de transporte que puede llevar uno o más bancos de madera. Cada camión se considera una entidad única para fines de seguimiento y análisis global.
- **Banco de Madera:** Representa cada grupo individual de troncos dentro de un camión, identificado y contado por el algoritmo como una unidad separada. Cada banco es considerado un objeto de seguimiento individual en el análisis.

Para la identificación clara y el seguimiento de eventos, se utiliza la siguiente nomenclatura:

- **Evento CnBm:** Donde “Cn” representa el camión número “n” y “Bm” representa el banco de madera número “m” dentro de dicho camión. Por ejemplo, el evento C1B2 se refiere al segundo banco de madera del primer camión.

Esta nomenclatura se utilizará a lo largo del estudio para especificar si se está discutiendo un evento relacionado con un banco específico de madera o con el camión en su totalidad.

3.2. Visión por Computadora (Computer Vision)

La visión por computadora es un subcampo interdisciplinario de la ciencia de la computación que busca imitar y mejorar la capacidad del sistema visual humano mediante máquinas y computadoras [9]. Su objetivo es hacer que las máquinas puedan interpretar y actuar basándose en la información que obtienen de las imágenes digitales o video [10].

En esencia, es el proceso de convertir imágenes en datos comprensibles para la máquina. La visión por computadora se emplea para resolver una variedad de problemas fundamentales en el análisis de imágenes y videos, entre los cuales se destacan la clasificación, la localización y detección de objetos, y la segmentación de imágenes. Cada uno de estos problemas aborda una faceta única de cómo las máquinas pueden interpretar el contenido visual. Por ejemplo, la clasificación se centra en identificar qué objetos están presentes en una imagen, mientras

que la localización y detección avanzan un paso más allá, determinando la presencia y el posicionamiento exacto de estos objetos dentro de la imagen. La segmentación, por otro lado, implica dividir una imagen en partes o segmentos, lo que permite un análisis detallado de sus componentes individuales.

Un desafío particular dentro de estos problemas es el de la oclusión, donde un objeto puede estar parcial o totalmente oculto por otro en la escena (Ver Figuras 3 y 4). Este fenómeno complica significativamente la tarea de seguimiento y reconocimiento de objetos, ya que la visibilidad completa de estos se ve comprometida.

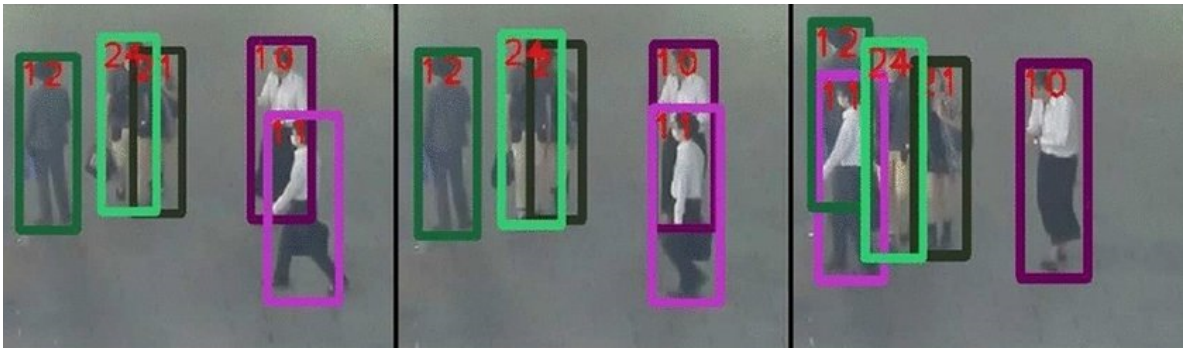


Figura 3: Ejemplo de Oclusiones Parciales. Tipo (a): Oclusión Parcial, Tipo (b) Oclusión Completa
Fuente: Online multi-object tracking with pedestrian re-identification and occlusion processing [11].



Figura 4: Ejemplo de Oclusion Completa
Fuente: Online multi-object tracking with pedestrian re-identification and occlusion processing [11].

En este contexto, el Seguimiento de un Solo Objeto (Single Object Tracking, SOT) y el Seguimiento de Múltiples Objetos (Multi Object Tracking, MOT) emergen como soluciones cruciales. SOT se enfoca en la localización y seguimiento de un único objeto a lo largo del tiempo dentro de un video, mientras que MOT amplía este concepto al seguimiento simultáneo de varios objetos. MOT es especialmente relevante en entornos dinámicos y complejos, donde múltiples objetos interactúan o se cruzan, presentando desafíos adicionales como el cambio

de apariencia, la oclusión mutua, y la necesidad de mantener identidades consistentes a lo largo del tiempo.

El proceso de rastrear múltiples objetos simultáneamente ha sido de interés en diversos campos de estudio. Esencialmente, se refiere a la capacidad de identificar, seguir y mantener una coherencia en el reconocimiento de varios objetos a medida que se mueven o cambian en un espacio o marco de referencia determinado [12]. Esta habilidad, ya sea natural en humanos o artificial en sistemas computacionales, es crucial en diversas aplicaciones, desde estudios cognitivos hasta soluciones de visión por computadora en la industria.

Las técnicas de visión por computadora se basan en teorías de procesamiento de imágenes, inteligencia artificial y aprendizaje automático. Esta disciplina se extiende a múltiples aplicaciones prácticas, cada una con sus propios retos y soluciones innovadoras, como por ejemplo:

- **Identificación Facial:** El algoritmo Viola-Jones Object Detection Framework [13], ha sido fundamental en el campo de la detección de objetos, con un impacto significativo en la identificación facial. Este método revolucionó la detección en tiempo real, ofreciendo un balance entre velocidad y precisión, demostrando su eficacia en aplicaciones de seguridad y sistemas de vigilancia.
- **Navegación de Vehículos Autónomos:** El vehículo autónomo “Stanley” [14], es un caso de éxito donde la visión por computadora converge con algoritmos de aprendizaje de máquina para lograr una autonomía efectiva. Integrando datos de sensores y procesamiento visual, “Stanley” pudo navegar con precisión por terrenos no estructurados, marcando un hito en la historia de la conducción autónoma.
- **Seguimiento y Reconocimiento de Múltiples Objetos en Movimiento:** El algoritmo de optimización de los k-caminos más cortos es una técnica avanzada para el seguimiento de múltiples objetos [15]. Este enfoque integra todas las trayectorias en una secuencia de video, superando las oclusiones y garantizando la precisión del seguimiento. Su eficiencia computacional lo hace adecuado para entornos dinámicos, y su versatilidad lo convierte en una herramienta valiosa para aplicaciones desde la seguridad urbana hasta el análisis deportivo.

En el contexto del proyecto INSTALOG, la visión por computadora se erige como pilar fundamental para abordar el problema central de la memoria: el conteo y seguimiento de troncos. La capacidad de las máquinas de interpretar y actuar basándose en información visual es crucial para desarrollar soluciones eficientes y precisas en entornos industriales donde se requiere visualizar e identificar objetos. El empleo de técnicas de procesamiento de imágenes, inteligencia artificial y aprendizaje automático, permite no solo la identificación y conteo de troncos de manera autónoma y en tiempo real, sino también el reconocimiento de patrones y la adaptación a diferentes condiciones y tipos de madera.

3.3. Teorema de Bayes

El Teorema de Bayes es una forma de entender cómo se puede actualizar la probabilidad a priori de una hipótesis, dada nueva evidencia. Es un principio crucial en la inferencia estadística bayesiana, que es una forma de inferencia estadística en la que se actualiza la probabilidad de una hipótesis a medida que se dispone de más evidencia. Este teorema está definido por el modelo matemático (1).

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)} \tag{1}$$

- $\boldsymbol{P(A)}$ **:** La Probabilidad a Priori, es la probabilidad original o inicial de la hipótesis antes de observar la nueva evidencia. Representa el conocimiento o creencias previas.
- $\boldsymbol{P(B|A)}$ **:** La Verosimilitud, indica la probabilidad de observar la nueva evidencia, dado que la hipótesis es cierta.
- $\boldsymbol{P(B)}$ **:** La Probabilidad Marginal de la Evidencia, también conocida como la constante de normalización, es la probabilidad total de la evidencia, teniendo en cuenta todas las hipótesis posibles.
- $\boldsymbol{P(A|B)}$ **:** La Probabilidad Posterior, es la probabilidad revisada de la hipótesis después de tener en cuenta la nueva evidencia. Representa el grado de creencia actualizado en la hipótesis después de considerar los nuevos datos.

Es relevante conocer los fundamentos del Teorema de Bayes ya que es la base de varios algoritmos de seguimiento de objetos, tales como los Filtros de Kalman y Filtros de Partículas, de los cuales se hablará más adelante.

3.4. Detección de Objetos con YOLO

El framework “You Only Look Once” (YOLO) [16] ha revolucionado el campo de la visión por computadora mediante su enfoque único para la detección de objetos en tiempo real. A diferencia de métodos previos, YOLO unifica la detección y clasificación de objetos en un solo paso, mejorando significativamente la velocidad sin sacrificar precisión. Desde su primera versión, YOLO ha experimentado varias iteraciones, cada una dirigida a mejorar aspectos específicos como la precisión en la detección, la velocidad de procesamiento y la capacidad para identificar objetos pequeños.

Al momento de implementar Instalog, YOLOv3 representaba la vanguardia en la detección de objetos en tiempo real. Su elección fue motivada por varias razones clave:

- **Eficiencia:** YOLOv3 demostró un equilibrio óptimo entre velocidad y precisión, crucial para el procesamiento en tiempo real de imágenes de troncos.
- **Robustez:** La arquitectura de YOLOv3, con mejoras en la predicción de cajas delimitadoras y en la capacidad de detección de objetos de diferentes escalas, lo hacía ideal para la variabilidad de tamaños y formas encontrados en los troncos de madera.
- **Estado del Arte:** En el momento de desarrollo de Instalog, YOLOv3 era la versión más reciente y avanzada disponible, ofreciendo las mejores capacidades de detección posibles para el proyecto.

La evolución de YOLO, desde su versión 3 hasta la actual YOLOv8, resalta la rápida innovación en el campo de la visión por computadora. Aunque Instalog se desarrolló utilizando YOLOv3, el proyecto reconoce la importancia de la adaptabilidad tecnológica. Futuras versiones de Instalog podrían beneficiarse de implementar versiones más recientes de YOLO, aprovechando mejoras en la detección, velocidad y eficiencia energética para optimizar aún más el proceso de conteo y clasificación de troncos.

3.5. Seguimiento de Múltiples Objetos (Multiple Object Tracking, MOT)

El seguimiento de múltiples objetos es una tarea cognitiva que ha sido ampliamente estudiada en el campo de la psicología experimental para entender cómo los humanos son capaces de mantener atención selectiva sobre varios objetos en movimiento en un campo visual lleno de distracciones. Estas investigaciones han revelado que los humanos tienen una capacidad limitada para rastrear múltiples objetos en movimiento y que esta capacidad puede verse afectada por factores como la velocidad de los objetos, la densidad del campo visual y la duración del seguimiento. La habilidad para realizar MOT ha sido relacionada con otras funciones cognitivas, como la memoria de trabajo y la atención selectiva [17].

3.5.1. Ciencias de la computación

En el ámbito computacional, el seguimiento de múltiples objetos se refiere al proceso automático de detectar y rastrear la posición y trayectoria de varios objetos a lo largo de una secuencia de imágenes o videos. Este desafío involucra no solo la detección de objetos individuales en cada frame, sino también la preservación de sus identidades a lo largo del tiempo, incluso cuando dichos objetos se ocultan parcial o totalmente entre sí, o bien, entran y salen del campo visual.

Para ello, se emplean técnicas avanzadas de procesamiento de imágenes y algoritmos basados en aprendizaje automático que aprenden y predicen patrones de movimiento y apariencia de los objetos. En aplicaciones prácticas, el MOT ha demostrado su valor en diversas situaciones. Por ejemplo:

- **Monitoreo de tráfico de autos:** En [18] se abordan los desafíos en el monitoreo del tráfico vehicular utilizando sistemas de visión por computadora. Propone una solución en tiempo real que integra detección basada en aprendizaje profundo, seguimiento mediante Filtros de Correlación Discriminativa y Filtros de Kalman, y asociación de datos a través del algoritmo húngaro. Este enfoque permite el seguimiento robusto y fiable de más de cuatrocientos vehículos simultáneamente, incluso en situaciones de oclusiones totales, siendo evaluado efectivamente en escenarios de la vida real con más de dos mil vehículos. Además, el sistema se aplica para detectar anomalías y analizar entradas y salidas en rotondas.

- **Sistema de seguridad y vigilancia:** En [19] se presenta un marco de trabajo innovador en el ámbito de la videovigilancia y conteo automático visual de objetos, destacando sus aplicaciones en entornos domésticos y empresariales, como son la seguridad y la gestión de puntos de acceso. En el documento, se propone un sistema eficiente y adaptable a las necesidades de los consumidores, con la facilidad de utilizar equipos estándar, una instalación y configuración sencilla, y operación en condiciones no supervisadas. El marco introduce un modelo Bayesiano de seguimiento, capaz de manejar distribuciones multimodales y resistente a detecciones erróneas, distorsionadas y ausentes, sin la necesidad de calcular explícitamente la asociación entre los objetos rastreados y las detecciones.

- **Observación de vida silvestre:** En [20] se explora el desarrollo de un marco para la observación televisual de Artiodactyla (un orden de mamíferos que incluye camellos y cerdos) en entornos naturales, utilizando técnicas avanzadas de inteligencia artificial para facilitar la protección ecológica. Este trabajo se centra en el seguimiento y la reidentificación de múltiples objetivos en tiempo real, utilizando la extracción y coincidencia de características en tres direcciones y filtros de Kalman para confirmar la presencia del objetivo, integrando detectores y rastreadores para solucionar problemas de detección discontinua en entornos de campo. Los resultados del estudio demuestran la viabilidad y efectividad del marco propuesto para la observación a largo plazo de animales salvajes sin intervención en su hábitat natural, contribuyendo así a los esfuerzos de conservación ecológica.

- **Seguimiento en eventos deportivos:** En [21] se aborda el desarrollo de un sistema para construir una cancha de baloncesto inteligente mediante la implementación de técnicas de seguimiento de múltiples objetos (MOT) especializadas en monitorear a los jugadores durante los juegos de baloncesto. El estudio enfatiza la necesidad de un sistema de seguimiento que sea no solo preciso sino también operativamente eficiente, tendiendo hacia una capacidad de tiempo real, para adecuarse a los escenarios dinámicos del baloncesto.

- **Monitoreo Automatizado de Granjas de Mejillones:** En [22] se propone una innovadora metodología basada en técnicas de visión por computadora para la monitorización automática de boyas de mejillones en las granjas de mejillones de Nueva Zelanda. Tradicionalmente, los granjeros monitorean estas boyas mediante viajes en barco, lo que

resulta laborioso y consume tiempo. Sin embargo, esta nueva técnica promete transformar la industria, ofreciendo una solución más eficiente y menos intensiva en mano de obra.

En el contexto de este trabajo, el MOT es esencial para mantener una contabilidad precisa de objetos en escenas complejas, como un camión lleno de troncos de madera en movimiento [23].

3.6. Cámara Estereoscópica

Una cámara estereoscópica, a menudo referida simplemente como “cámara estéreo”, es un tipo de sistema de cámara diseñado para capturar o grabar imágenes desde dos perspectivas ligeramente diferentes simultáneamente. Esta configuración busca emular la disposición binocular de los ojos humanos, que están separados por una distancia determinada y ofrecen dos vistas ligeramente diferentes del mundo [24].



Figura 5: Ejemplo imágenes tomadas por cámara estereoscópica.
Fuente: Visión Artificial Para Todos [25]

El cálculo de profundidad en la estereoscopía se basa fundamentalmente en la triangulación. Para comprenderlo miremos la Figura 6, en donde hay dos cámaras separadas por una distancia conocida **d**. Ambas cámaras enfocan un punto en el espacio. La línea que conecta una cámara y el punto de interés forma un ángulo con la línea base (la línea que conecta las dos cámaras). La diferencia en los ángulos y la distancia **d** entre las cámaras proporciona suficiente información para determinar la posición del punto en un espacio tridimensional mediante triangulación.

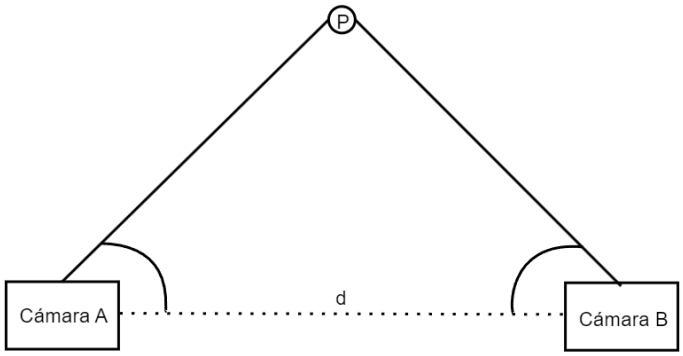


Figura 6: Diagrama de funcionamiento de cálculo de profundidad.
Fuente: Elaboración Propia.

Aquí es donde entra en juego la disparidad. La disparidad es básicamente la diferencia en la posición horizontal del punto de interés en las dos imágenes capturadas por las cámaras estereoscópicas. A mayor disparidad, el objeto está más cerca de las cámaras y viceversa. Por lo tanto, al medir la disparidad, podemos calcular la distancia de cada punto en la imagen a las cámaras, proporcionando así un mapa de profundidad de la escena.

3.6.1. Aplicaciones de Visión Estereoscópica

La cámara estereoscópica es ampliamente utilizada en aplicaciones donde la percepción de la profundidad es crucial. A continuación, se detallan algunas de estas aplicaciones:

- **Fotografía 3D:** Utiliza cámaras estereoscópicas para capturar imágenes desde dos perspectivas ligeramente diferentes, permitiendo recrear una sensación de profundidad al ser visualizadas. Esta tecnología ha sido ampliamente empleada en el cine y la fotografía para brindar una experiencia más inmersiva al espectador [26].
- **Realidad Virtual:** Emplea cámaras estereoscópicas para crear entornos tridimensionales inmersivos. Capturando información de profundidad, permiten a los sistemas de RV representar espacios con una percepción espacial realista, mejorando así la experiencia del usuario [27].
- **Mapeo Topográfico:** En esta aplicación, cámaras estereoscópicas montadas en aeronaves o satélites adquieren imágenes del terreno desde diferentes ángulos. Posteriormente, estas imágenes son procesadas para calcular la altitud de cada punto en ellas, resultando en mapas detallados del relieve terrestre [28].
- **Robótica:** Las cámaras estereoscópicas en robótica proveen a los robots de una percepción tridimensional de su entorno, siendo vital para tareas como navegación autónoma, reconocimiento de objetos y manipulación precisa [29].

En el contexto de este trabajo, las cámaras estereoscópicas permiten obtener información sobre la posición, orientación, dimensiones y velocidad de los troncos de madera en un camión al pasar frente a ellas utilizando la información de profundidad de imagen a imagen.

3.6.2. Ventajas

Una de las principales ventajas de las cámaras estereoscópicas es que ofrecen una solución pasiva para la obtención de información de profundidad. En el contexto de la visión por computadora y la percepción sensorial, una solución pasiva se refiere a sistemas que obtienen información utilizando solamente la luz o las señales ambientales que ya existen en la escena, como la fotogrametría tradicional, donde se estima la geometría de una escena utilizando imágenes desde diferentes puntos de vista [30]. En otras palabras, no necesitan introducir ninguna señal o energía adicional para capturar datos sobre el entorno.

Esto contrasta con los sistemas que dependen de la emisión activa de señales o radiación para obtener información. Por ejemplo, algunos dispositivos emiten activamente señales, como luz infrarroja o radiación láser, para sondear el entorno y luego detectan el reflejo o la respuesta a esa señal. Un buen ejemplo de esto es el sistema Light Detection and Ranging (LIDAR), que utiliza pulsos láser para medir distancias [31]. Mide el tiempo que tarda un pulso láser en viajar hasta un objeto y regresar, determinando así la distancia a ese objeto. Si bien LIDAR es extremadamente preciso y tiene muchas aplicaciones, su naturaleza activa puede hacerlo más complejo y potencialmente intrusivo en ciertos escenarios.

Por lo tanto, las cámaras estereoscópicas son ideales para situaciones en las que se requiere una solución de visión 3D simple, eficiente y menos intrusiva, evitando la necesidad de introducir energía o señales adicionales en la escena.

3.6.3. Desventajas

Si bien las cámaras estereoscópicas ofrecen beneficios notables, también presentan ciertas desventajas y limitaciones. Primero, la precisión de la profundidad que se puede lograr depende en gran medida de la distancia entre las dos cámaras. Una distancia más grande puede mejorar la precisión, pero también puede aumentar el riesgo de áreas sin solapamiento, especialmente en escenas cercanas.

Otra desventaja importante es el problema de correspondencia. Determinar qué puntos en una imagen corresponden a los mismos puntos en la segunda imagen puede ser un reto, especialmente en escenas con texturas repetidas o en aquellas que carecen de textura [32]. Además, factores como variaciones en la iluminación o reflexiones pueden alterar la apariencia de los objetos, lo que hace que encontrar correspondencias precisas sea aún más desafiante.

Además, a diferencia de los sistemas de visión activa, como LIDAR, las cámaras estereoscópicas pueden verse significativamente afectadas por la iluminación ambiental. En condiciones de baja luz o iluminación extremadamente variable, la eficacia de un sistema estereoscópico puede verse comprometida [33].

3.7. Procesamiento de Imágenes

El procesamiento de imágenes se refiere al conjunto de técnicas y operaciones que se pueden aplicar a las imágenes con el objetivo de mejorar su calidad, extraer información o características, y/o generar una representación alternativa [34]. Estas técnicas pueden ser aplicadas en imágenes producidas por diferentes medios. Por ejemplo:

- **Fotografía:** Las técnicas de procesamiento de imágenes son comúnmente usadas en la edición y postproducción de fotografías para mejorar el contraste, eliminar el ruido o corregir imperfecciones [35].
- **Ultrasonido:** En medicina, el procesamiento de imágenes de ultrasonido se utiliza para mejorar la visualización de estructuras anatómicas o para extraer características especificas de tejidos [36].
- **Rayos X:** El procesamiento de imágenes de rayos X puede ayudar en la detección y visualización de anomalías, como tumores de fracturas, haciendo que las imágenes sean más claras y legibles para el profesional médico [37].

Estas operaciones pueden ser aplicadas en distintas combinaciones y secuencias para lograr resultados específicos según las necesidades de la aplicación en cuestión. Es esencial tener una comprensión clara de cada operación porque cada técnica puede influir o modificar los datos de la imagen de maneras específicas. Una elección inapropiada o una secuencia incorrecta de operaciones puede llevar a interpretaciones erróneas, desinformación o pérdida de detalles cruciales en la imagen. En el peor de los casos, puede llevar a decisiones erradas, especialmente en aplicaciones críticas como la medicina o la seguridad. Por lo tanto, comprender a fondo cada técnica no solo garantiza la integridad de la información en la imagen, sino que también asegura que la imagen procesada sea fiel al propósito de la aplicación específica [38].

Dentro del procesamiento de imágenes, se pueden identificar varias categorías de operaciones:

- **Mejora de imágenes:** Se refiere al proceso de modificar imágenes para obtener una versión “mejor” según ciertos criterios estéticos o funcionales. Cuando hablamos de “mejorar la apariencia”, nos referimos a hacer que una imagen sea visualmente más

atractiva o más clara para la percepción humana o para una aplicación tecnológica especifica.

En este contexto, “mejorar” puede significar una variedad de cosas:

- **Contraste:** Incrementar la diferencia entre las regiones más oscuras y más claras de una imagen, permitiendo que ciertos detalles se destaquen más. La Figura 7 muestra este efecto, en donde la parte izquierda de la imagen muestra la luna con bajo contraste, mientras que en la derecha la luna se muestra con un contraste alto.



Figura 7: Comparación de contraste, Imagen izquierda tiene menor contraste a la derecha.
Fuente: www.ianmorison.com

- **Brillo:** Ajustar la luminosidad general de una imagen para que parezca más clara o más oscura según lo necesitado. En la Figura 8 se puede ver esta comparación, en donde la imagen de la izquierda se muestra con un brillo alto, mientras que la derecha tiene un brillo bajo.



Figura 8: Comparación de brillo, Imagen izquierda tiene mayor brillo que la derecha.
Fuente: www.epson.co.nz

- **Reducción de ruido:** Disminuir o eliminar el “grano” o “puntos” aleatorios en una imagen que pueden haber sido causados por la baja luz, alta sensibilidad

del sensor, o errores en la transmisión de datos. Se puede ver en la Figura 9 esta comparación con un antes y después de una imagen luego de haber pasado por un proceso de reducción de ruido.



Figura 9: Comparación de disminución de ruido, Imagen izquierda tiene mayor ruido que la derecha.
Fuente: photo.johanneshjorth.se

- **Segmentación:** La segmentación se refiere al proceso de dividir una imagen en partes o segmentos para resaltar objetos o características específicas, facilitando su análisis. Estos segmentos representan áreas homogéneas con respecto a alguna característica, como intensidad o color. La segmentación es fundamental en aplicaciones donde se necesita aislar o identificar objetos dentro de una imagen. A esto se le puede agregar la generación de etiquetas que permitan identificar los distintos objetos encontrados en la imagen. En la Figura 10 se pueden ver ejemplos de segmentación de imágenes, donde fue posible separar cada una de las partes de estas, como el cielo, árboles, pasto y animales.

3.8. Filtro de Kalman

El Filtro de Kalman introducido por Rudolf Kalman en 1960 [39], es una joya en el mundo de la estimación y el control. Nacido del deseo de proporcionar soluciones precisas en situaciones inciertas, esencialmente actúa como un “adivino educado” que mejora constantemente sus predicciones a medida que recibe nuevos datos.

Para entenderlo de manera más simple, es útil ponerse en el papel de que se está tratando de predecir la trayectoria de una pelota en movimiento. No sólo hay que basarse en la última posición conocida de la pelota, sino que también considerar cómo se movía antes. A medida que la pelota continúa moviéndose, se ajustan las predicciones utilizando la nueva información. El Filtro de Kalman hace precisamente eso, pero de manera matemática.

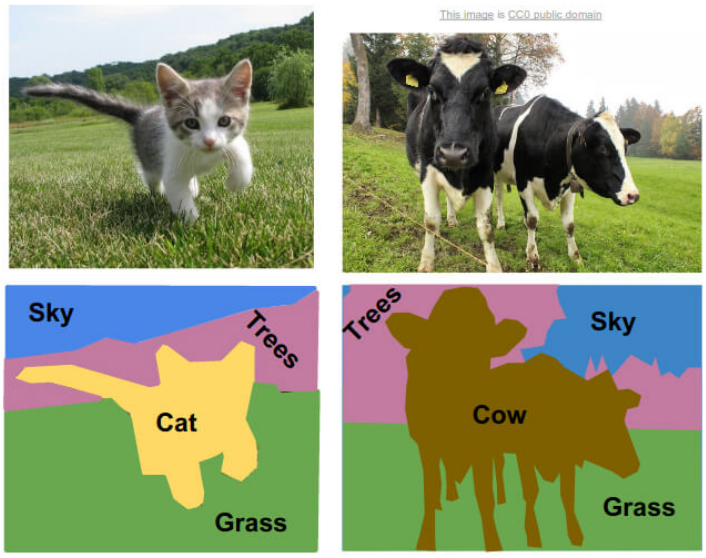


Figura 10: Ejemplo de segmentación de una imagen.
Fuente:www.superannotate.com

Al describirlo como un “algoritmo de estimación recursiva”, se refiere a que el filtro utiliza la estimación anterior y los nuevos datos recibidos para producir una nueva estimación. Esta “retroalimentación” continúa, lo que permite que las estimaciones sean cada vez más precisas a medida que se recopilan más datos.

La belleza del Filtro de Kalman radica en su capacidad para manejar el ruido y la incertidumbre. En muchos sistemas del mundo real, los datos que se reciben pueden estar “contaminados” con errores o ruido, ya sea debido a instrumentación imprecisa, interferencias o cualquier otro factor. El Filtro de Kalman es especialmente hábil para navegar a través de este ruido, ofreciendo estimaciones que tienden a ser más precisas que las basadas simplemente en los datos brutos.

3.8.1. Fundamentos

El Filtro de Kalman se fundamenta en la teoría de estimación bayesiana, un enfoque estadístico que se basa en aplicar la probabilidad a proposiciones teóricas en lugar de solo a eventos. En esencia, la teoría bayesiana permite actualizar nuestras creencias (probabilidades) sobre un evento dada nueva evidencia.

- **Predicción:** Aquí, el filtro anticipa el estado futuro del sistema usando el conocimiento anterior (estimación a priori) y el modelo del sistema. Es como hacer una suposición educada basada en lo que sabemos hasta ahora y cómo esperamos que el sistema se comporte.

- **Corrección:** Una vez que se tiene una nueva medida observada, el filtro compara esta medida con la predicción. Utilizando la teoría bayesiana, el filtro pondera su predicción y la nueva medida para obtener una "corrección" o actualización de la estimación, resultando en una "estimación a posteriori".

3.8.2. Modelo del Sistema

El Filtro de Kalman se fundamenta en representar sistemas dinámicos usando modelos matemáticos. Para aplicar el filtro adecuadamente, es imprescindible modelar el sistema en cuestión con precisión. Estos modelos se describen generalmente mediante dos ecuaciones primordiales:

- **Ecuación del Estado:** Esta ecuación caracteriza cómo evoluciona el sistema en el tiempo. Suponiendo que el sistema es lineal, se puede representar la relación entre el estado actual y el estado siguiente usando matrices y vectores. Dado que el número de variables utilizadas para el filtro de Kalman define la dimensión de las matrices, si consideramos n como el número de dichas variables, entonces las matrices implicadas en la ecuación del estado son de dimensión $n \times n$. Por lo tanto, la ecuación del estado se representa de la siguiente manera:

$$\mathbf{x}_{k+1} = A\,\mathbf{x}_k + B\,\mathbf{u}_k + \mathbf{w}_k$$

  Donde:

  - x_k: Representa el estado actual del sistema. Es un vector que captura toda la información relevante que necesitamos saber sobre el sistema en el instante de tiempo k. Un ejemplo de información relevante que podría ser capturada por el vector de estado x_k en el contexto del sistema de este trabajo es la posición y velocidad de los troncos en un camión en movimiento
  - A: Es la matriz de transición del estado. Describe cómo el sistema evoluciona de un paso de tiempo a otro debido a su propia dinámica, sin ninguna intervención externa o perturbación.
  - u_k: Representa la entrada de control en el instante k, que es un vector clave en el modelo del Filtro de Kalman. Se refiere a todas las acciones deliberadas o inputs externos aplicados al sistema para influir en su estado futuro. A diferencia de las variables de estado, que se actualizan en función de la dinámica interna del sistema y las observaciones, las entradas de control son maneras por las cuales se puede intervenir directamente en el sistema. Por ejemplo, en un vehículo autónomo, la entrada de control u_k podría incluir variables como la aceleración o el ángulo de giro del volante. Estas acciones deliberadas, como acelerar o girar, son fundamentales para predecir la posición futura del vehículo. Al integrar

estas entradas en el modelo, se puede anticipar de manera más precisa cómo estas acciones alterarán la trayectoria del vehículo, permitiendo ajustar nuestros algoritmos de seguimiento y predicción para adaptarse a estas dinámicas.

- B: Es la matriz que define cómo el sistema responde a las entradas de control. Multiplica las entradas de control para mapearlas al espacio de estados del sistema.
- w_k: Es el ruido del proceso. Captura las perturbaciones y otras incertidumbres no modeladas que afectan al sistema.

La ecuación del estado $\mathbf{x}_{k+1} = A\mathbf{x_k} + B\mathbf{u_k} + \mathbf{w_k}$ describe cómo el estado del sistema evoluciona de un instante de tiempo k al siguiente $k+1$. Primero, el sistema se mueve debido a su propia naturaleza, como se describe con $A\mathbf{x_k}$. Luego, las acciones deliberadas, las entradas de control, influyen en él, como se ve en $B\mathbf{u_k}$. Y finalmente, cualquier perturbación imprevista o ruido afecta al sistema representado por $\mathbf{w_k}$. Todo esto se combina para darnos el estado siguiente, $\mathbf{x_{k+1}}$.

- Ecuación de Observación: No siempre podemos observar directamente el estado de un sistema. En su lugar, realizamos mediciones que están relacionadas con este estado. Esta relación se modela a través de la ecuación de observación:

$$\mathbf{z_k} = H\mathbf{x_k} + \mathbf{v_k}$$

Donde:

- z_k: Esta es la observación o medida en el instante de tiempo k. Es el vector que representa lo que se detecta o mide sobre el sistema, posiblemente mediante sensores o instrumentos.
- H: Es la matriz de observación. Mapea el estado verdadero del sistema al espacio de observaciones. Esencialmente, describe cómo se traduce el estado interno del sistema a lo que realmente se puede medir u observar.
- x_k: Como se mencionó anteriormente, es el estado actual del sistema en el instante k.
- v_k: Es el ruido de la medida. Representa el error o las imprecisiones asociadas con la medición. Estas inexactitudes pueden ser inherentes al sensor o pueden surgir debido a factores externos.

La ecuación de observación $\mathbf{z_k} = H\mathbf{x_k} + \mathbf{v_k}$ nos dice cómo se traduce el estado real del sistema en una observación o medida. En primer lugar, el estado verdadero $\mathbf{x_k}$ se transforma mediante la matriz de observación H para producir una versión "observable" del estado. A esto se le suma cualquier ruido o error $\mathbf{v_k}$ asociado con la medición para producir la observación final $\mathbf{z_k}$. Es una representación de cómo percibimos o medimos el sistema desde el exterior. Es importante recordar que lo que observamos (la medida) puede no ser exactamente igual al estado real debido al ruido $\mathbf{v_k}$.

3.8.3. Ruido y Covarianza

Una de las razones por las que el Filtro de Kalman se destaca en el ámbito de la estimación es su enfoque intrínseco en el manejo del ruido. En muchos sistemas reales, las observaciones y mediciones están contaminadas con ruido, lo cual puede deberse a múltiples factores como errores instrumentales, interferencias externas, entre otros. El Filtro de Kalman asume que este ruido es inherente y se prepara para lidiar con él, en lugar de simplemente ignorarlo.

Dentro del Filtro de Kalman, el ruido del proceso w_k y el ruido de la medida v_k suelen considerarse como ruido blanco gaussiano, lo que significa que las muestras de ruido en diferentes momentos son independientes entre sí, y que tiene una distribución de probabilidad normal. Esto implica que los valores más probables del ruido son aquellos cercanos a la media, y que el valor del ruido en un punto en el tiempo no está correlacionado con el valor en otro punto en el tiempo. Estos ruidos tienen matrices de covarianza asociadas, Q y R, que representan cuánta variabilidad o dispersión se espera del ruido en el proceso y en las mediciones, respectivamente.

A medida que el filtro opera, no solo estima el estado actual del sistema sino también cuánta incertidumbre o error hay en esa estimación. Esta incertidumbre se representa mediante una matriz de covarianza del error del estado. Con cada iteración, el Filtro de Kalman actualiza esta matriz, reflejando cómo la confianza en la estimación cambia a medida que se reciben nuevas mediciones y se hacen nuevas predicciones. Es esta habilidad de rastrear y actualizar la incertidumbre lo que permite al filtro ponderar adecuadamente entre las predicciones basadas en el modelo y las mediciones observadas.

3.8.4. Aplicaciones de Filtro de Kalman

Dado el poder y versatilidad del Filtro de Kalman, no es sorprendente encontrar aplicaciones en diversos campos, tal como los siguientes:

- **Navegación por satélite:** El Filtro de Kalman juega un rol crítico en los sistemas de navegación por satélite [40]. Se aplica para filtrar el ruido de las señales de satélite y mejorar las estimaciones de posición y velocidad de las aeronaves. Los parámetros del filtro deben ser ajustados cuidadosamente para adaptarse a las dinámicas específicas del vehículo y a las características del ruido del sensor. Los resultados han demostrado una mejora significativa en la precisión de la ubicación en comparación con los métodos no filtrados, especialmente en situaciones donde la señal es intermitente o corrupta por interferencias.
- **Control de sistemas:** En el campo del control automático [41], el Filtro de Kalman es utilizado para proporcionar estimaciones óptimas del estado de sistemas dinámicos. Se ajusta para predecir y corregir la estimación del estado de variables como la posición

y la velocidad, lo que es crucial para controladores automáticos que requieren datos precisos para funcionar correctamente. Los resultados han mostrado que el uso del Filtro de Kalman puede llevar a un control más estable y eficiente en comparación con sistemas que no utilizan estimación de estado o que usan métodos menos avanzados.

- **Seguimiento de objetos en visión por computadora:** En el seguimiento de objetos dentro de la visión por computadora, el Filtro de Kalman se usa para predecir la trayectoria de objetos en movimiento a lo largo de videos. En [42] se proporciona un panorama general de cómo se aplica esta técnica en el seguimiento de objetos. Se requiere adaptar el modelo del filtro para que refleje con precisión las dinámicas del objeto que se está rastreando, y sus parámetros se optimizan para minimizar la discrepancia entre las predicciones y las observaciones reales. En comparación con otros enfoques de seguimiento, el Filtro de Kalman ha mostrado ser especialmente efectivo en situaciones con ruido y cuando los movimientos del objeto son relativamente predecibles y lineales.

3.9. Filtro de Kalman Extendido (EKF)

Una limitación inherente del Filtro de Kalman es su dependencia de la linealidad. Es decir, asume que las relaciones de las ecuaciones de estado y las ecuaciones de observación son lineales. Sin embargo, en muchos sistemas reales, especialmente aquellos que involucran fenómenos complejos o sensores avanzados, estas relaciones pueden ser inherentemente no lineales.

Para abordar este desafío, se introdujo el Filtro de Kalman Extendido (EKF). Mientras que el Filtro de Kalman linealiza las ecuaciones alrededor de un punto operativo fijo, el EKF linealiza las ecuaciones alrededor del estado estimado actual. Esto lo hace más adecuado para tratar con sistemas no lineales.

3.9.1. Funcionamiento del EKF

- **Linealización:** A diferencia del filtro de Kalman estándar que opera directamente con ecuaciones lineales, el EKF utiliza las funciones no lineales reales del sistema. Sin embargo, para poder trabajar con estas funciones, el EKF las linealiza mediante la aproximación de Taylor de primer orden en el punto de operación actual. Específicamente, se calculan las matrices Jacobianas de las funciones no lineales con respecto a los estados, que representan cómo cambiarían las funciones con pequeños cambios en los estados.
- **Predicción:** Utilizando las funciones no lineales del sistema y las matrices Jacobianas calculadas, el EKF predice el estado siguiente y la covarianza del estado, similar al paso de predicción en el filtro de Kalman estándar.

- **Actualización:** Una vez que se recibe una nueva medición, el EKF actualiza la estimación del estado y la covarianza del estado usando las mediciones y las matrices Jacobianas de las funciones de medición.
- **Iteración:** Al igual que con el filtro de Kalman, el proceso de predicción y actualización en el EKF se repite con cada nuevo conjunto de datos o en cada paso de tiempo.

3.9.2. Ventajas y Limitaciones

El EKF ha demostrado ser eficaz en muchos escenarios prácticos donde la no linealidad es moderada y las aproximaciones lineales son razonablemente precisas. Sin embargo, no está exento de limitaciones. La linealización utilizada en el EKF puede no ser adecuada para sistemas con no linealidades extremadamente fuertes o cambiantes. Además, el cálculo de las matrices Jacobianas puede ser computacionalmente intensivo, especialmente para sistemas de alta dimensión.

3.10. Filtro de Partículas (FP)

El Filtro de Partículas, fue introducido en el contexto de la estimación no lineal y no gaussiana a principios de la década de 1990 por Neil Gordon, David Salmond y Adrian Smith [43]. Es una técnica avanzada en estimación que pertenece a la familia de los métodos de Monte Carlo secuenciales. Esta técnica es particularmente poderosa en sistemas con modelos no lineales y ruido no gaussiano. A diferencia del Filtro de Kalman, que asume una distribución gaussiana del ruido y utiliza representaciones analíticas, el FP emplea un enfoque de muestreo para representar y propagar la incertidumbre del sistema.

3.10.1. Fundamentos

El Filtro de Partículas es un método de estimación basado en técnicas de muestreo. La idea central detrás del FP es representar la distribución de probabilidad posterior del estado de un sistema usando un conjunto de muestras, denominadas “partículas”. Estas partículas son esencialmente posibles soluciones o estados que el sistema podría tener en un momento determinado. La esencia del FP se puede resumir en tres pasos fundamentales: muestreo, ponderación y remuestreo.

- **Muestreo:** En esta etapa, se generan partículas que representan posibles estados futuros del sistema. Estas partículas se obtienen tomando en cuenta el modelo de transición del sistema y el estado estimado anterior.

- **Ponderación:** Una vez generadas las partículas, cada una se evalúa para determinar cuán bien se ajusta a la medición observada. Es decir, se mide la probabilidad de que una partícula dada sea el "verdadero" estado del sistema dado el nuevo conjunto de mediciones.

  Para realizar esta ponderación, se utiliza la función de verosimilitud que compara la medición observada con lo que se esperaría medir dado el estado propuesto por cada partícula.

  Como resultado, a cada partícula se le asigna un peso que refleja su relevancia o importancia en relación con las observaciones.

- **Remuestreo:** Una vez que todas las partículas han sido ponderadas, algunas tendrán pesos bajos (es decir, son menos probables dadas las observaciones) mientras que otras tendrán pesos altos. Para evitar que solo unas pocas partículas dominen la estimación, se lleva a cabo una etapa de remuestreo.

  Durante el remuestreo, se generan nuevas partículas a partir del conjunto existente, seleccionando preferentemente aquellas con mayores pesos. Esto significa que las partículas con mayores pesos serán replicadas, mientras que las partículas con menores pesos pueden ser descartadas.

  El remuestreo ayuda a garantizar que el conjunto de partículas siga representando adecuadamente la verdadera distribución de probabilidad posterior del estado del sistema.

Es crucial comprender que el FP es un método no paramétrico. Esto significa que no asume una forma específica para la distribución de probabilidad (como una distribución gaussiana en el Filtro de Kalman). En cambio, la distribución se define completamente por el conjunto de partículas y sus pesos. Esto le da al FP una flexibilidad significativa para manejar sistemas no lineales y ruidos no gaussianos.

3.10.2. Modelo del Sistema

Para definir el Filtro de Partículas desde un punto de vista matemático, vamos a considerar dos etapas principales: la propagación de partículas y la actualización de sus pesos.

- **Modelo de Transición (Propagación de Partículas):** La primera fase involucra propagar las partículas usando el modelo de transición del sistema. Matemáticamente, esto se puede describir como:

$$x_t^{(i)} = f(x_{t-1}^{(i)}, u_t, w_t^{(i)})$$

  Donde:

- $x_t^{(i)}$ representa el estado de la i-ésima partícula en el tiempo t.
- f es la función de transición del sistema.
- $x_{t-1}^{(i)}$ es el estado de la i-ésima partícula en el tiempo $t-1$.
- u_t es la entrada de control en el tiempo t.
- $w_t^{(i)}$ es el ruido del proceso asociado con la i-ésima partícula.

- **Modelo de Medición (Actualización de Pesos):** Una vez que las partículas se han propagado, se actualizan sus pesos en función de cuán bien las partículas se ajustan a la medición observada. Los pesos se calculan usando la función de verosimilitud:

$$w_t^{(i)} = g(z_t|x_t^{(i)})$$

Donde:

- $w_t^{(i)}$ es el peso de la i-ésima partícula en el tiempo t.
- g es la función de verosimilitud que compara la medición observada z_t con lo que se esperaría medir dado el estado $w_t^{(i)}$ de la i-ésima partícula.

Una vez calculados los pesos, se normalizan para que sumen 1:

$$w_t^{(i)} = \frac{w_t^{(i)}}{\sum_{j=1}^{N} w_t^{(j)}}$$

Donde:

- N es el número total de partículas.

Estos modelos describen el proceso iterativo del Filtro de Partículas. Las partículas se propagan usando el modelo de transición, se les asignan pesos basados en las mediciones observadas, y luego se remuestrean para formar el conjunto de partículas para la siguiente iteración.

3.10.3. Aplicaciones de Filtro de Partículas

A lo largo de los años, el FP ha encontrado aplicaciones en diversos campos, entre los que destacan:

- **Robótica:** En [44] se describe cómo el Filtro de Partículas se aplica a la localización de robots en la robótica móvil. Este algoritmo, conocido como localización de Monte Carlo, utiliza un conjunto de partículas para representar la distribución de la ubicación del robot. Cada partícula representa una posible ubicación y orientación del robot. Los parámetros del filtro, como el número de partículas, deben ser cuidadosamente seleccionados para equilibrar la precisión y el rendimiento computacional. Los resultados obtenidos han mostrado una localización más precisa en comparación con métodos de localización deterministas, especialmente en entornos con señales sensoriales ambiguas o engañosas.
- **Rastreo de Objetos:** En [45] el Filtro de Partículas es utilizado para rastrear objetos a través de secuencias de video. Este método, también conocido como el filtro CONDENSATION, maneja efectivamente el rastreo de objetos con movimientos no lineales y cambios en la iluminación. Los parámetros clave incluyen el modelo de movimiento del objeto y la función de verosimilitud que mide qué tan bien una partícula concuerda con las observaciones actuales. Los resultados demostraron que el FP superaba a los métodos tradicionales de seguimiento, ofreciendo una mejor adaptación a las trayectorias complejas y las oclusiones.
- **Sistemas de Navegación:** En [46] se ilustra cómo el FP mejora la precisión en la localización de vehículos, especialmente cuando las señales de GPS están degradadas. El filtro ajusta los parámetros de ruido y el modelo de movimiento del vehículo para estimar su trayectoria. Los resultados comparativos indicaron que el FP proporciona estimaciones más robustas y confiables en comparación con los sistemas de navegación basados únicamente en GPS, mejorando la precisión en entornos desafiantes.
- **Epidemiología:** En [47], el FP se aplica al modelado y seguimiento de enfermedades para predecir su propagación. Los parámetros incluyen tasas de transmisión y recuperación que se adaptan para reflejar las dinámicas de la enfermedad. Este enfoque ha mostrado ser valioso para comprender la evolución de epidemias y optimizar respuestas de salud pública, superando otros métodos que no manejan tan bien la incertidumbre y la variabilidad en los datos de enfermedades.

3.11. Aplicaciones de la Visión por Computadora en la Industria Maderera

La industria maderera avanza con firmeza hacia la meta de automatización en identificación y producción, buscando mejorar la inteligencia en la fabricación[48]. Esta investigación analiza en profundidad las aplicaciones de la visión por computadora en el ámbito de los productos de madera. Se abordaron áreas claves como la identificación de especies de árboles, inspección y clasificación de madera, detección de defectos en productos de madera, análisis de color en superficies de madera y control de calidad en productos de mobiliario.

El estudio también resalta cómo la visión por computadora puede desempeñar un papel fundamental en la producción y gestión de materiales de madera, y cómo su adopción puede

estar alineada con los objetivos actuales de desarrollo sostenible en la industria del mobiliario. Específicamente, se sugiere que estas tecnologías pueden ser cruciales para mejorar el impacto ambiental de los productos de madera y mobiliario, contribuyendo significativamente a los objetivos de carbono.

Este estudio servirá como base para entrar en más detalles de las distintas técnicas que fueron mencionadas.

3.11.1. Identificación Automática de Especies de Árboles

La identificación automática de especies de árboles es un área fascinante y desafiante dentro de la aplicación de la visión por computadora en la industria maderera y la botánica. Con el creciente interés en la conservación del medio ambiente, la gestión sostenible de los recursos forestales y la lucha contra la tala ilegal, la capacidad de identificar rápidamente y con precisión las especies de árboles se ha vuelto más crucial que nunca. Este desafío ha llevado a los investigadores a explorar el uso de tecnologías avanzadas de visión por computadora para desarrollar sistemas capaces de reconocer y clasificar diferentes especies de árboles basándose en sus características únicas.

Los estudios en este campo combinan diversas disciplinas, incluyendo botánica, ecología, ciencias forestales y, por supuesto, visión por computadora y aprendizaje automático. Al aplicar técnicas como el procesamiento de imágenes, la extracción de características y las redes neuronales convolucionales, los investigadores han logrado desarrollar sistemas que no solo igualan, sino en muchos casos superan, la precisión de la identificación manual realizada por expertos humanos.

En las siguientes secciones, se explorarán varios estudios notables que han contribuido al desarrollo de la identificación automática de especies de árboles, destacando sus metodologías, tecnologías utilizadas y los resultados obtenidos.

- **Using Deep Learning to Identify Costa Rican Native Tree Species From Wood Cut Images [49]**

  Este estudio destaca una innovadora aproximación a la identificación de especies arbóreas mediante el uso de imágenes. Los autores enfatizan la relevancia de identificar especies de árboles, considerando su papel en la conservación, la gestión sostenible y la lucha contra la tala ilegal. Como contribución inicial, se creó un conjunto de datos, CRTreeCuts, que agrupa imágenes macroscópicas de secciones transversales de 147 especies de árboles nativos de Costa Rica. En un avance técnico, implementaron una Red Neuronal Convolucional (CNN) que utiliza estas imágenes para la identificación automática de las especies de árboles. El modelo VGG16, previamente entrenado con el conjunto de datos IMAGENET, fue ajustado y aplicado, logrando una precisión de identificación del 70.5 % en la especie exacta y del 80.3 % al considerar las tres predicciones principales. Un aspecto esencial del estudio es la ausencia del Sesgo de Imagen

del Mismo Espécimen (SSPB), garantizando así la fiabilidad de los resultados. Como culminación del trabajo, se introdujo COCOBOLO, una aplicación móvil para dispositivos Android que capitaliza la CNN desarrollada, permitiendo identificar especies de árboles costarricenses a través de imágenes de secciones transversales de madera.

- **Leafsnap: A Computer Vision System for Automatic Plant Species Identification [50]**

  Este proyecto innovador se centró en la identificación de especies de árboles mediante el análisis de imágenes digitales de hojas. Para ello, se creó una extensa base de datos de imágenes de hojas, abarcando una amplia variedad de especies. Estas imágenes se capturaron bajo condiciones controladas para garantizar la calidad y consistencia necesarias para el análisis automatizado.

  En el corazón del sistema Leafsnap yacen sofisticados algoritmos de procesamiento de imágenes, diseñados para segmentar con precisión la hoja del fondo en cada imagen. Este paso era crucial para aislar las características clave de la hoja, como su forma, tamaño y textura. Posteriormente, se aplicaron técnicas de aprendizaje automático, incluyendo redes neuronales y algoritmos de clasificación, para identificar la especie de cada hoja basándose en estas características.

  Los resultados obtenidos por Leafsnap fueron notables. En pruebas realizadas con un conjunto diverso de imágenes, el sistema alcanzó una precisión de clasificación de aproximadamente el 90 %, superando significativamente los métodos tradicionales de identificación manual. Esta alta tasa de precisión no solo demostró la viabilidad del enfoque automatizado sino que también estableció a Leafsnap como una herramienta valiosa y rápida para la identificación de especies de árboles.

  Además de su aplicación en el campo científico, Leafsnap ha encontrado un uso extensivo como herramienta educativa. Ha permitido a estudiantes y aficionados a la naturaleza identificar especies de árboles de manera rápida y precisa, facilitando el aprendizaje y fomentando un mayor interés en la botánica y la conservación ambiental.

- **Tree Species Classification Based on Bark Textures Using Convolutional Neural Networks [51]**

  En este estudio los investigadores abordaron la tarea de identificar especies de árboles a partir de imágenes de su corteza utilizando técnicas avanzadas de visión por computadora. Se recopiló un conjunto de datos exhaustivo, compuesto por miles de imágenes de corteza de diferentes especies de árboles, cada una con sus características texturales y patrones únicos.

  Para el análisis y la clasificación de estas imágenes, se implementaron redes neuronales convolucionales (CNN). Se utilizaron arquitecturas específicas de CNN como AlexNet y VGG, conocidas por su eficacia en el procesamiento y clasificación de imágenes. Estos modelos se entrenaron y ajustaron para identificar patrones y texturas distintivas en las imágenes de corteza, lo que permitió una clasificación precisa de las especies.

Los resultados obtenidos por este estudio fueron impresionantes: el modelo VGG, en particular, alcanzó una precisión de clasificación de alrededor del 92 % en la identificación de especies de árboles. Este nivel de precisión representó una mejora significativa en comparación con los métodos de clasificación basados en características manuales, que típicamente alcanzaban tasas de precisión mucho más bajas.

Además, el estudio incluyó un análisis comparativo con otras técnicas de visión por computadora, demostrando que las CNN no solo eran más precisas sino también más consistentes en la clasificación de especies a partir de imágenes de corteza, incluso bajo diversas condiciones de iluminación y variaciones en la textura de la corteza.

Este enfoque de clasificación de especies mediante CNN representa un avance significativo en la botánica y la gestión forestal, ofreciendo una herramienta poderosa y no invasiva para la identificación rápida y precisa de especies de árboles, lo que es esencial para la conservación y el estudio de la biodiversidad forestal.

3.12. Algoritmos de Seguimiento de Objetos en Tiempo Real

En el campo del seguimiento de objetos en tiempo real, la evolución de los algoritmos ha sido impulsada por la creciente necesidad de aplicaciones en áreas como la vigilancia, el seguimiento vehicular, y la gestión de recursos naturales, entre otros. Estos algoritmos se han desarrollado para abordar desafíos específicos como la oclusión, variaciones en la iluminación y el movimiento, manteniendo un equilibrio entre precisión y eficiencia en tiempo real. En esta sección, exploraremos varios algoritmos clave que han marcado hitos en este campo, examinando sus métodos de implementación, resultados obtenidos, características específicas, ventajas y desventajas, así como los diversos contextos en los que han sido aplicados.

3.12.1. Simple Online and Realtime Tracking (SORT)

El algoritmo SORT [52] es una técnica en el campo del seguimiento de objetos, particularmente reconocido por su capacidad de operar en tiempo real con alta eficiencia. Desarrollado con el objetivo de equilibrar velocidad y precisión, SORT se ha establecido como una solución prominente para aplicaciones donde el seguimiento rápido y fiable de múltiples objetos es crucial. Esta característica lo hace especialmente valioso en escenarios donde la capacidad de procesamiento es una limitante, o donde se requiere una respuesta rápida, como en la vigilancia de seguridad, el seguimiento vehicular y el análisis de video en tiempo real.

- **Características Clave del Algoritmo SORT**
  - **Eficiencia en Tiempo Real:** Diseñado para ser rápido y eficiente, adecuado para aplicaciones donde el tiempo de respuesta es crítico.

- **Enfoque en Asociación de Datos:** Utiliza información sobre la posición y movimiento de objetos para seguirlos a lo largo del tiempo.
- **Uso de Filtros de Kalman:** Emplea estos filtros para mejorar la precisión en la predicción de la posición de los objetos.
- **Manejo de Oclusiones y Entradas/Salidas de Objetos:** Capaz de manejar situaciones donde los objetos entran y salen del campo de visión, aunque con limitaciones en casos de oclusión severa.
- **Dependencia de la Detección de Objetos:** Requiere un sistema de detección de objetos robusto y preciso para funcionar efectivamente.

- **Ventajas y Limitaciones**

  - **Ventajas:** Alta velocidad, eficiencia y flexibilidad para integrarse con sistemas de detección de objetos.
  - **Limitaciones:** Menos efectivo en oclusiones prolongadas y dependiente de la calidad del detector de objetos.

3.12.2. DeepSORT

DeepSORT (Deep Simple Online and Realtime Tracking) [53] es una extensión y mejora del algoritmo SORT, que integra técnicas de aprendizaje profundo para mejorar la precisión en el seguimiento de objetos en tiempo real. Este algoritmo fue desarrollado para abordar algunas de las limitaciones de SORT, especialmente en escenarios de oclusión y cambios de apariencia de los objetos. DeepSORT combina las ventajas de rapidez y eficiencia de SORT con la robustez y precisión del aprendizaje profundo, lo que lo convierte en una herramienta poderosa para aplicaciones de seguimiento de objetos más complejas y dinámicas.

- **Características Clave del Algoritmo DeepSORT**

  - **Integración de Aprendizaje Profundo:** Diseñado para ser rápido y eficiente, adecuado para aplicaciones donde el tiempo de respuesta es crítico.
  - **Mejora en el Manejo de Oclusiones:** Gracias a su enfoque en el aprendizaje profundo, DeepSORT es más capaz de manejar oclusiones y cambios en la apariencia de los objetos que SORT.
  - **Asociación de Datos con Características de Apariencia:** Utiliza características extraídas por la red neuronal para asociar datos de manera más precisa, lo que resulta en un seguimiento más estable y confiable.
  - **Uso Continuado de Filtros de Kalman:** Al igual que SORT, emplea filtros de Kalman para la predicción de la trayectoria de los objetos.

- **Eficiencia y Precisión:** Aunque es más complejo que SORT, DeepSORT mantiene un equilibrio entre eficiencia y precisión, siendo adecuado para aplicaciones en tiempo real que requieren un mayor nivel de detalle en el seguimiento.

- **Ventajas y Limitaciones**

  - **Ventajas:** Mejor capacidad para manejar oclusiones y cambios en la apariencia, mayor precisión en el seguimiento gracias al aprendizaje profundo.
  - **Limitaciones:** Mayor complejidad computacional en comparación con SORT, requiere más recursos y es ligeramente menos eficiente en tiempo real.

3.12.3. FairMOT

FairMOT [54] es un algoritmo de seguimiento de objetos en tiempo real que se distingue por su enfoque holístico en el seguimiento de múltiples objetos. Este algoritmo se ha desarrollado para superar algunas limitaciones de los sistemas de seguimiento anteriores, que a menudo sacrificaban la precisión de detección en favor de la identidad del seguimiento o viceversa. FairMOT integra de manera efectiva tanto la detección como la identificación de objetos, logrando un equilibrio óptimo entre estos dos aspectos clave. Esta integración permite que FairMOT realice un seguimiento preciso y consistente de múltiples objetos en escenarios complejos y dinámicos.

- **Características Clave del Algoritmo FairMOT**

  - **Integración de Detección y Seguimiento:** FairMOT utiliza una única red neuronal para manejar tanto la detección como el seguimiento de objetos, mejorando la coherencia entre estos dos procesos.
  - **Alto Rendimiento en Seguimiento de Múltiples Objetos:** Especialmente eficaz en el seguimiento de múltiples objetos, manteniendo altas tasas de precisión y fiabilidad.
  - **Uso de Aprendizaje Profundo:** Emplea técnicas de aprendizaje profundo para la extracción de características y la asociación de datos, lo que le permite manejar con eficacia situaciones complejas y variadas.
  - **Eficiencia en Tiempo Real:** A pesar de su complejidad, FairMOT está optimizado para funcionar eficientemente en tiempo real, lo que lo hace adecuado para aplicaciones que requieren respuesta rápida.
  - **Robustez en Situaciones Difíciles:** Buen manejo de oclusiones, cambios en la iluminación y otras condiciones desafiantes, gracias a su enfoque integrado y al uso de aprendizaje profundo.

- **Ventajas y Limitaciones**

- **Ventajas:** Equilibrio efectivo entre detección y seguimiento, alta precisión en seguimiento de múltiples objetos, y robustez en condiciones desafiantes.
- **Limitaciones:** Mayor complejidad y demanda de recursos computacionales en comparación con algoritmos más simples, lo que puede ser un desafío en sistemas con limitaciones de hardware.

3.12.4. MOTDT

El algoritmo MOTDT (Multi-Object Tracking with Deeply Learned Candidate Selection and Person Re-Identification) [55], representa un avance significativo en el campo del seguimiento de múltiples objetos en tiempo real. Este algoritmo se enfoca en mejorar la eficiencia y precisión del seguimiento de múltiples personas, un desafío notable en aplicaciones de vigilancia y análisis de video. MOTDT combina técnicas avanzadas de selección de candidatos aprendidos mediante aprendizaje profundo y re-identificación de personas, lo que le permite distinguir y seguir con precisión a individuos específicos en entornos complejos y dinámicos.

- **Características Clave del Algoritmo MOTDT**
  - **Selección de Candidatos con Aprendizaje Profundo:** MOTDT utiliza aprendizaje profundo para seleccionar candidatos para el seguimiento, mejorando la precisión en la identificación de los objetos adecuados para seguir.
  - **Re-Identificación de Personas:** Incorpora técnicas de re-identificación de personas, permitiendo al algoritmo reconocer y seguir a la misma persona a lo largo del tiempo, incluso después de oclusiones o cambios en el entorno.
  - **Eficiencia en el Seguimiento de Múltiples Objetos:** Diseñado específicamente para el seguimiento de múltiples personas, maneja eficazmente situaciones con numeroso objetos en movimiento.
  - **Alto Rendimiento en Tiempo Real:** A pesar de su complejidad, MOTDT está optimizado para funcionar eficientemente en tiempo real, lo que lo hace adecuado para aplicaciones de vigilancia y seguimiento en entornos dinámicos.
  - **Robustez ante Cambios y Oclusiones:** Su enfoque en la re-identificación lo hace robusto en situaciones donde los objetos son ocluidos o cambian su apariencia.
- **Ventajas y Limitaciones**
  - **Ventajas:** Alta precisión en la selección y seguimiento de objetivos, habilidad para manejar eficazmente la re-identificación de personas en entornos complejos.
  - **Limitaciones:** Mayor demanda de recursos computacionales en comparación con algoritmos más simples, y un enfoque principal en el seguimiento de personas, que puede limitar su aplicabilidad en otros contextos.

3.12.5. CenterTrack

El algoritmo CenterTrack, presentado en la European Conference on Computer Vision en 2020 [56], representa un enfoque innovador en el campo del seguimiento de objetos. Este trabajo, titulado "Tracking Objects as Points", introduce una metodología única para el seguimiento de objetos centrada en la identificación y seguimiento de puntos centrales de los objetos, en lugar de adoptar enfoques tradicionales basados en la detección de bordes o características. CenterTrack se destaca por su capacidad para manejar eficientemente el seguimiento en entornos dinámicos y su habilidad para adaptarse a cambios rápidos en la escena.

- **Características Clave del Algoritmo CenterTrack**
  - **Enfoque en Puntos Centrales:** CenterTrack identifica y sigue los puntos centrales de los objetos, lo que simplifica el proceso de seguimiento y mejora la precisión.
  - **Manejo Dinámico de la Escena:** Especialmente diseñado para entornos donde los objetos entran y salen frecuentemente del campo de visión, y donde hay cambios significativos en la escena.
  - **Uso de Redes Neuronales:** Implementa técnicas de aprendizaje profundo para la detección y seguimiento de objetos, lo que le permite adaptarse a diversas condiciones y tipos de objetos.
  - **Alto Rendimiento en Tiempo Real:** A pesar de su sofisticación, CenterTrack mantiene una alta eficiencia, permitiendo su uso en aplicaciones de seguimiento en tiempo real.
  - **Robustez en Condiciones Cambiantes:** Capaz de adaptarse a cambios rápidos en la escena, como oclusiones y variaciones en la iluminación, manteniendo un seguimiento consistente.
- **Ventajas y Limitaciones**
  - **Ventajas:** Alta precisión en el seguimiento, habilidad para adaptarse a entornos dinámicos y capacidad de manejar eficazmente los cambios en la escena.
  - **Limitaciones:** Mayor demanda computacional en comparación a métodos más simples y puede requerir ajustes específicos para optimizar su rendimiento en diferentes aplicaciones.

3.12.6. ByteTrack

El algoritmo ByteTrack [57], representa un avance significativo en el seguimiento de múltiples objetos. Este algoritmo, bajo el título "ByteTrack: Multi-Object Tracking by Associating Every Detection Box", introduce un enfoque novedoso que se centra en asociar cada caja de

detección, optimizando así el proceso de seguimiento en entornos dinámicos y complejos. ByteTrack se destaca por su eficacia en asociar detecciones en situaciones de alta densidad de objetos y en escenas con cambios rápidos.

- **Características Clave del Algoritmo ByteTrack**
  - **Asociación de Cada Caja de Detección:** ByteTrack asocia cada caja de detección en el entorno, lo que aumenta significativamente la precisión del seguimiento.
  - **Eficaz en Entornos de Alta Densidad:** Particularmente efectivo en situaciones donde hay muchos objetos en movimiento, manteniendo un seguimiento preciso y consistente.
  - **Manejo de Oclusiones y Cambios Rápidos:** Su enfoque de asociación lo hace robusto en situaciones de oclusiones frecuentes y cambios rápidos en la escena.
  - **Aplicación de Aprendizaje Profundo:** Utiliza técnicas avanzadas de aprendizaje profundo para la detección y seguimiento, adaptándose a diferentes tipos de objetos y escenarios.
  - **Alto Rendimiento en Seguimiento en Tiempo Real:** A pesar de su complejidad, ByteTrack mantiene una eficiencia adecuada para aplicaciones en tiempo real.
- **Ventajas y Limitaciones**
  - **Ventajas:** Excelente en el seguimiento de situaciones de alta densidad de objetos y en escenas dinámicas, con alta precisión y robustez.
  - **Limitaciones:** Requiere una mayor capacidad de procesamiento en comparación con métodos más simples, además de que su eficacia depende de la calidad de los datos con que este se entrenó.

Este capítulo presentó los fundamentos teóricos y tecnológicos esenciales para el desarrollo del algoritmo de seguimiento de múltiples objetos en el sistema INSTALOG, destinado a mejorar el conteo y la medición de troncos en camiones de carga. Se exploran varios conceptos clave:

- **Visión por Computadora:** Se discutió cómo la capacidad de interpretar y actuar basándose en la información visual es crucial para automatizar la detección y el seguimiento de troncos, destacando la importancia de la visión por computadora en el contexto industrial y su aplicación en INSTALOG.
- **Teorema de Bayes y Filtros:** Se introdujeron el Teorema de Bayes y los filtros (Kalman, Kalman extendido y de partículas) como herramientas matemáticas y estadísticas fundamentales para la predicción y corrección de errores en tiempo real, proporcionando a INSTALOG ventajas en precisión y eficacia.

- **Seguimiento de Múltiples Objetos (MOT):** Se enfatizó el desafío de seguir múltiples troncos a través de imágenes, manteniendo un registro coherente incluso frente a obstrucciones. Se discutieron las aplicaciones de la visión por computadora en la industria maderera, incluyendo la identificación automática de especies de árboles y el seguimiento de objetos en tiempo real, destacando varios algoritmos como SORT, DeepSORT, y otros, por sus ventajas y limitaciones específicas.
- **Aplicaciones Industriales:** Se mencionaron aplicaciones específicas de la visión por computadora en la industria maderera, subrayando el potencial de estas tecnologías para transformar operaciones tradicionales hacia procesos más eficientes y precisos.

Este marco conceptual sienta las bases para una solución innovadora al problema de conteo y seguimiento de troncos, destacando el papel transformador de la tecnología en la industria maderera.

Teniendo una comprensión sólida de los principios subyacentes de la visión por computadora, se tienen las bases necesarias para poder realizar una propuesta de solución en el siguiente capítulo.

CAPÍTULO 4
PROPUESTA DE SOLUCIÓN

Este capítulo se enfoca en desarrollar una solución innovadora para el sistema INSTALOG, dirigida específicamente a la incorporación de una funcionalidad vital: el seguimiento eficiente de troncos. Aunque INSTALOG ya cuenta con capacidades de detección de troncos, la meta de esta memoria es enriquecer el sistema con una herramienta avanzada que permita seguir la trayectoria y el movimiento de los troncos detectados, mejorando así significativamente la eficiencia del proceso global.

Comenzaremos con una descripción detallada de las capacidades actuales de INSTALOG, destacando cómo se lleva a cabo la detección de troncos y por qué es esencial añadir una función de seguimiento. Esta evaluación del estado actual del sistema servirá para identificar los requisitos y desafíos específicos asociados con el seguimiento efectivo de troncos.

Luego, exploraremos los criterios y consideraciones clave que guían la elección de un algoritmo de seguimiento apropiado para esta aplicación. Estos incluyen factores como la precisión, la capacidad para manejar oclusiones parciales, y la adaptabilidad a las condiciones específicas del seguimiento de troncos.

Posteriormente, presentaremos el algoritmo seleccionado para la tarea de seguimiento, proporcionando una justificación detallada de esta elección. Analizaremos sus ventajas, cómo se alinea con los objetivos y desafíos del proyecto y por qué es el más adecuado para integrarse con el sistema de detección existente en INSTALOG.

Además, discutiremos las adaptaciones y ajustes necesarios para que este algoritmo funcione de manera óptima en el contexto específico de INSTALOG, incluyendo el desarrollo de heurísticas personalizadas y mejoras para enfrentar situaciones de seguimiento desafiantes.

Finalmente, delinearemos el proceso de integración de esta nueva funcionalidad de seguimiento en INSTALOG, con un enfoque tanto en la eficacia técnica como en la viabilidad operativa, asegurando que la solución sea práctica y aplicable en la industria maderera.

4.1. INSTALOG en la Actualidad

INSTALOG representa una herramienta avanzada en la industria maderera, que utiliza cámaras estereoscópicas para la detección y el análisis de troncos. El sistema tiene la capacidad de operar con una o dos cámaras, colocadas a cada lado del camión, lo que proporciona una visión integral de la carga transportada.

El núcleo del sistema INSTALOG es un algoritmo de detección de troncos basado en YOLOV3,

que ha sido especialmente adaptado para este propósito. YOLOV3, conocido por su eficiencia en la detección de objetos en tiempo real luego de haber sido entrenado específicamente para el problema, se ajusta perfectamente para identificar troncos en los bancos de los camiones que pasan frente a las cámaras. El sistema utiliza la información capturada por estas cámaras para generar bounding boxes alrededor de cada tronco, determinando así su ubicación y área.

Una característica interesante de INSTALOG es su capacidad para calcular un volumen aproximado de cada tronco. Aunque este cálculo no es preciso, ofrece una estimación razonable que es valiosa para las operaciones logísticas. Este proceso se logra analizando el área cubierta por cada bounding box detectado por el sistema.

El algoritmo actual de INSTALOG, para decidir la cantidad de troncos en cada banco del camión realiza comparaciones entre diferentes frames de imágenes. Este método se basa en la premisa de que, una vez que se deja de incrementar el número de troncos detectados en imágenes consecutivas, se ha alcanzado un conteo máximo. Este conteo máximo se utiliza entonces como el resultado final para ese banco específico del camión. Un aspecto importante de este proceso es que se realizan comparaciones en todas las cámaras disponibles, y el sistema selecciona la imagen de la cámara que detectó la mayor cantidad de troncos, ya que las detecciones erróneas son poco comunes, lo que sugiere con solidez que la cámara que identificó más troncos es, de hecho, la que logró capturar la mayor cantidad de información relevante de sus imágenes. Esto asegura la máxima precisión posible en el conteo.

A pesar de las capacidades avanzadas de INSTALOG, existen limitaciones significativas en el sistema actual, especialmente en situaciones de oclusión y en la consistencia de la detección de troncos. Estas limitaciones se hacen evidentes en el proceso de conteo y pueden afectar significativamente la precisión del sistema.

Una limitación clave del sistema se manifiesta cuando hay inconsistencias en la detección de troncos entre imágenes consecutivas. Específicamente, si un tronco es identificado en una imagen pero no en la siguiente, y simultáneamente, un tronco diferente es detectado en la última imagen sin haber sido visto en la anterior, el algoritmo no modifica el conteo total de troncos (ver Figura 11). Esto implica que, aunque en realidad se estén observando troncos distintos en las imágenes sucesivas, el sistema los registra como si fueran el mismo. Esta situación puede conducir a errores en el conteo de troncos, ya sea subestimando o sobreestimando el número real, dependiendo del movimiento y la disposición de los troncos en las imágenes. Esta inconsistencia en la detección se debe a la falta de un mecanismo de seguimiento que pueda mantener la identidad de cada tronco a lo largo de su movimiento y a pesar de las oclusiones. En otras palabras, mientras el sistema actual es capaz de detectar troncos, carece de la capacidad de “recordar” y seguir estos troncos de manera continua a través de sucesivos frames de video.

Esta limitación subraya la necesidad de implementar una solución de seguimiento robusta que pueda mantener la consistencia y precisión en el conteo de troncos, a pesar de los desafíos presentados por las oclusiones y los cambios en la visibilidad de los troncos. Un

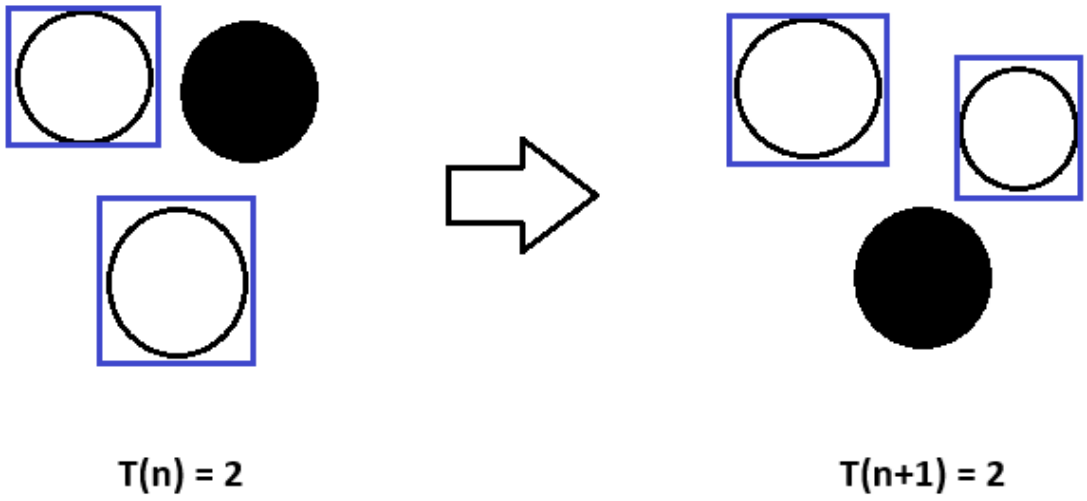


Figura 11: Ejemplo de tronco que aparece en un frame n, pero no en un frame n+1, manteniendo el conteo de troncos. Bounding Box azul representa un tronco detectado, mientras que un tronco rellenado en color negro representa que no fue detectado debido a una obstrucción.

Fuente: Elaboración Propia.

algoritmo de seguimiento eficaz abordaría este problema al asegurar que cada tronco sea contabilizado de manera precisa a lo largo del tiempo, mejorando así la fiabilidad y exactitud del sistema INSTALOG.

4.2. Criterios de Selección de Algoritmos

Al seleccionar un algoritmo de seguimiento adecuado para integrar en el sistema INSTALOG, es crucial tener en cuenta una serie de criterios clave que asegurarán que la solución elegida no solo sea efectiva sino también compatible y eficiente. Estos criterios incluyen:

- **Precisión de los Resultados:** La precisión de los resultados es otro criterio crucial. En el seguimiento de troncos, cada error en la detección puede llevar a imprecisiones en el conteo y en la estimación del volumen. Por lo tanto, es esencial que el algoritmo seleccionado sea capaz de seguir cada tronco detectado por YOLOV3 de manera consistente y precisa, manteniendo la fiabilidad en todo el proceso.
- **Capacidad de Operar en Tiempo Real:** La capacidad de operar en tiempo real es también de gran importancia. Dada la naturaleza dinámica de los troncos en movimiento, el algoritmo debe ser capaz de procesar información y mantener el seguimiento sin retrasos significativos, Esto es vital para las operaciones logísticas y de producción que

se realizan en tiempo real, especialmente considerando que puede haber bancos de madera que puedan tener una cantidad bastante elevada de troncos. La habilidad de manejar eficientemente estas grandes cantidades sin comprometer la precisión o la rapidez es crucial para el éxito del sistema.

- **Compatibilidad con YOLOV3:** La compatibilidad con YOLOV3 es esencial para garantizar una transición fluida entre la detección y el seguimiento de troncos. El algoritmo de seguimiento debe ser capaz de integrarse sin problemas con las salidas proporcionadas por YOLOV3, lo que facilitará la implementación y reducirá la necesidad de modificaciones extensas.

- **Facilidad de Implementación y Uso:** La facilidad de implementación es fundamental, especialmente considerando que este proyecto es una prueba de la factibilidad del seguimiento de troncos. Es crucial seleccionar un algoritmo que sea sencillo de implementar y que permita una evaluación rápida y efectiva de su aplicabilidad en un entorno industrial real. Un algoritmo con una curva de aprendizaje baja y la capacidad de adaptación rápida facilitará la integración con el sistema existente y permitirá realizar ajustes basados en los resultados de las pruebas iniciales.

- **Robustez Frente a Oclusiones y Variabilidad de Condiciones:** La robustez frente a oclusiones y variabilidad de condiciones es un factor importante. El algoritmo debe ser lo suficientemente robusto para manejar situaciones donde los troncos se ocluyen entre sí o cuando hay variaciones en las condiciones de iluminación y en los patrones de movimiento.

- **Costo Computacional y Recursos Necesarios:** El costo computacional y los recursos necesarios para ejecutar el algoritmo son también consideraciones importantes. Un algoritmo que requiera una gran cantidad de recursos computacionales o hardware especializado puede no ser viable desde un punto de vista práctico y económico para el entorno operativo de INSTALOG.

- **Flexibilidad y Posibilidad de Ajustes Personalizados:** Por último, la flexibilidad y la posibilidad de ajustes personalizados son criterios relevantes. La capacidad del algoritmo para ser ajustado y adaptado a las necesidades específicas del seguimiento de troncos en INSTALOG es fundamental. Esto incluye la posibilidad de modificar parámetros o incorporar heurísticas personalizadas para mejorar el rendimiento del seguimiento en situaciones específicas a este proyecto.

4.3. Selección del Algoritmo

En el proceso de selección del algoritmo adecuado para el seguimiento de troncos en INSTALOG, se evaluaron algoritmos destacados en el campo del seguimiento de objetos en tiempo real. Cada uno de estos algoritmos fue analizado en función de los criterios clave definidos anteriormente (Ver Tabla 1)

SORT (Simple Online and Realtime Tracking) [52] se distingue por su simplicidad y facilidad de implementación, cumpliendo eficientemente con el criterio de factibilidad para las pruebas iniciales. A pesar de que puede enfrentar desafíos con las oclusiones complejas, su capacidad para operar en tiempo real y su compatibilidad con YOLOV3 lo hacen una opción atractiva. Además, SORT ofrece un notable nivel de flexibilidad, permitiendo la personalización de parámetros críticos y la incorporación de heurísticas personalizadas para adaptarse a las necesidades específicas del proyecto INSTALOG. Su bajo costo computacional y la capacidad de operar efectivamente con recursos moderados lo convierten en una solución práctica y económica, resaltando su viabilidad para una amplia gama de entornos operativos sin incurrir en costos adicionales significativos por hardware especializado.

DeepSORT [53], una versión mejorada de SORT, añade un componente de aprendizaje profundo para mejorar la precisión en el seguimiento. Aunque ofrece una mayor precisión, especialmente en situaciones de oclusiones, su mayor complejidad computacional y la necesidad de ajuste fino lo hacen menos idóneo para una implementación rápida y sencilla en esta etapa de prueba de factibilidad. Aún así, gracias a ser un sucesor bastante directo del algoritmo SORT, posee una capacidad parecida en cuanto a la flexibilidad de adaptarse a distintos problemas y la compatibilidad con YOLOV3.

FairMOT (Fair Multi Object Tracking [54] integra la detección y el seguimiento en un único marco de trabajo, ofreciendo un equilibrio entre precisión y velocidad. Sin embargo, la integración de este algoritmo en el sistema INSTALOG actual, que ya emplea YOLOV3 para la detección, podría requerir modificaciones sustanciales, lo que va en contra del criterio de facilidad de implementación.

MOTDT (Multi-Object Tracking with Dual-Path) [55] ofrece un enfoque balanceado entre precisión y velocidad. Aunque es eficiente en términos de seguimiento en tiempo real, su complejidad y la necesidad de ajustes finos podrían complicar su integración inmediata en el sistema INSTALOG actual.

CenterTrack [56], que localiza objetos en cada frame y predice su movimiento, es innovador en su enfoque. Sin embargo, la necesidad de adaptar el sistema existente para integrar adecuadamente este algoritmo lo hace menos viable para una implementación rápida y sencilla.

ByteTrack [57] se destaca por su alta precisión en el seguimiento, incluso en escenarios con oclusiones y movimientos rápidos. A pesar de su impresionante rendimiento, la complejidad y los requisitos computacionales más elevados de ByteTrack presentan un desafío para su implementación inmediata en INSTALOG.

Dado estos análisis, se ha decidido optar por el algoritmo SORT para esta fase de implementación en INSTALOG. La elección de SORT se basa en su simplicidad y la capacidad de proporcionar resultados de seguimiento suficientemente buenos para verificar la factibilidad de este tipo de algoritmos en el contexto de INSTALOG. La facilidad de integración de SORT con el sistema de detección basado en YOLOV3 existente es un factor clave en esta decisión, ya que permite una implementación directa y eficiente, minimizando la necesidad

de ajustes extensos o desarrollo adicional.

La implementación de SORT en INSTALOG nos permitirá evaluar la efectividad del seguimiento de troncos en un entorno operativo real, proporcionando una base sólida para futuras investigaciones y mejoras en el sistema. Esta decisión se alinea con los objetivos de mejorar la precisión y eficiencia en el conteo y seguimiento de troncos, manteniendo al mismo tiempo una metodología práctica y viable para la implementación tecnológica.

Criterio/Algoritmo	SORT	DeepSORT	FairMOT	MOTDT	CenterTrack	ByteTrack
Precisión de los Resultados	✓	✓✓	✓✓	✓✓	✓✓	✓✓✓
Capacidad de Operar en Tiempo-Real	✓✓✓	✓	✓✓	✓✓	✓✓	✓✓
Compatibilidad con YOLOV3	✓✓✓	✓✓✓	✓	✓✓	✓	✓✓
Facilidad de Implementación y Uso	✓✓✓	✓✓	✓	✓	✓	✓
Robustez Frente a Oclusiones y Variabilidad de Condiciones	✓	✓✓	✓✓	✓✓	✓✓	✓✓✓
Costo Computacional y Recursos Necesarios	✓✓✓	✓✓	✓✓	✓✓	✓✓	✓
Flexibilidad y Posibilidad de Ajustes Personalizados	✓✓	✓✓	✓	✓	✓	✓✓

Tabla 1: Resumen de Criterios por Algoritmo - Símbolos utilizados: ✓ Cumplimiento Básico, ✓✓ Buen Rendimiento, y ✓✓✓ Rendimiento Excepcional.
Fuente: Elaboración Propia

4.4. Implementación del Algoritmo

El algoritmo SORT [52], está diseñado para ser eficiente y efectivo en el seguimiento de múltiples objetos en aplicaciones en tiempo real. Los principales componentes de SORT incluyen:

- **Detección:** La fase de detección emplea un algoritmo seleccionado según las especificaciones de cada proyecto específico, con el objetivo de identificar objetos en cada frame y generar sus respectivas bounding boxes.

- **Modelo de Estimación:** Implementa un modelo lineal de velocidad constante para aproximar los desplazamiento entre frames de cada objeto.
- **Asociación de Datos:** Emplea el algoritmo húngaro, calculando la distancia de intersección sobre unión (IoU) entre las detecciones y las cajas delimitadoras predichas para la asignación óptima.
- **Creación y Eliminación de Identidades de Seguimiento:** Gestiona la entrada y salida de objetos en la escena, creando nuevas identidades de seguimiento para objetos no rastreados y terminando las trayectorias que no se detectan durante un cierto número de frames.

En el contexto de INSTALOG, SORT se adapta para rastrear el movimiento de troncos en un camión, centrándose en el procesamiento en tiempo real y manteniendo las identidades de seguimiento a pesar de las posibles oclusiones o condiciones variables de seguimiento. La implementación implica integrar SORT con el sistema de detección basado en YOLOV3 existente en INSTALOG y adaptarlo a las necesidades específicas del seguimiento de troncos.

A continuación se hablará más en detalle de cada uno de los componentes que se nombraron con anterioridad:

- **Detección:** Esta fase de detección es fundamental para el éxito del seguimiento de troncos en INSTALOG. Asegurando que los troncos se detecten de manera precisa y efectiva en cada frame, SORT puede entonces realizar un seguimiento más eficiente y preciso, manteniendo las identidades de los troncos a lo largo del tiempo y proporcionando estimaciones de conteo y volumen más fiables. Esta fase consta de tres componentes principales:
  - **Marco de Trabajo de Detección:** En el contexto de INSTALOG, el algoritmo SORT comienza con la detección de troncos en cada frame del video de cada cámara. Este proceso es fundamental, ya que las detecciones iniciales alimentan directamente al sistema de seguimiento. INSTALOG utiliza una red neuronal convolucional (CNN) adaptada, específicamente YOLOV3, para realizar esta detección. YOLOV3 es conocido por su velocidad y precisión, lo que permite la detección en tiempo real.
  - **Entrada de Datos:** Cada frame capturado por las cámaras estereoscópicas se introduce en el sistema de detección. YOLOV3 procesa estas imágenes y proporciona bounding boxes, que identifican la ubicación y dimensiones aproximadas de cada tronco en la imagen.
  - **Preparación de Datos para el Seguimiento:** Las bounding boxes resultantes, junto con sus correspondientes confianzas o scores de detección, son cruciales, ya que representan la “vista” inicial del sistema sobre donde se encuentran los troncos en cada frame. Estas detecciones son las que luego serán rastreadas a través del tiempo por SORT (Ver Figura 12).



Figura 12: Ejemplo de Detección de Caras de Tronco en INSTALOG
Fuente: Elaboración Propia

- **Modelo de Estimación:** Este segmento se enfoca en desglosar cómo el Modelo de Estimación ataca el problema del seguimiento y estimación de troncos en el algoritmo SORT. Mediante la aplicación del Filtro de Kalman Extendido para la estimación de velocidades, y con ayuda de heurísticas específicas para acercar este algoritmo al caso real de INSTALOG.

  - **Adaptación a Velocidades Variables y Perspectiva de la Cámara:** Antes de abordar la adaptabilidad del modelo ante velocidades variables y la perspectiva de la cámara, es pertinente recordar brevemente la función y relevancia del Filtro de Kalman Extendido (EKF). El EKF es una extensión del Filtro de Kalman, diseñado para sistemas con modelos no lineales. Este método es ampliamente utilizado para estimar el estado de un proceso dinámico de manera óptima, corrigiendo predicciones basadas en mediciones observadas. Su capacidad para manejar no linealidades lo hace especialmente útil en aplicaciones de seguimiento y navegación, donde los movimientos y observaciones no siguen patrones lineales.

    Dado que los troncos sobre el camión tienen velocidades variables y estas cambian conforme el camión se aleja de la cámara, el EKF puede adaptarse para manejar estas variaciones de velocidad y posición. Aunque los cambios en la velocidad y la posición de los troncos no son abruptos, estos son continuos y dependen de la orientación de las cámaras y la distancia al camión. El EKF puede modelar esta dinámica ajustando las predicciones de velocidad y posición para cada tronco individualmente, basándose en su trayectoria observada y la geometría proyectiva de la escena.
  - **Linealización y Modelado de Movimiento:** En el contexto de INSTALOG, las fun-

ciones de estado y medición del EKF se han adaptado específicamente para modelar la relación entre la posición del tronco, su velocidad, y la distancia desde la cámara. Aunque el sistema no enfrenta cambios abruptos en estas variables, la precisión es crucial para estimar las velocidades cambiantes y las trayectorias proyectadas de los troncos. Por ello, se recurre a la linealización de estas funciones, una técnica que permite abordar de manera eficiente las no linealidades leves, típicamente asociadas con la perspectiva de la cámara y el alejamiento de los troncos en movimiento.

Es importante destacar que, aunque no se detallarán nuevamente aquí, las fórmulas y procesos específicos de linealización y modelado utilizados en este contexto se basan en los principios establecidos en la sección del Estado del Arte de este trabajo. Para los interesados en la mecánica detallada de estas operaciones, se recomienda revisar dicha sección, donde se explican con mayor profundidad las ecuaciones y su aplicación en el marco del EKF.

- **Manejo de Incertidumbres y Actualizaciones:** La capacidad del EKF para manejar incertidumbres se muestra especialmente útil en el seguimiento de troncos, donde aspectos como variaciones en la iluminación, oclusiones, detecciones erróneas y la calidad de la imagen pueden introducir incertidumbres significativas. Al realizar actualizaciones de las estimaciones de estado con cada nueva detección, el EKF emplea un proceso de ponderación inteligente que equilibra la información histórica con las nuevas mediciones. Este equilibrio se logra a través de la matriz de covarianza del error en el estado estimado y la información proporcionada por las nuevas mediciones.

La implementación del Filtro de Kalman Extendido en INSTALOG, ajustado para manejar las velocidades variables y los cambios graduales en la posición de los troncos, promete mejorar la precisión y robustez del seguimiento. Al adaptar el EKF a las necesidades específicas de seguimiento de troncos en movimiento, se espera obtener un rendimiento superior en términos de coherencia y fiabilidad en el conteo y seguimiento de troncos.

En el proceso de adaptación del Filtro de Kalman Extendido a las dinámicas específicas de seguimiento de troncos en INSTALOG, es esencial realizar ajustes meticulosos en las matrices de covarianza para reflejar adecuadamente la confianza en las mediciones y en las predicciones del modelo. Este ajuste se lleva a cabo modificando las diagonales de las matrices de covarianza, tanto para las mediciones como para las predicciones, actuando estos valores modificados efectivamente como hiperparámetros. Los números asignados a estas diagonales son determinantes en la ponderación de la confianza del sistema entre las detecciones actuales y las predicciones del modelo de movimiento (Ver Figura 13).

Dada la alta precisión y confiabilidad de las detecciones generadas por YOLOV3 en el sistema, se ha optado por asignar una mayor confianza a estas detecciones en comparación con las predicciones del modelo. Esto se traduce en asignar valores menores en las diagonales de la matriz de covarianza para las mediciones, indicando una alta

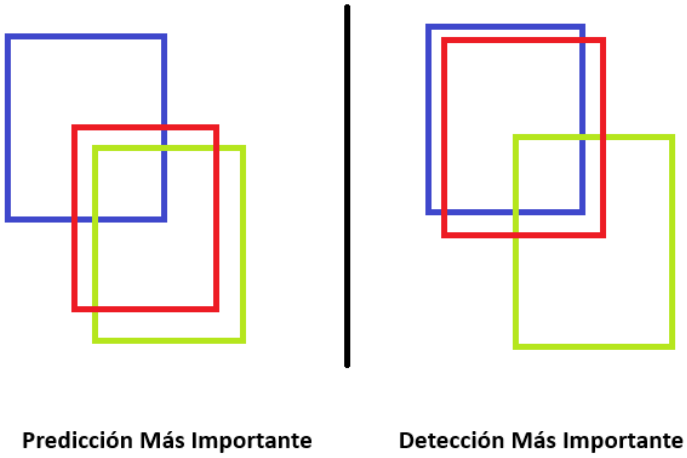


Figura 13: Ejemplo de Ajuste de Covarianzas. Azul: Detección, Verde: Predicción, Rojo: Estado Obtenido.

Fuente: Elaboración Propia

confianza en las detecciones de troncos actuales. Simultáneamente, se mantiene una cautela adecuada hacia las predicciones del modelo, asignando valores con órdenes de magnitud superiores en las diagonales de la matriz de covarianza para el proceso, reflejando así una confianza relativamente menor en estas predicciones.

Este enfoque de priorizar las detecciones sobre las predicciones durante la actualización del estado del tronco permite que el sistema INSTALOG se adapte de manera ágil a los cambios reales observados en la posición y movimiento de los troncos, minimizando el impacto de posibles predicciones inexactas. Como resultado, se consigue un seguimiento más fiable y coherente, esencial para lograr un conteo preciso y una estimación fiable del volumen de troncos.

Es importante destacar que la optimización de las matrices de covarianza no es un proceso estático. Requiere una revisión y ajuste continuos basados en el rendimiento observado del sistema de seguimiento y en el entendimiento progresivo del comportamiento de los troncos. A medida que se acumulan más datos y se adquieren nuevos conocimientos sobre la eficacia del seguimiento, es posible realizar ajustes adicionales para perfeccionar aún más el desempeño del EKF dentro de INSTALOG. Estos ajustes dinámicos garantizan que el sistema se mantenga eficiente y preciso, adaptándose a las cambiantes condiciones y requisitos del entorno operativo real.

En el caso de INSTALOG, se optó por incorporar las siguientes dos heurísticas en el Modelo de Estimación del algoritmo SORT, las cuales permiten mejorar la precisión y eficacia del seguimiento de troncos:

- **Uso de Velocidades de Troncos Adyacentes:** Dado que los troncos en un camión están fijos y mantienen su posición relativa unos con otros, es lógico que sus velocidades y movimientos también estén correlacionados. Esta heurística se basa

en la observación de que, cuando un tronco se mueve, los troncos adyacentes probablemente se muevan de manera similar.

En el modelo de estimación, para cada tronco, se considera no solo su historial de movimiento propio, sino también el movimiento de los troncos adyacentes. Esto permite hacer predicciones más precisas sobre la posición futura de un tronco, especialmente en situaciones donde la detección individual puede ser difícil debido a oclusiones o baja visibilidad.

- **Modelo Basado en Análisis Estadístico del Movimiento:** El modelo matemático basado en análisis estadístico del movimiento de los troncos se concibió tras un meticuloso estudio de las secuencias de imágenes capturadas en 100 bancos de madera distintos. Utilizando una versión menos refinada del algoritmo de seguimiento de este mismo trabajo, se registraron las velocidades de los troncos frame a frame, creando una base de datos extensa sobre su dinámica de movimiento en variadas condiciones.

  Sin embargo, reconociendo las limitaciones inherentes al algoritmo de seguimiento, que en ocasiones fallaba en mantener un rastreo preciso, se procedió a una evaluación manual detallada de cada frame de cada banco de troncos registrado. Este paso crítico aseguró la depuración de la base de datos, eliminando las trayectorias donde los troncos fueron seguidos incorrectamente. La información resultante constituyó un conjunto de datos fiable, compuesto exclusivamente por troncos que fueron monitoreados con éxito y precisión a lo largo de su trayectoria.

  A partir de este conjunto de datos purificado, se desarrollaron dos funciones polinomiales de segundo grado que estiman las velocidades en los ejes X e Y, respectivamente. El cálculo de este modelo se realizó mediante el método de mínimos cuadrados, y las funciones resultantes toman como variables de entrada las posiciones actuales en X e Y de cada tronco y, a través de un cálculo matemático, generan una estimación de la velocidad futura en ambas dimensiones. Este enfoque permite anticipar cómo se moverán los troncos en el corto plazo, una herramienta invaluable especialmente en situaciones donde las detecciones directas son inexistentes o no confiables.

  La integración de este modelo en el sistema de seguimiento se realiza mediante la ponderación de estas estimaciones de velocidad con otras heurísticas ya existentes en INSTALOG. Esto significa que, al predecir la posición futura de un tronco, el sistema no solo considera la información más reciente proporcionada por el algoritmo de seguimiento, sino que también incorpora las predicciones generadas por el modelo estadístico. Esta combinación de datos y predicciones enriquece el proceso de estimación, proporcionando un mecanismo más robusto y fiable para prever la posición futura de los troncos, garantizando así una mayor precisión y coherencia en el seguimiento y conteo de troncos.

- **Asociación de Datos:** La Asociación de Datos es una etapa crítica en el algoritmo SORT y se refiere al proceso de vincular las detecciones de troncos en el frame actual con

las trayectorias existentes. Esta etapa es esencial para mantener la identidad de cada tronco a lo largo de los frames consecutivos. Su desafío radica particularmente en entornos dinámicos, como el seguimiento de troncos en camiones en movimiento, donde las variaciones en la velocidad, junto con posibles oclusiones, complican significativamente el mantenimiento coherente de las identidades de los troncos de un frame a otro.

- **Concepto Básico:** La Asociación de Datos en el contexto del seguimiento de múltiples objetos implica decidir cuáles detecciones corresponden a cuáles trayectorias basadas en la información del estado actual y las mediciones recientes. En el caso de SORT, la asociación se realiza en cada frame y se basa principalmente en la predicción de la ubicación de los troncos y las detecciones actuales proporcionadas por el sistema de visión computarizada.
- **Cálculo de Distancia y Asignación:** Para cada tronco detectado en el frame actual, el sistema calcula la distancia Intersection over Union (IoU) con todas las trayectorias existentes.

  La distancia Intersection over Union (IoU) es una métrica comúnmente utilizada en visión por computadora, especialmente en tareas de detección y seguimiento de objetos. Específicamente en el seguimiento, la IoU es una medida que ayuda a determinar cuán bien se superponen dos bounding boxes (cajas delimitadoras), una que representa la predicción del algoritmo y otra que corresponde a la detección actual.

  La IoU se calcula como el área de la intersección dividida por el área de la unión de las dos cajas delimitadoras. Matemáticamente, si denotamos las dos cajas delimitadoras como A y B, la IoU se calcula como:

$$\text{IoU} = \frac{\text{Área de intersección de } A \text{ y } B}{\text{Área de unión de } A \text{ y } B}$$

  En el contexto de la Asociación de Datos, se calcula la IoU entre cada caja delimitadora de detección y las cajas delimitadoras de las trayectorias existentes. Una IoU alta indica una superposición significativa entre las cajas, sugiriendo una fuerte correspondencia y probable continuidad de una misma trayectoria, lo cual es clave para mantener la identidad correcta de cada objeto a través del tiempo. Por otro lado, una IoU baja señala poca o ninguna superposición, lo que implica que las detecciones probablemente no pertenecen a la misma trayectoria, ayudando a filtrar asociaciones erróneas y optimizando la precisión del seguimiento. Este método es esencial para asegurar un seguimiento preciso y confiable, especialmente en entornos donde los objetos pueden ocluirse mutuamente o moverse rápidamente, garantizando así la continuidad y coherencia de las trayectorias en aplicaciones complejas de visión por computadora.

  En el proceso de Asociación de Datos para el seguimiento de objetos, se emplea el Algoritmo Húngaro [58], un método clásico en optimización combinatorial diseñado para resolver problemas de asignación de manera óptima. Este algoritmo

se aplica para asociar cada detección con la trayectoria existente más adecuada, asegurando que la correspondencia se realice de la forma más eficiente posible. Originariamente desarrollado para abordar asignaciones en un contexto matemático general, el Algoritmo Húngaro ha encontrado una aplicación natural en el campo del seguimiento de objetos, donde facilita la tarea de vincular detecciones a trayectorias manteniendo una alta precisión y minimizando errores de asociación, razones por las cuales los autores de SORT decidieron hacer uso de él.

El algoritmo trabaja sobre una matriz de costos, donde cada elemento de la matriz representa el costo de asignar una detección particular a una trayectoria particular. En el caso de SORT y el seguimiento de troncos, los "costos" suelen basarse en la distancia IoU negativa (o alguna transformación de ella) entre las detecciones y las trayectorias, y es así como se hizo en este trabajo.

El objetivo del Algoritmo Húngaro es encontrar la asignación completa que minimice el costo total. Esto significa que se busca una asignación de detecciones a trayectorias tal que la suma de las distancias IoU (o su equivalente negativo como costos) sea mínima, asegurando que cada detección se asocie con la trayectoria más probable y que cada trayectoria reciba a lo más una detección.

En INSTALOG, después de calcular la IoU para todas las combinaciones posibles de detecciones actuales y trayectorias existentes, el Algoritmo Húngaro se utiliza para resolver el problema de asignación. Como resultado, cada tronco detectado en el frame actual se asocia con la trayectoria más adecuada, manteniendo la continuidad del seguimiento a lo largo del tiempo.

La etapa de "Asociación de Datos" en el seguimiento de troncos mediante el algoritmo SORT es fundamental para mantener la continuidad y precisión en la identificación de cada tronco a lo largo de los frames. Sin embargo, esta tarea se ve complicada significativamente por la proximidad de los troncos entre sí y las posibles obstrucciones que pueden ocurrir durante el seguimiento. Estos desafíos pueden distorsionar la percepción de las trayectorias de los troncos y provocar errores en la asociación. A continuación, se profundizará en cómo la proximidad de los troncos y las obstrucciones presentan retos particulares en la Asociación de Datos y las estrategias para mitigarlos.

La proximidad entre troncos puede llevar a que las bounding boxes de troncos adyacentes se solapen o estén muy cerca, complicando la tarea de distinguir entre troncos individuales. Además, las oclusiones, ya sean temporales (por el paso de un tronco frente a otro) o más permanentes (como sombras profundas o áreas ocultas por la disposición de los troncos), pueden hacer que un tronco desaparezca temporalmente de la vista o alterar su apariencia visual en la secuencia de imágenes.

Estos factores aumentan la complejidad del problema de asignación de datos en el algoritmo SORT, donde se requiere una asociación precisa para mantener la continuidad en el seguimiento de cada tronco a lo largo del tiempo. La proximidad y las obstrucciones pueden llevar a múltiples asociaciones plausibles para una detección dada, especialmente cuando los troncos están ocultos.

Para optimizar el proceso de Asociación de Datos y mitigar casos de asignaciones incorrectas, se ajusta cuidadosamente un parámetro clave: el umbral de IoU. Este umbral determina el grado de superposición necesario entre una detección y una trayectoria existente para considerar que pertenecen a la misma entidad. Ajustar el umbral de IoU permite adaptar el proceso de seguimiento a las particularidades del problema específico en cuestión, como es el seguimiento de troncos en INSTALOG. Este enfoque garantiza que la asociación entre detecciones y trayectorias se realice de manera óptima, enfocándose en el equilibrio preciso entre la sensibilidad y la especificidad requeridas para el conteo y seguimiento efectivo de los troncos.

Al aumentar el umbral de IoU, el algoritmo se vuelve más restrictivo y solo asocia detecciones a trayectorias cuando hay una superposición significativa. Esto puede ser útil en escenarios donde los troncos están muy juntos y hay un alto riesgo de asociaciones incorrectas debido a la proximidad. Un umbral más alto puede reducir los falsos positivos pero también puede aumentar los falsos negativos.

Disminuir el umbral de IoU hace que el algoritmo sea más permisivo, permitiendo asociaciones incluso con menor grado de superposición. Esto puede ser beneficioso en situaciones donde los troncos son parcialmente ocluidos o cuando sus bounding boxes cambian de tamaño o forma debido a la perspectiva. Sin embargo, un umbral demasiado bajo puede llevar a más asociaciones incorrectas, especialmente en entornos densos.

Ajustar el umbral de IoU implica encontrar un equilibrio entre la precisión de las asociaciones y la robustez del seguimiento ante variaciones y oclusiones. Se busca optimizar tanto la tasa de verdaderos positivos (correctas asociaciones) como minimizar los falsos positivos y negativos.

- **Creación y Eliminación de Identidades de Seguimiento:** El paso de “Creación y Eliminación de Identidades de Seguimiento” en el algoritmo SORT es vital para manejar dinámicamente las trayectorias de los troncos a lo largo del tiempo en el sistema INSTALOG. Este proceso involucra dos aspectos clave: la iniciación de nuevas trayectorias para troncos recién detectados y la terminación de trayectorias cuando ya no son relevantes. Aquí se explica en detalle cómo funciona este paso:

  - **Creación de Nuevas Identidades:** Cuando una detección de tronco no se puede asociar a ninguna trayectoria existente, se considera que este tronco es nuevo en la escena. En este caso, se crea una nueva identidad de seguimiento para este tronco. Esto implica iniciar una nueva trayectoria con su propia historia de posiciones y velocidades, basada en las mediciones iniciales.

    Este proceso es crucial para asegurar que todos los troncos presentes en la imagen sean rastreados, incluso aquellos que acaban de entrar en el campo de visión de la cámara.

  - **Eliminación de Identidades Antiguas:** La eliminación de una trayectoria ocurre cuando un tronco ha dejado de ser visible o detectable durante un periodo prolongado. Si una trayectoria no recibe asociaciones con detecciones nuevas en va-

rios frames consecutivos, se considera que el tronco correspondiente ha salido del campo visual, está completamente ocluido o debido a errores en las predicciones está en un lugar de la imagen que no le permite ser asociado nuevamente.

La trayectoria se elimina del sistema para evitar el seguimiento de troncos inexistentes o erróneos, lo que es esencial para mantener la precisión y eficiencia del sistema de seguimiento

Dada la naturaleza dinámica del seguimiento de troncos, las decisiones sobre cuando iniciar o terminar una trayectoria deben equilibrar la necesidad de capturar troncos nuevos y la importancia de eliminar las trayectorias inactivas para mantener la eficiencia del sistema.

La implementación del algoritmo SORT en INSTALOG incorpora parámetros que permiten un control refinado sobre la creación y eliminación de identidades de seguimiento. Estos parámetros son esenciales para ajustar el algoritmo a las especificidades del seguimiento de troncos en camiones. Los dos parámetros principales son:

- **Mínimas Ocurrencias:** Este parámetro define el número mínimo de frames consecutivos en los que una identidad debe aparecer para ser considerada válida. Aumentar este valor puede reducir los falsos positivos, evitando que detecciones erróneas momentáneas se conviertan en trayectorias. Sin embargo, un valor demasiado alto podría excluir troncos que son rápidamente ocluidos después de su primera aparición.

  A pesar de que los valores sugeridos para este parámetro puedan variar dependiendo de las especificidades del problema de seguimiento en cuestión, se sugiere empezar con valores alrededor de 3 Mínimas Ocurrencias, lo que implicaría que una detección necesitaría ser confirmada en al menos tres frames consecutivos para que la trayectoria sea considerada válida y no sea eliminada prematuramente.

  En la implementación actual, se optó por un valor menor al sugerido para “Mínimas Ocurrencias”. Esto se debe a que es común que los troncos aparezcan en un frame pero no sean detectados en el siguiente. Un valor bajo permite capturar estos troncos antes de que sean ocluidos, aunque conlleva un riesgo ligeramente mayor de falsos positivos.
- **Vida Máxima:** Este parámetro determina el número máximo de frames que una trayectoria puede persistir sin asociarse a nuevas detecciones antes de ser eliminada. Un valor más alto para “Vida Máxima” es beneficioso en situaciones donde las oclusiones son prolongadas, como es típico en el caso de los bancos de madera en camiones. Esto permite que las trayectorias de troncos ocluidos se mantengan activas durante más tiempo, aumentando la probabilidad de que sean correctamente retomadas una vez que la obstrucción se resuelva. Pero un valor muy alto puede también llevar a casos en los que se mantengan trayectorias erróneas que no deberían seguir siendo consideradas, generando situaciones en las que pueda afectar a un conteo de troncos efectivo.

En cuanto a los valores sugeridos para este parámetro, es recomendado que sea cercano a 3 también, al igual que el de Mínimas Ocurrencias. Este valor indica cuántos frames consecutivos un objeto puede ser no detectado antes de que su trayectoria sea descartada.

Para este trabajo, se seleccionó un número cercano de frames a lo sugerido para la “Vida Máxima”, equilibrando así la necesidad de mantener troncos activos en el seguimiento frente a la posibilidad de mantener trayectorias innecesarias.

Una vez completados los pasos de seguimiento y asociación de troncos en el algoritmo SORT, el proceso continúa en funcionamiento hasta detectar el fin de un banco de troncos. Esto se determina mediante la observación de la cantidad de detecciones de troncos: cuando el número de detecciones deja de aumentar durante varios frames consecutivos, se asume que se ha alcanzado el máximo local de troncos en ese banco particular.

En concordancia con la implementación previa en INSTALOG, el frame que contiene el mayor número de bounding boxes dentro de un banco de madera se selecciona para realizar el conteo final. El número de estas bounding boxes se utiliza como la estimación del número total de troncos en ese banco. Este enfoque garantiza que el conteo se base en el frame más informativo y completo disponible, lo que ayuda a maximizar la precisión del conteo de troncos, a pesar de las variaciones y oclusiones que puedan ocurrir a lo largo de la secuencia de imágenes.

La propuesta de solución detallada en este capítulo representa un avance significativo para el sistema INSTALOG, abordando una necesidad crítica dentro de la industria maderera por mejorar el conteo y seguimiento de troncos. La integración del algoritmo SORT no solo promete aumentar la precisión en la estimación del conteo de los troncos transportados, sino también ofrecer una base robusta para futuras mejoras y adaptaciones conforme evolucionen las necesidades y tecnologías disponibles. Esta solución no solo destaca la importancia de un enfoque sistemático y basado en criterios claros para la selección de algoritmos, sino que también subraya el valor de la adaptabilidad y la integración técnica para implementar innovaciones tecnológicas en contextos industriales complejos.

CAPÍTULO 5
VALIDACIÓN DE LA SOLUCIÓN

Este capítulo se dedica a la evaluación detallada de la solución propuesta implementada en el sistema INSTALOG, destinada a mejorar el seguimiento y conteo de troncos en camiones de carga. A través de un conjunto de pruebas experimentales, se examinó la solución en una variedad de escenarios que simulan condiciones operativas realistas enfrentadas por el sistema. Estos escenarios incluyeron diversas configuraciones de carga y la presencia de oclusiones, para evaluar la robustez y adaptabilidad del sistema. Se puso especial atención en la evaluación de parámetros críticos del algoritmo de seguimiento, tales como el umbral de IoU, las mínimas ocurrencias necesarias para validar una trayectoria, la vida máxima permitida para las trayectorias sin detecciones asociadas y las ponderaciones que se le dieron a las diversas heurísticas de predicción de velocidad. A pesar de las expectativas, los resultados revelaron desafíos en alcanzar mejoras significativas en la precisión del seguimiento y conteo, subrayando la complejidad del problema y la sensibilidad del sistema a las condiciones del entorno. Este capítulo proporciona una visión completa del proceso de validación, desde la metodología empleada hasta el análisis de los resultados cuantitativos y cualitativos, destacando tanto los logros como las limitaciones de la solución actual. Se discuten las implicancias de estos hallazgos para el desarrollo futuro de INSTALOG, identificando áreas clave para la mejora continua y la investigación adicional.

5.1. Escenario Experimental

Para el escenario experimental, se utilizó un Notebook Lenovo modelo LOQ 15APH8, dotado de un procesador AMD Ryzen 7 7840HS, 16 GB de RAM DDR5 a 5600MHz, y un SSD de 512 GB M.2 2242 PCIe Gen4 TLC. El software empleado comprende C++ para la implementación del algoritmo, y Python para la recopilación y análisis de datos, aprovechando su flexibilidad y las bibliotecas de análisis de datos. Se utilizan dos cámaras estereoscópicas, situadas una a cada lado de un portal con un ángulo específico, generando cuatro imágenes por frame, capturando así la dinámica completa de los troncos. Este entorno reproduce diversas condiciones ambientales, incluyendo variaciones de luz diurna y nocturna, y enfrenta al algoritmo a troncos de diferentes tamaños y cantidades, algunos bancos de troncos presentan troncos grandes, pequeños o una combinación de ambos, todo esto gracias a utilizar eventos reales.

5.2. Recopilación de Datos

En esta sección, se detalla el proceso de recopilación y evaluación de datos empleados para validar la precisión del conteo preexistente de troncos en camiones, sin la aplicación del algoritmo de seguimiento mejorado propuesto en este trabajo. Se seleccionaron al azar 100

eventos, cada uno representando un banco de madera individual, para analizar la efectividad del sistema de detección original.

La evaluación se centró en comparar el conteo automático del sistema preexistente con conteos manuales, considerados como referencia. De los 100 bancos de madera evaluados, se encontró que en 48 casos el conteo fue correcto, mientras que en 52 casos el conteo fue incorrecto (Véase Tabla 2). Estos resultados subrayan la necesidad de implementar mejoras en la capacidad del sistema para contar troncos de manera precisa.

Categoría de Evento	**Número de Eventos**
Conteo Correcto	48
Conteo Incorrecto	52

Tabla 2: Número de bancos de troncos evaluados según la precisión del conteo de troncos que entrega la detección en INSTALOG.
Fuente: Elaboración Propia

5.3. Selección y Ajuste de Hiperparámetros

En el desarrollo del algoritmo para el seguimiento efectivo de troncos, la selección y ajuste de hiperparámetros representa un pilar fundamental para asegurar la precisión y eficacia del sistema. Debido a la naturaleza específica de la aplicación y la ausencia de valores de referencia o benchmarks establecidos en la literatura, el proceso de ajuste de estos hiperparámetros se llevó a cabo de manera empírica y manual. Esta aproximación fue dictada por las limitaciones inherentes al proyecto, incluyendo la falta de un conjunto de datos con anotaciones exhaustivas que permitieran un ajuste automático mediante técnicas convencionales como la validación cruzada o la búsqueda de cuadrícula.

El procedimiento para el ajuste manual de los hiperparámetros, que incluye al umbral de intersección sobre unión (IoU), la vida máxima, la mínima cercanía de troncos, y la ponderación de las predicciones de velocidad, se basó en la observación detallada y la evaluación del impacto de cada variación en el seguimiento y la identificación de troncos. Para cada hiperparámetro, se realizaron ajustes incrementales, evaluando sistemáticamente cómo estos cambios influían en la capacidad del algoritmo para mantener un seguimiento coherente y preciso a lo largo de las secuencias de imágenes.

Un aspecto clave en este proceso fue la definición de criterios específicos de evaluación visual, que permitieron determinar la efectividad del algoritmo en diferentes configuraciones. Estos criterios incluyeron la coherencia en el seguimiento de troncos a través de las imágenes, la minimización de identificaciones erróneas y la habilidad del algoritmo para manejar oclusiones.

- **Umbral de Intersección sobre Unión (IoU):** Este hiperparámetro determina el grado

de superposición necesario entre las bounding boxes en la etapa de asociación para considerar que un tronco en un frame sigue siendo el mismo tronco en el siguiente frame. Un umbral adecuadamente ajustado minimiza los falsos positivos y negativos, especialmente importante en situaciones donde los troncos pueden ocluirse parcialmente entre sí o cambiar rápidamente de posición relativa. En el caso de este trabajo se llego a la conclusión de que un valor alto de este umbral, igual a un 90 %, daba los mejores resultados, debido a que de esta forma se estaría siendo más permisivos a la hora de asociar bounding boxes, lo cual es útíl en casos de que las predicciones no sean muy precisas.

- **Vida Máxima:** Este parámetro, crucial para equilibrar la tenacidad de las trayectorias de seguimiento con la precisión en la identificación de troncos, define el límite de frames consecutivos durante los cuales un tronco puede permanecer no detectado antes de considerar que su trayectoria ha concluido. Dado este contexto, se optó por asignar un valor pequeño al parámetro de "Vida Máxima". En los experimentos finales, la configuración con una "Vida Máxima" de 2 frames demostró ofrecer los mejores resultados en términos de balance entre la precisión del seguimiento y la minimización de trayectorias falsas o erróneas. Sin embargo, también se realizaron pruebas con un valor de "Vida Máxima" de 3 frames. Estas pruebas resultaron ser particularmente reveladoras, ya que permitieron identificar y visualizar de manera más clara los desafíos y limitaciones del algoritmo, especialmente en lo que respecta a las predicciones de velocidad de los troncos.

  La elección de un valor de "Vida Máxima" más conservador se alinea con el objetivo de priorizar la precisión y confiabilidad del seguimiento en el contexto operativo de INSTALOG. Este enfoque permite mantener la continuidad en el seguimiento de los troncos a través de oclusiones temporales y limitar el impacto de las predicciones imprecisas en la calidad general del seguimiento.

- **Mínima Cercanía de Troncos:** Dentro de las heurísticas adicionales implementadas en el algoritmo, una particularmente relevante es el uso de velocidades de troncos adyacentes, la cual se guía por un parámetro específico: la distancia mínima necesaria entre los centros de dos troncos para que se consideren adyacentes. La calibración de este parámetro es esencial, ya que influye directamente en cómo el algoritmo interpreta y utiliza la información de proximidad entre troncos para mejorar las predicciones de movimiento.

  Un valor demasiado alto para este parámetro implicaría considerar prácticamente todos los troncos como adyacentes, ignorando el hecho de que su movimiento puede variar significativamente dependiendo de su ubicación en el camión. Esto podría resultar en predicciones de movimiento inexactas, al asumir incorrectamente que troncos distantes se mueven de manera similar. Por otro lado, un valor demasiado bajo limitaría excesivamente la cantidad de troncos considerados adyacentes, reduciendo la capacidad del algoritmo para aprovechar información valiosa sobre la dinámica grupal de los troncos, y potencialmente basando sus cálculos en un conjunto de datos insuficientemente representativo.

Tras una serie de experimentos destinados a encontrar el equilibrio óptimo, se determinó que un valor de 200 píxeles para la distancia mínima entre los centros de los troncos ofrece la mejor combinación de precisión y utilidad. Este valor permite al algoritmo distinguir adecuadamente entre troncos adyacentes y no adyacentes, teniendo en cuenta las variaciones en su movimiento relativo y asegurando que las predicciones de velocidad se basen en una representación fiable de las condiciones reales en el camión.

- **Ponderación de las Predicciones de Velocidad:** Una faceta crucial en la afinación del algoritmo involucra la ponderación asignada a las distintas heurísticas de predicción de velocidad, que determina la contribución relativa de cada una al resultado final del seguimiento. Esta decisión es vital para asegurar que el algoritmo se beneficie de forma equilibrada de los distintos enfoques de predicción, ajustando su comportamiento para maximizar la precisión global del seguimiento.

  Después de un proceso exhaustivo de evaluación y pruebas, se estableció que la asignación más efectiva de ponderaciones para nuestro contexto específico es la siguiente: un 40 % de la influencia en las predicciones finales se otorga a los resultados obtenidos a través de los filtros de Kalman. Esta elección se basa en la solidez y fiabilidad de los filtros de Kalman para proporcionar estimaciones de movimiento consistentes y fundamentadas en el análisis predictivo de trayectorias.

  Paralelamente, se asignó otro 40 % de la ponderación al uso de velocidades de troncos adyacentes. Esta heurística, que explota la correlación espacial entre los movimientos de troncos cercanos, se ha demostrado particularmente valiosa en escenarios donde las dinámicas grupales de los troncos influyen significativamente en su comportamiento individual, permitiendo una modelación más fiel de las tendencias de movimiento en el conjunto de troncos.

  El restante 20 % se destina al modelo basado en análisis estadístico del movimiento. Aunque esta aproximación ofrece insights valiosos y complementarios, especialmente al modelar patrones generales de movimiento, se consideró que su contribución debería ser menor en comparación con las otras dos heurísticas, equilibrando así la adaptabilidad inmediata del filtro de Kalman y la relevancia contextual del análisis de troncos adyacentes.

  Este esquema de ponderación refleja un balance deliberado, diseñado para integrar las fortalezas individuales de cada método de predicción de velocidad mientras se minimizan sus limitaciones. Al otorgar un mayor peso a los filtros de Kalman y al uso de velocidades de troncos adyacentes, el algoritmo aprovecha tanto el análisis predictivo como la contextualización espacial para generar estimaciones de movimiento precisas y contextualmente informadas.

El proceso de ajuste descrito permitió alcanzar un equilibrio entre la precisión del seguimiento y la eficiencia operativa del sistema. Este enfoque empírico, aunque laborioso, ha

sido esencial para adaptar el algoritmo a las especificidades del entorno de la aplicación, logrando así un buen rendimiento y demostrando la adaptabilidad y robustez del sistema de seguimiento.

5.4. Análisis de Resultados

En el proceso de validación de la solución para el seguimiento de troncos en camiones mediante el sistema INSTALOG, emprendemos un análisis crítico no solo para evaluar la eficacia del seguimiento, sino también para comprender cómo este influye en la precisión del conteo de troncos en comparación con un método que no emplea seguimiento. Este análisis es esencial para identificar cómo la implementación del algoritmo SORT, con sus configuraciones de hiperparámetros específicas, mejora o afecta la capacidad de contar troncos de manera precisa y fiable.

Es importante señalar que, aunque el seguimiento de troncos es relativamente independiente de las variaciones de iluminación y clima, algunos problemas en el seguimiento pueden originarse en detecciones deficientes, como la identificación incorrecta de troncos donde no existen. Este aspecto subraya la interconexión entre la detección precisa y el seguimiento efectivo, enfatizando la importancia de considerar la calidad de las detecciones iniciales en nuestro análisis.

Para este estudio, se ha optado por centrarnos en una configuración específica de hiperparámetros que ha demostrado ofrecer los mejores resultados, particularmente utilizando un valor de “Vida Máxima” de 2 frames. Adicionalmente, se explorará una configuración con una “Vida Máxima” de 3 frames, no con el objetivo de comparar rendimientos, sino para ilustrar de manera más explícita los desafíos y limitaciones inherentes al algoritmo, especialmente aquellos relacionados con las predicciones de velocidad y la gestión de trayectorias.

La justificación para la selección de una “Vida Máxima” de 2 frames en lugar de 3 frames se abordará detalladamente tras la presentación de los resultados obtenidos. Este enfoque permitirá examinar con mayor precisión el impacto de cada configuración en los datos, facilitando la compresión del efecto de cada uno de los ajustes.

Este enfoque selectivo permite profundizar en el comportamiento del algoritmo bajo condiciones de operación óptimas, al mismo tiempo que proporciona insights valiosos sobre los aspectos que requieren atención y ajuste. A través de este análisis, se aspira a ofrecer una visión integral de la solución implementada, destacando tanto sus fortalezas como las áreas potenciales para futuras mejoras.

5.4.1. Metodología de Evaluación

La evaluación del algoritmo SORT para el seguimiento de troncos en camiones se basó en una metodología que combina análisis cuantitativos y cualitativos para determinar la precisión del conteo de troncos y la calidad del seguimiento. Para ello, se comparó el conteo de troncos detectados con y sin el uso del seguimiento contra un conteo manual, considerado como el valor real.

- **Análisis Cuantitativo:** El análisis cuantitativo implicó la recopilación de datos sobre el número de troncos detectados por la cámara (sin seguimiento) y el número de troncos rastreados (con seguimiento), comparándolos con el conteo real obtenido manualmente. Las diferencias entre estos conteos se analizaron estadísticamente para identificar tendencias en la precisión del conteo, utilizando métricas como la media y la desviación estándar de las diferencias en el conteo.
- **Análisis Cualitativo:** El análisis cualitativo se centró en la revisión manual de las bounding boxes generadas por el algoritmo en frames específicos, especialmente en aquellos eventos donde se encontraba alguna diferencia en el conteo. Este análisis permitió clasificar los eventos en categorías según la calidad de las detecciones y el seguimiento: “Mejora”, “Empeora”, y “Variabilidad Mixta” basándonos en la correspondencia de las bounding boxes con troncos reales y su impacto en la precisión del conteo.

5.4.2. Resultados Cuantitativos

La evaluación cuantitativa proporciona una perspectiva inicial sobre el impacto del algoritmo SORT en la precisión del conteo de troncos, comparando los conteos detectados sin seguimiento y con seguimiento frente a los conteos reales. Sin embargo, es crucial interpretar estos resultados con cautela, dado que los números pueden no reflejar completamente la complejidad y calidad del seguimiento.

De los eventos analizados, se observó una predominancia de resultados clasificados como “iguales” con un total de 81 ocurrencias, lo que indica que en la mayoría de los casos el conteo de troncos realizado con el algoritmo de seguimiento no varió del conteo realizado sin seguimiento. Este resultado puede ser interpretado de dos maneras: por un lado, sugiere que el algoritmo de seguimiento mantiene una consistencia en el conteo; por otro lado, plantea preguntas sobre la eficacia del seguimiento para corregir errores de detección específicos.

La categoría “Mejor” recibió un número relativamente menor de eventos, con un total de 14, lo que indica casos donde el seguimiento habría logrado ajustar el conteo de troncos más cerca del número real. Sin embargo, esta mejora no fue universal, destacando la variabilidad en el rendimiento del algoritmo bajo diferentes condiciones.

Los eventos clasificados como “Peor” representan los casos en los que el seguimiento introdujo errores adicionales en el conteo, alejándolo del valor real. Aunque estos casos fueron los menos frecuentes, sumando solo 5 eventos, su existencia es crucial para identificar las limitaciones del algoritmo y las áreas específicas que requieren mejora.

La evaluación cuantitativa del desempeño del algoritmo SORT en la precisión del conteo de troncos se enriquece al examinar las sumas y medias específicas derivadas de los datos. Estas métricas pueden mostrar información valiosa sobre el impacto global del seguimiento y permiten una interpretación más matizada de los resultados.

- **Suma Total de la Comparación con Detección:** Esta suma refleja la discrepancia acumulada entre el número de troncos detectados sin seguimiento y el conteo real a través de todos los eventos analizados. Un valor de -84 indica que, en general, el sistema sin seguimiento subestimó el número de troncos en comparación con el conteo real. Esta subestimación acumulada sugiere áreas donde el sistema de detección inicial podría requerir ajustes o mejoras para aumentar su precisión.
- **Suma Total de la Comparación con Seguimiento:** Similar a la suma anterior, pero para los conteos con seguimiento, donde un valor de -54 muestra una mejora en la precisión del conteo al aplicar el algoritmo de seguimiento. Esta mejora podría indicar que el seguimiento ayuda a corregir algunas de las deficiencias de la detección inicial, acercando el conteo más al valor real.
- **Media de Comparación con Detección:** Una media de -0.8 refleja la discrepancia promedio por evento entre el conteo detectado sin seguimiento y el conteo real. Esta cifra resalta la precisión general y los límites de la detección sin seguimiento.
- **Media de la Comparación con Seguimiento:** Con una media de -0.5, sugiere una mejora en la precisión del conteo de troncos cuando se aplica el seguimiento, comparado con la detección sin seguimiento. Este ajuste en la media refleja una menor discrepancia promedio por evento entre el conteo con seguimiento y el conteo real, indicando que el seguimiento tiene un impacto positivo en la precisión del conteo, aunque existen margen de error y oportunidades para la mejora.

Se ha elaborado una tabla que facilita la visualización de los resultados cualitativos de forma más resumida (ver Tabla 3). Adicionalmente, los resultados específicos de cada evento están disponibles en la sección de anexos, específicamente en las tablas 8, 9 y 10. En estas tablas, se observa que en ciertos casos no se llevó a cabo el conteo para bancos específicos dentro de algunos eventos. Este fenómeno se debe a las limitaciones del algoritmo de detección actual, el cual no inicia el conteo de un banco a pesar de identificar algunos troncos, debido a que se requiere una cantidad mínima de estos para activar dicha inicialización. Esta situación ocurre en dos ocasiones, correspondientes a los eventos C3B1 y C6B1, los cuales no se incluyeron en el conteo debido a la detección insuficiente de troncos. Aunque esto es ajeno al algoritmo de

seguimiento y, por tanto, no afecta directamente al análisis, es relevante mencionarlo para contextualizar adecuadamente los resultados observados.

En el análisis detallado de cada evento presentado en las tablas anteriormente mencionadas, se realiza una comparación entre el conteo real de troncos y los conteos obtenidos a través de la detección y el seguimiento de troncos. Esto permite evaluar qué tan precisas son estas mediciones respecto a la cantidad real de troncos. Los valores negativos indican que se detectaron menos troncos de los que realmente hay, mientras que los valores positivos muestran un conteo superior al real. Por ende, cuanto más cercano sea el resultado a cero, mayor será la precisión de la medición.

Utilizando estos valores, se efectúa una comparación adicional entre las diferencias obtenidas en los conteos detectados y los conteos con seguimiento. El objetivo es determinar cuál de las dos mediciones está más cerca de cero, es decir, cuál es más precisa. A partir de esta comparación, se categoriza el rendimiento del algoritmo de seguimiento en cada evento, determinando si este mejoró, empeoró o no tuvo efecto sobre la precisión del conteo en comparación con el uso exclusivo de las detecciones.

Métrica	**Valor**
Eventos Iguales	81
Eventos Mejores	14
Eventos Peores	5
Suma Total Comparación con Detección	-84
Suma Total Comparación con Seguimiento	-54
Media Comparación con Detección	-0.8
Media Comparación con Seguimiento	-0.5

Tabla 3: Resumen de Resultados Cuantitativos del Algoritmo de Seguimiento - Vida Máxima = 2

Fuente: Elaboración Propia.

En relación a los resultados obtenidos para el algoritmo con una Vida Máxima de tres frames (ver Tablas 4, 11, 12, y 13), se registraron 69 eventos catalogados como 'Iguales'. Esta cifra es inferior a los 81 eventos 'Iguales' obtenidos con el algoritmo con Vida Máxima de dos frames, lo que sugiere que un aumento en la Vida Máxima impacta significativamente en la volatilidad del conteo de troncos.

Además, se observó un aumento en la cantidad de eventos 'Mejores', alcanzando un total de 20 eventos, lo que representa seis eventos más en comparación con la Vida Máxima de dos frames. Sin embargo, también se incrementó el número de eventos 'Peores' a 11, aumentando igualmente en seis eventos respecto a la configuración anterior.

Los resultados de la Suma Total y Media de Comparaciones indican que, en general, ahora se están contando más troncos que con la Vida Máxima de dos frames, ya que estos valores están más próximos a cero. A pesar de que los resultados muestran tanto mejoras como

empeoramientos en cantidades iguales en comparación con el algoritmo de Vida Máxima de dos frames, es crucial para este sistema, que tiene como objetivo optimizar el conteo de troncos, minimizar los casos en que se empeora el conteo. Por ello, se ha decidido continuar con el uso del algoritmo de Vida Máxima de dos frames para análisis más detallados.

Métrica	**Valor**
Eventos Iguales	69
Eventos Mejores	20
Eventos Peores	11
Suma Total Comparación con Detección	-84
Suma Total Comparación con Seguimiento	-34
Media Comparación con Detección	-0.8
Media Comparación con Seguimiento	-0.3

Tabla 4: Resumen de Resultados Cuantitativos del Algoritmo de Seguimiento - Vida Máxima = 3

Fuente: Elaboración Propia.

La distribución de los resultados entre las categorías de mejora, empeoramiento e igualdad subraya la complejidad inherente al seguimiento de troncos y la necesidad de un análisis cualitativo detallado para complementar estos hallazgos cuantitativos. Aunque la evaluación numérica indica una tendencia hacia una precisión mejorada en el conteo de troncos con el seguimiento, la presencia de resultados variados y la predominancia de casos “iguales” sugieren que el éxito del algoritmo puede ser más matizado. Este análisis cuantitativo proporciona un punto de partida esencial para investigaciones más profundas sobre la calidad y precisión del seguimiento, lo cual se realizará a continuación.

5.4.3. Resultados Cualitativos

La evaluación cualitativa de este análisis se enfoca en los casos que, según la evaluación cuantitativa, resultaron en un desempeño “Mejor” o “Peor” en términos de precisión de conteo, en comparación con el método de conteo basado únicamente en detecciones. Esta decisión se fundamenta en la premisa de que la predicción siempre debería ofrecer un conteo igual o superior al obtenido solo mediante detecciones. Por lo tanto, cualquier caso clasificado como “Igual” se interpreta como una situación en la que las bounding boxes se ubican en posiciones aproximadamente similares a las de las detecciones originales, sin agregar valor significativo al proceso de seguimiento. Aunque de todas formas estos casos funcionan como un indicador de que el algoritmo al menos no afecta de mala manera a una gran cantidad de casos.

Para los casos categorizados como “Mejor” o “Peor”, se realizó una revisión detallada de cada evento para examinar el comportamiento y la colocación de las bounding boxes generadas por las predicciones. Este examen meticuloso tiene como objetivo determinar si las mejoras

numéricas observadas en el conteo reflejan verdaderas mejoras en la precisión y relevancia de las detecciones o si, por el contrario, las bounding boxes adicionales no están justificadas por la presencia real de troncos. Lo cual es esperable que ocurra debido a que se trata de un sistema que está en sus etapas iniciales de desarrollo, por lo cual las predicciones pueden no llegar a ser completamente correctas.

La forma en que se realizó este análisis fue mediante las imágenes de debug generadas por el algoritmo, las cuales se dividen en seis partes distintas, describiendo cada etapa del proceso de seguimiento y detección:

Descripción de las Imágenes de Debug:

- **Estado Inicial:** Se ilustran las bounding boxes del frame anterior en color rojo, cada una con su propio ID, proporcionando un contexto inicial para el seguimiento (Ver Figura 14).

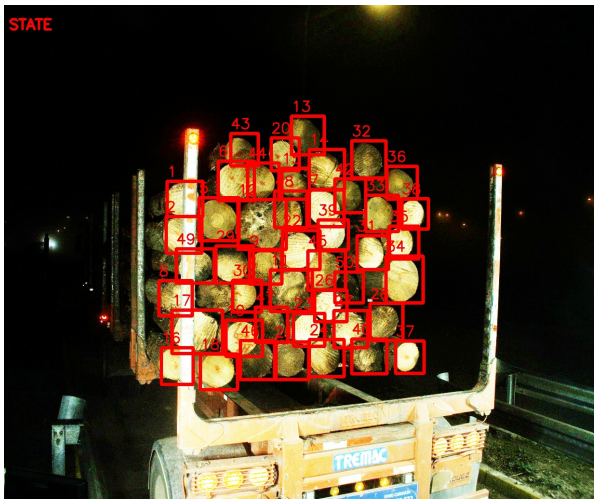


Figura 14: Ejemplo de Visualización Cualitativa Estado Inicial.
Fuente: Elaboración Propia.

- **Estado Inicial + Predicciones:** Avanzamos un frame, mostrando tanto el estado anterior en rojo como las predicciones de cada una de las bounding boxes en verde, ofreciendo una vista previa de los movimientos esperados (Ver Figura 15).



Figura 15: Ejemplo de Visualización Cualitativa Estado Inicial y Predicciones.
Fuente: Elaboración Propia.

- **Predicciones y Observaciones:** En el frame actual, se presentan las predicciones en verde y las detecciones de bounding boxes en azul, realizadas por el algoritmo de detección, destacando la interacción entre predicciones y detecciones reales (Ver Figura 16).

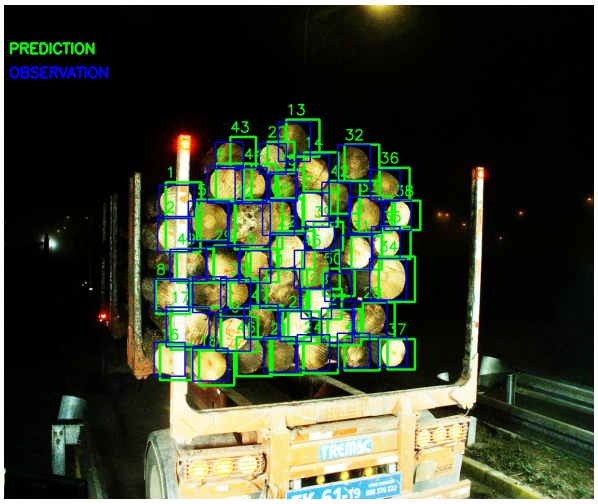


Figura 16: Ejemplo de Visualización Cualitativa Predicciones y Observaciones.
Fuente: Elaboración Propia.

- **Asociaciones:** Este paso muestra cómo se han asociado las predicciones con las observaciones, utilizando el mismo color para las bounding boxes asociadas, blanco para las predicciones no asociadas y negro para las detecciones no emparejadas, clarificando el resultado de la asociación (Ver Figura 17).

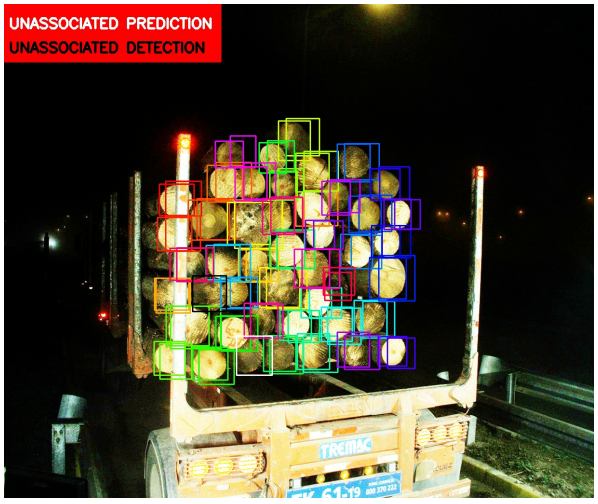


Figura 17: Ejemplo de Visualización Cualitativa Asociaciones.
Fuente: Elaboración Propia.

- **Nuevo Estado + Predicciones y Observaciones:** Se exhibe el nuevo estado logrado tras las asociaciones, junto con las predicciones y observaciones, facilitando la comprensión de la evolución hacia el estado final (Ver Figura 18).



Figura 18: Ejemplo de Visualización Cualitativa Nuevo Estado, Predicciones y Observaciones. Fuente: Elaboración Propia.

- **Nuevo Estado:** Finalmente, se muestra el nuevo estado obtenido, similar a cómo se presentó el Estado Inicial, cerrando el ciclo y preparando el algoritmo para continuar con los siguientes frames (Ver Figura 19).



Figura 19: Ejemplo de Visualización Cualitativa Nuevo Estado, Predicciones y Observaciones. Fuente: Elaboración Propia.

A través del análisis, se identificaron ejemplos específicos que ilustran la variedad de situaciones encontradas, las cuales se clasificarán en las siguientes categorías:

- **Mejora:** En esta categoría se incluyen los eventos en los cuales las bounding boxes generadas por el algoritmo de seguimiento representan una adición positiva y precisa, identificando correctamente troncos que no fueron detectados inicialmente o mejorando la precisión de las detecciones existentes. Estos casos demuestran la capacidad del algoritmo para añadir valor real al proceso de detección y seguimiento, aumentando la precisión global del conteo.
- **Empeora:** Aquí se agrupan los eventos en los que las bounding boxes generadas por el seguimiento resultan ser inexactas o irrelevantes, marcando áreas sin troncos reales. Estos casos señalan limitaciones en el algoritmo, donde el seguimiento introduce errores que pueden afectar negativamente la precisión del conteo y la confiabilidad de las detecciones.
- **Variabilidad Mixta:** Esta categoría se reserva para eventos donde se observa una mezcla de resultados: algunas bounding boxes generadas por el seguimiento son precisas y mejoran el conteo, mientras que otras son incorrectas. Estos casos reflejan la complejidad del entorno operativo y las dificultades inherentes al seguimiento de troncos, destacando la necesidad de equilibrar la sensibilidad y especificidad del algoritmo para optimizar su rendimiento.

De acuerdo con el análisis realizado, se identificaron 5 casos de “Variabilidad Mixta”, 7 casos de “Mejora” y 7 casos de “Empeora” (Ver Tabla 5). Para cada categoría, se seleccionaron ejemplos representativos que ilustran las distintas realidades del seguimiento. Estos ejemplos específicos ayudan a entender como el algoritmo se comportan en situaciones reales, ofreciendo perspectivas sobre sus fortalezas y áreas donde es necesario enfocarse para futuras mejoras. La selección de casos específicos sirve como evidencia concreta de los hallazgos generales del análisis cualitativo y proporciona una base sólida para discusiones posteriores sobre la mejora del algoritmo.

Categoría	Ocurrencias
Mejora	7
Empeora	7
Variabilidad Mixta	5

Tabla 5: Resultados Análisis Cualitativo.
Fuente: Elaboración Propia

Ejemplo de Mejora Para ilustrar la efectividad del algoritmo de seguimiento en mejorar la precisión de las detecciones, examinamos el caso del evento C1B1. Este ejemplo destaca cómo el algoritmo logra superar las limitaciones de la detección inicial, ofreciendo una mejora en la identificación de troncos.

Lo primero que llama la atención de este evento es lo bien que están posicionadas las bounding boxes en el estado inicial (Ver Figura 20), se puede apreciar claramente que cada una

corresponde a un tronco específico, pero también se puede ver que existen 3 troncos en la parte superior del banco de madera, que no están siendo detectados y tampoco siendo seguidos, esto demuestra una falencia en el proceso de detección ya que a pesar de ser clara la existencia de esos troncos para el ojo humano, el algoritmo no logró notarlos.

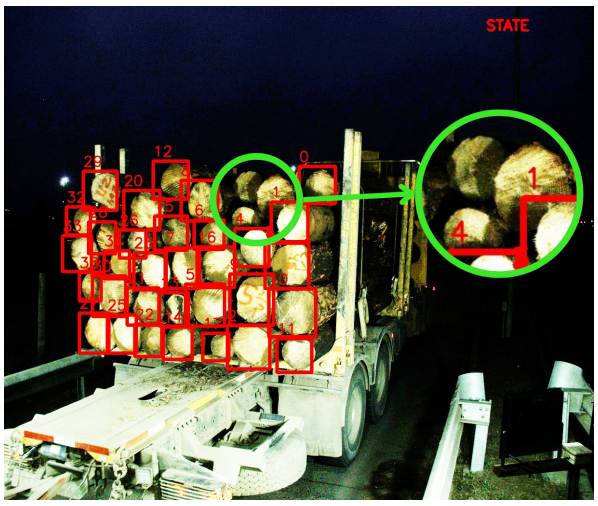


Figura 20: Ejemplo de Mejora Cualitativa - Evento C1B1, Estado Inicial.
Fuente: Elaboración Propia.

Luego si se sigue a la siguiente etapa del algoritmo de seguimiento (Ver Figura 21), se puede ver que las predicciones fueron relativamente correctas ya que siguen la trayectoria del camión aunque se puede notar que estas quedan un poco atrás de donde está realmente el tronco, lo cual puede ser un indicio de problemas que tiene el algoritmo.



Figura 21: Ejemplo de Mejora Cualitativa - Evento C1B1, Estado Inicial y Predicción.
Fuente: Elaboración Propia.

En la etapa de Predicciones y Observaciones (Ver Figura 22), se puede apreciar que los troncos que antes no habían sido detectados ahora si fueron observados por el algoritmo, pero también hay un tronco que había sido previamente detectado que ya no lo está, solo existe su predicción. Este tronco está en la zona inferior del banco de madera y tiene un ID de 17.

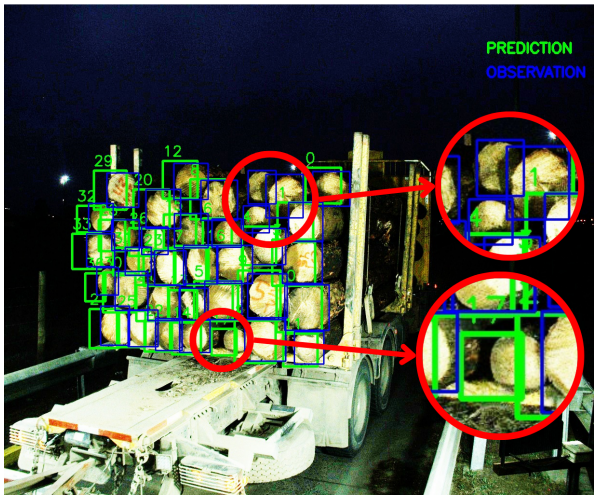


Figura 22: Ejemplo de Mejora Cualitativa - Evento C1B1, Predicción y Observación.
Fuente: Elaboración Propia.

Al seguir a la etapa de Asociaciones (Ver Figura 23), se puede notar que los troncos fueron correctamente asociados unos con otros, que los troncos recientemente detectados fueron reconocidos por el algoritmo de seguimiento, al igual que la predicción que ya no tiene ninguna detección asociada.

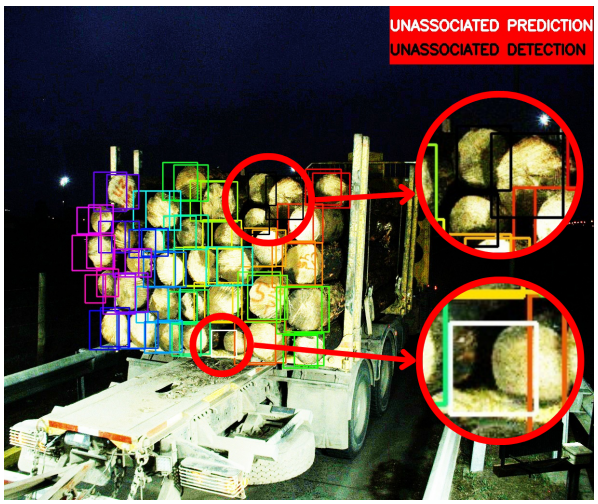


Figura 23: Ejemplo de Mejora Cualitativa - Evento C1B1, Asociación.
Fuente: Elaboración Propia.

En las últimas etapas, tanto donde se muestra el nuevo estado, las predicciones y observaciones (Ver Figura 24), como en la que se muestra solamente el nuevo estado (Ver Figura 25) se puede ver como fueron inicializados las bounding boxes de las nuevas detecciones y también se mantuvo la predicción de la trayectoria que se quedo sin detección, lo que permitió mejorar el conteo de troncos del algoritmo en una unidad.

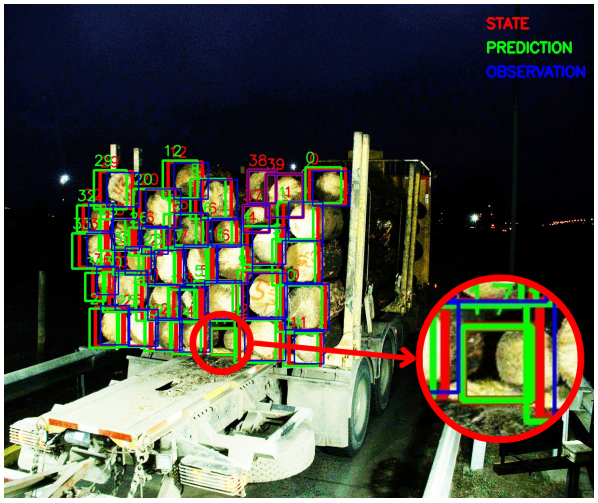


Figura 24: Ejemplo de Mejora Cualitativa - Evento C1B1, Nuevo Estado, Predicción y Observación.
Fuente: Elaboración Propia.

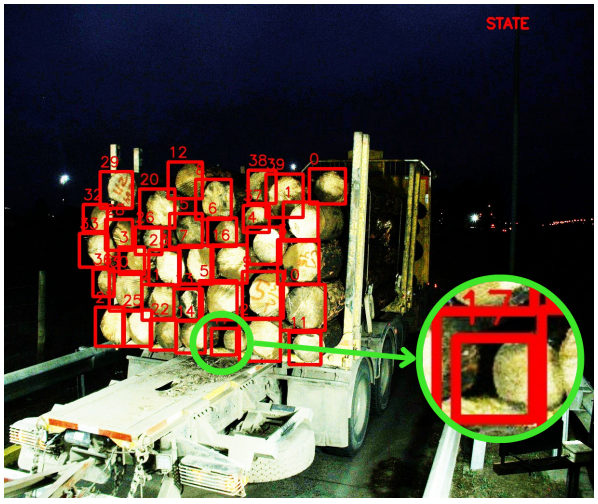


Figura 25: Ejemplo de Mejora Cualitativa - Evento C1B1, Nuevo Estado.
Fuente: Elaboración Propia.

La evaluación detallada del caso de mejora en el evento C1B1 ofrece una perspectiva valiosa sobre las capacidades y limitaciones del algoritmo de seguimiento implementado. Uno

de los hallazgos más significativos es la demostración clara de cómo este algoritmo puede mantener la integridad de la detección de troncos incluso cuando el algoritmo de detección subyacente falla. Este ejemplo específico ilustra un escenario común en el que, a pesar de la presencia obvia de troncos para el observador humano, el algoritmo de detección inicial no logra identificarlos adecuadamente. El algoritmo de seguimiento interviene de manera crucial para compensar esta deficiencia, asegurando que el tronco no detectado inicialmente sea incorporado en el conteo final. Este resultado subraya la importancia del seguimiento como una capa adicional de verificación y corrección que puede mejorar significativamente la precisión global del sistema.

Sin embargo, el análisis también revela ciertas limitaciones inherentes al algoritmo de seguimiento, particularmente en lo que respecta a la precisión de las predicciones de movimiento. Aunque las bounding boxes se mueven en la dirección correcta de un frame a otro, se observa que estas predicciones tienden a quedarse “atrás” respecto a las posiciones reales de los troncos. Esto indica que, aunque el algoritmo es capaz de prever la trayectoria de los troncos, la estimación de la velocidad no es del todo precisa, lo que resulta en una ligera discrepancia entre la ubicación predicha y la real.

Este desajuste en las predicciones de velocidad, aunque no compromete la capacidad del algoritmo para mejorar la detección de troncos no identificados, sí señala una oportunidad de mejora. Ajustar el algoritmo para que las predicciones de velocidad se alineen más estrechamente con las velocidades reales de los troncos podría aumentar aún más la precisión del seguimiento y, por extensión, la exactitud del conteo total de troncos.

Ejemplo de Empeoramiento Para comprender las limitaciones y desafíos del algoritmo de seguimiento, analizamos un evento específico de nomenclatura C36B1, en el que se evidencia un empeoramiento en la precisión de las detecciones debido al seguimiento. Este caso destaca situaciones en las que el algoritmo de seguimiento, a pesar de sus intenciones de mejorar la precisión del conteo y seguimiento de troncos, introduce errores o inexactitudes.

En el Estado Inicial del evento (Ver Figura 26), las bounding boxes de los troncos presentan un ligero desplazamiento respecto a la posición real de los troncos. Un claro ejemplo es la bounding box del tronco número 11, ubicado en la parte superior izquierda, que aparece desproporcionadamente alta en comparación con el tronco real, lo que podría llevar a estimaciones erróneas de sus dimensiones.

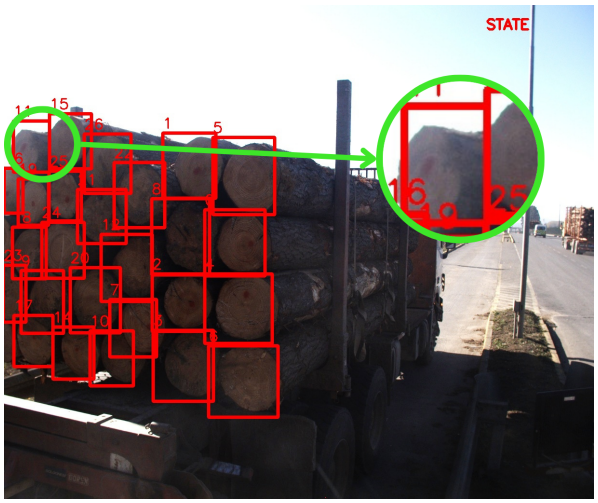


Figura 26: Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Estado Inicial.
Fuente: Elaboración Propia.

Avanzando a la imagen de Estado Inicial y Predicciones (Ver Figura 27), es evidente la inexactitud de las predicciones, especialmente notoria en los troncos situados en la parte superior izquierda. Las predicciones para troncos como el 11, 15 y 16 se quedan notablemente atrás respecto a la posición real de los troncos.

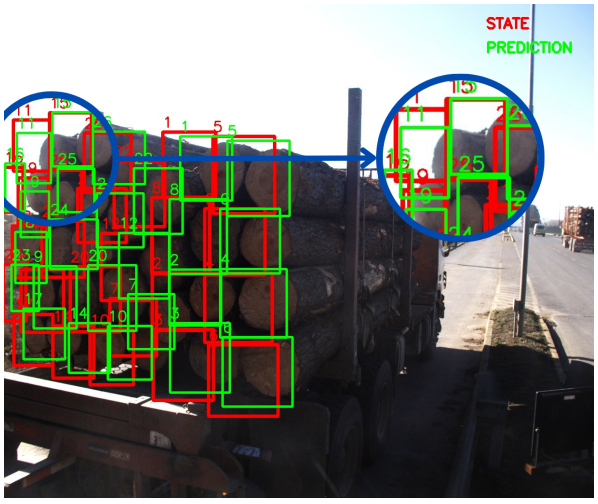


Figura 27: Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Estado Inicial y Predicciones.
Fuente: Elaboración Propia.

La etapa de Predicciones y Observaciones (Ver Figura 28) muestra una clara desconexión entre las bounding boxes predichas y las detectadas, particularmente en los troncos con ID 11, 15 y 16, donde las predicciones apenas intersectan con sus troncos correspondientes.

Este fenómeno puede atribuirse a la geometría del problema, indicando que los troncos más alejados de la cámara se mueven aparentemente más rápido respecto a los cercanos.

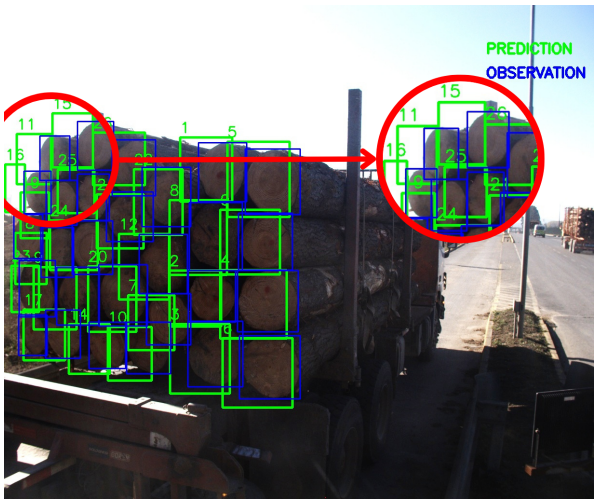


Figura 28: Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Predicciones y Observaciones.

Fuente: Elaboración Propia.

En la Etapa de Asociaciones (Ver Figura 29), se observa una meticulosa labor de emparejamiento entre las predicciones y las observaciones reales. A pesar de las inexactitudes previas en las predicciones, el algoritmo logra realizar asociaciones correctas en la mayoría de los casos. Esta etapa es crucial porque determina la precisión con la que el algoritmo de seguimiento puede mantener la continuidad de los troncos a través de los frames.

No obstante, se enfrenta a un desafío notable debido a la elección del color blanco para demarcar las predicciones no asociadas. En contextos de alta luminosidad, como el cielo despejado en el fondo de algunas imágenes, estas bounding boxes se vuelven difíciles de distinguir, complicando la evaluación visual de las asociaciones. Este problema se agrava aún más por el hecho de que el algoritmo utiliza un espectro de colores completo para diferenciar entre las demás bounding boxes, dejando pocas opciones para resaltar de manera única las predicciones no asociadas sin crear confusión.

Aun así, el algoritmo muestra su capacidad para adaptarse y reconocer troncos recientemente detectados, integrándolos efectivamente en el seguimiento. Sin embargo, se identifica una predicción no asociada en la parte izquierda de la imagen que, debido al contraste insuficiente con el fondo luminoso, resulta casi invisible. Este detalle no solo plantea un desafío visual sino que también subraya la importancia de optimizar la representación gráfica de las imágenes de debug para facilitar la interpretación de los resultados.



Figura 29: Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Asociaciones.
Fuente: Elaboración Propia.

Las Últimas Etapas, que muestran el nuevo estado, las predicciones y las observaciones (ver Figuras 30 y 31), revelan cómo una bounding box, específicamente la ID 16, que no era fácilmente visible para el ojo humano en la etapa de Asociaciones, queda fuera de lugar debido a predicciones inexactas, afectando negativamente el conteo final con este tronco fantasma.

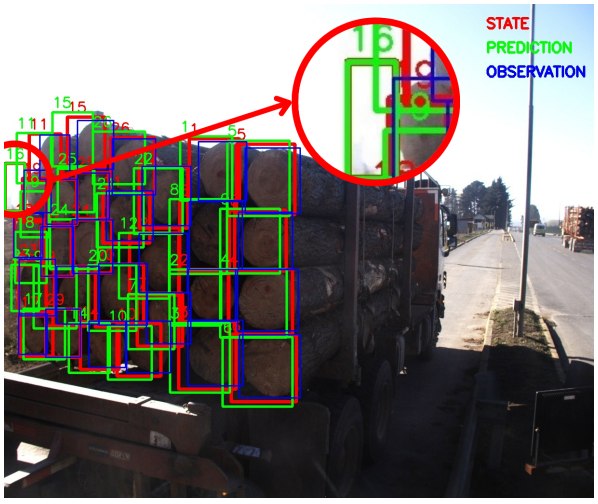


Figura 30: Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Nuevo Estado, Predicciones y Observaciones.
Fuente: Elaboración Propia.

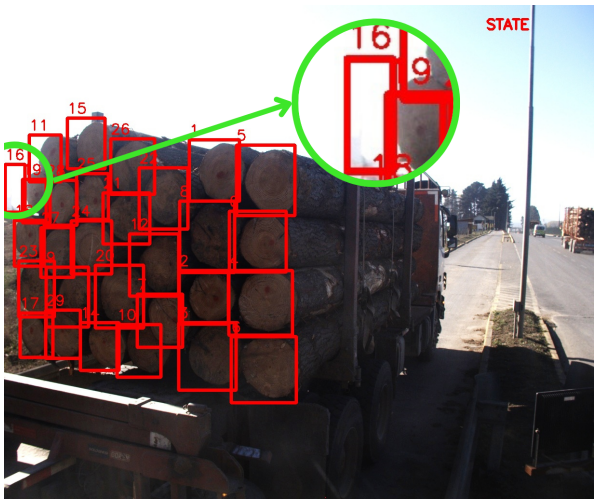


Figura 31: Ejemplo de Empeoramiento Cualitativo - Evento C36B1, Nuevo Estado.
Fuente: Elaboración Propia.

Ejemplo de Variabilidad Mixta Se analizó el evento C32B1, que ejemplifica la “Variabilidad Mixta” en el algoritmo de seguimiento. Este caso ilustra situaciones en las que el seguimiento produce resultados mixtos: mejorando algunas detecciones mientras introduce errores en otras. Es un ejemplo representativo de cómo el algoritmo maneja las complejidades y variaciones inherentes al seguimiento de troncos en movimiento.

El Estado Inicial del evento (ver Figura 32) destaca por su alta densidad de troncos. Sin embargo, el banco no se visualiza en su totalidad, un fenómeno frecuente cuando los bancos de troncos están muy próximos entre sí, lo que restringe la capacidad del algoritmo de detección debido a las oclusiones presentes. A pesar de esta limitación, las bounding boxes iniciales muestran una alineación adecuada, aunque se observa la omisión en la detección de un tronco claramente visible en la parte inferior derecha, lo que sugiere una oportunidad de mejora para el algoritmo de detección.

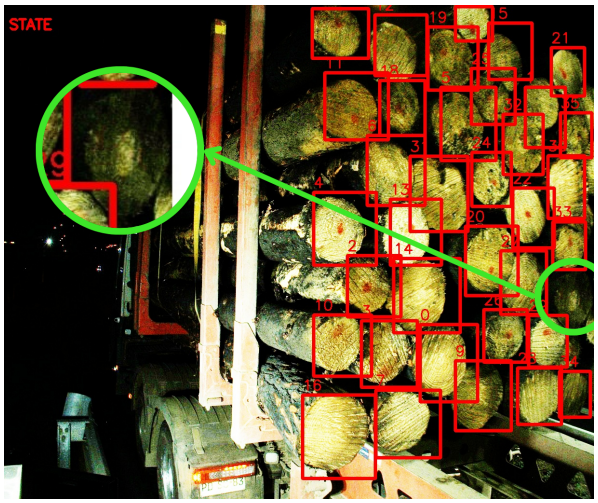


Figura 32: Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Estado Inicial.
Fuente: Elaboración Propia.

Al examinar la imagen del Estado Inicial junto con las Predicciones (Ver Figura 33), se observa que, similar a ejemplos anteriores, las predicciones no son completamente acertadas. En particular, se nota que las predicciones de los troncos más cercanos a la cámara son más precisas, aunque aún deficientes. Se destaca que en los troncos ubicados arriba a la izquierda, la predicción erróneamente continúa ascendiendo a pesar de que el tronco real ya no sigue esa trayectoria. Esto pone de manifiesto una limitación del algoritmo SORT, relacionada con el uso de Filtros de Kalman, donde trayectorias con cambios de dirección significativos pueden no ser capturadas adecuadamente sin suficientes frames de imágenes para facilitar una transición suave.

Además, se observa que las predicciones de velocidad para los troncos no se ajustan adecuadamente para seguir el movimiento real de los troncos, quedándose “atrás”, especialmente en el caso de los troncos más alejados de la cámara. Esto se debe a la perspectiva, que hace que estos troncos se muevan más de un frame a otro en comparación con los más cercanos. También se debe considerar que los troncos a la derecha, debido a que el banco de madera no ha sido completamente visualizado, han tenido menos tiempo para ajustar su velocidad predicha, la cual inicialmente se basa en una velocidad genérica y se ajusta mediante las heurísticas adicionales implementadas, pero que a menudo no es suficiente para predecir una velocidad inicial adecuada.



Figura 33: Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Estado Inicial y Predicción.

Fuente: Elaboración Propia.

En la imagen de Predicciones y Observaciones (Ver Figura 34), se destacan claramente las inexactitudes en las predicciones. Notablemente, el tronco anteriormente identificado con el ID 9 ya no se detecta, aunque mantiene una predicción relativamente buena. Asimismo, varios troncos que aparecen desde la derecha de la imagen, a pesar de ser visibles, no fueron detectados por el algoritmo.

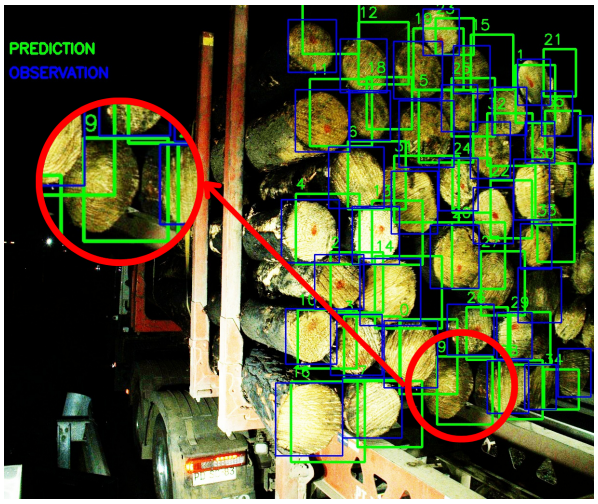


Figura 34: Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Predicción y Observación.

Fuente: Elaboración Propia.

En el proceso de Asociación (Ver Figura 35), se evidencian las consecuencias de las inexacti-

tudes en las predicciones y detecciones. Se observan tres predicciones sin asociar: una en la parte superior derecha, una en el centro y otra en la parte inferior de la imagen. La predicción no asociada en la parte superior se debe a una mala predicción que no coincide con ningún tronco, cuando debería haberse asociado con el tronco a su izquierda, el cual, a su vez, se asoció incorrectamente con otra trayectoria debido a errores en la predicción de esta última. Por otro lado, las predicciones no asociada en la parte inferior y central logra mantener una relativa cercanía al tronco que representa, aunque ya no se detectan, lo que sugiere que, en este caso específico, el algoritmo logró mantener activas las trayectorias de troncos que por alguna razón ya no están siendo detectados.

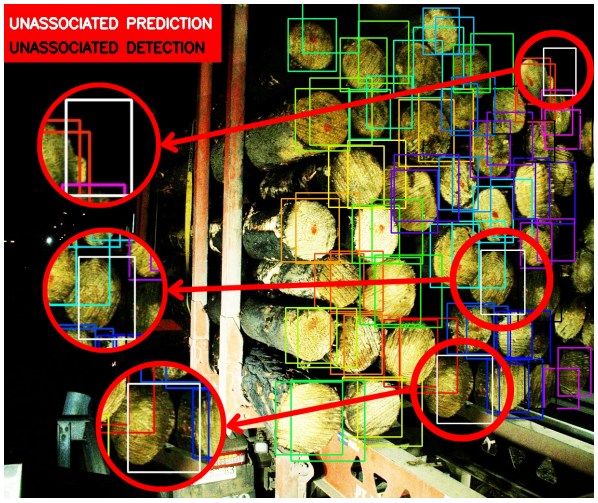


Figura 35: Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Asociaciones.
Fuente: Elaboración Propia.

Finalmente, en las etapas últimas del evento (Ver Figuras 36 y 37) se ve evidenciado el resultado de estas tres bounding boxes, en donde por una parte se mantuvo el ID de los tronco 9 y 27 en el algoritmo a pesar de que esto ya no está siendo detectados, y por otro lado, se mantuvo una trayectoria de ID 21 en discordancia de donde se movió su tronco en realidad.



Figura 36: Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Nuevo Estado, Predicciones y Observaciones.
Fuente: Elaboración Propia.

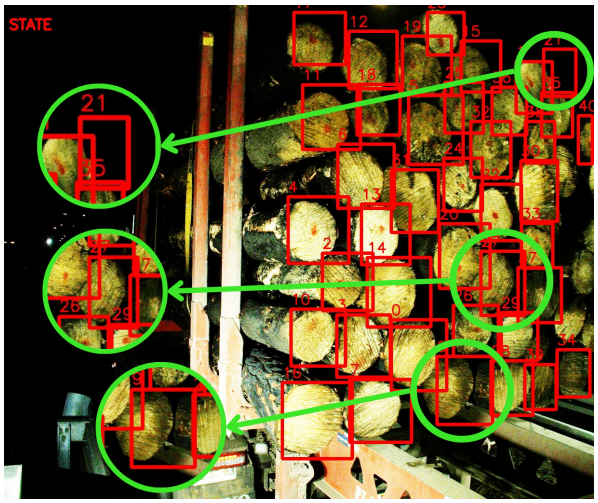


Figura 37: Ejemplo de Variabilidad Mixta Cualitativa - Evento C32B1, Nuevo Estado.
Fuente: Elaboración Propia.

5.4.4. Integración de Análisis

En la fase final de este estudio sobre el algoritmo de seguimiento de troncos en camiones, se realiza una comparativa exhaustiva entre los análisis cuantitativo y cualitativo para obtener una visión completa del rendimiento del algoritmo. A través de esta comparación, se busca identificar no solo la eficacia general del algoritmo en términos numéricos, sino también evaluar la precisión y relevancia de las detecciones y seguimientos en un contexto práctico.

El análisis cuantitativo, basado principalmente en la comparación de conteos de troncos detectados versus conteos reales, permitió categorizar los eventos en términos de mejora, empeoramiento o igualdad respecto al conteo manual. Sin embargo, esta evaluación, centrada en números, no siempre refleja la complejidad subyacente de cada evento. Por ello, se complementó este estudio con un análisis cualitativo detallado, centrado en la evaluación de la calidad de las bounding boxes y la precisión del seguimiento a lo largo del tiempo.

Se presenta un resumen que integra ambos análisis (Ver Tabla 6), destacando casos en los que un evento considerado como “mejora” en el análisis cuantitativo muestra resultados mixtos o incluso negativos cuando se examina más detalladamente en el plano cualitativo. Por ejemplo, el evento C32B1, aunque cuantitativamente clasificado como mejora, reveló una “Variabilidad Mixta” al analizar la calidad de las detecciones y seguimientos, subrayando cómo el algoritmo puede mejorar algunas detecciones mientras introduce errores en otras.

Nueva Categoría / Categoría Inicial	Mejora	Empeora	Variabilidad Mixta
Mejor	7	2	5
Peor	0	5	0

Tabla 6: Resumen de la reevaluación de eventos inicialmente categorizados como “Mejor” y “Peor” en el análisis cuantitativo, comparados con los resultados del análisis cualitativo - Vida Máxima 2.

Fuente: Elaboración Propia

También se muestra un análisis integrado de los resultados utilizando una Vida Máxima de 3 frames (Ver Tabla 7). Aquí se puede ver como en total existieron 14 eventos con mejora mientras que hay otros 17 casos en los que el algoritmo de seguimiento empeoró los resultados, recalcando la decisión previamente tomada de utilizar el algoritmo con una vida máxima de 2 frames para el análisis principal de los datos.

Nueva Categoría / Categoría Inicial	Mejora	Empeora	Variabilidad Mixta
Mejor	13	8	0
Peor	1	9	0

Tabla 7: Resumen de la reevaluación de eventos inicialmente categorizados como “Mejor” y “Peor” en el análisis cuantitativo, comparados con los resultados del análisis cualitativo - Vida Máxima = 3.

Fuente: Elaboración Propia

Este enfoque dual ha permitido no solo validar la eficacia del algoritmo desde una perspectiva numérica, sino también comprender mejor sus limitaciones y áreas de mejora. La variabilidad en los resultados cualitativos, especialmente en eventos clasificados de manera optimista por el análisis cuantitativo, enfatiza la necesidad de un enfoque equilibrado que considere tanto la cantidad como la calidad de las detecciones y seguimientos.

CAPÍTULO 6
CONCLUSIONES

En el transcurso de esta investigación, se llevó a cabo un exhaustivo análisis de las limitaciones presentes en el sistema Instalog, enfocándose primordialmente en la problemática asociada con el conteo y seguimiento de troncos en camiones de carga, especialmente bajo condiciones de obstrucciones visuales. La investigación inicial reveló que, aunque Instalog poseía una base sólida para la detección de troncos, su capacidad para realizar un seguimiento coherente y preciso de los mismos a través de secuencias de imágenes era insuficiente, particularmente en situaciones donde los troncos se ocultan o se superponen entre sí.

Para abordar esta problemática, se realizó una investigación sobre las técnicas y metodologías existentes de seguimiento de objetos. La revisión de literatura permitió identificar que el algoritmo SORT (Simple Online and Realtime Tracking), con modificaciones específicas para adaptarlo al contexto de la detección de troncos en el sistema Instalog, presentaba un potencial significativo. Por lo tanto, se diseñó e implementó una versión adaptada de SORT, la cual se integró al sistema Instalog con el objetivo de mejorar su capacidad de seguimiento en situaciones de obstrucción visual. Sin embargo, los resultados de esta implementación revelaron una complejidad y sensibilidad del sistema a las condiciones del entorno que no permitieron alcanzar las mejoras significativas en la precisión del conteo que inicialmente se esperaban.

A pesar de estos desafíos, el proceso de validación proporcionó una comprensión profunda de la solución propuesta y su interacción con las condiciones operativas realistas. Se realizaron evaluaciones cuantitativas y cualitativas, destacando tanto los logros como las limitaciones del algoritmo implementado. Este análisis subrayó la importancia de considerar tanto la cantidad como la calidad de las detecciones y seguimientos, enfatizando la necesidad de un enfoque equilibrado que considere tanto aspectos numéricos como cualitativos del seguimiento y conteo de troncos.

6.1. Contribución a la Industria Maderera

A pesar de que los resultados experimentales no reflejaron una mejora significativa en la precisión del conteo de troncos dentro del sistema Instalog debido a diversas complicaciones, este trabajo aporta valiosas contribuciones a la industria maderera. Este proyecto no solo destaca la complejidad inherente al seguimiento y conteo de troncos en condiciones dinámicas y, a menudo, impredecibles, sino que también subraya la importancia de la investigación continua y el desarrollo tecnológico en este campo.

Primero, la investigación ha proporcionado una comprensión detallada de las limitaciones actuales del sistema Instalog, especialmente en escenarios con obstrucciones visuales. Es-

ta comprensión es crucial para cualquier esfuerzo futuro destinado a mejorar los sistemas de visión por computadora aplicados al conteo y seguimiento de troncos. Además, el análisis de las técnicas de seguimiento de múltiples objetos existentes y la adaptación de estas metodologías al contexto específico de la industria maderera representan un avance metodológico importante. Aunque el algoritmo adaptado no cumplió con todas las expectativas iniciales, la experiencia adquirida y las lecciones aprendidas son fundamentales para guiar futuras investigaciones.

La industria maderera se enfrenta a retos continuos para optimizar sus operaciones y garantizar una gestión eficiente de sus recursos. En este contexto, la capacidad de contar y seguir troncos de manera precisa y eficiente es de suma importancia, ya que afecta directamente a la logística, la planificación de la producción y las transacciones comerciales. Aunque este trabajo no ha solucionado completamente el problema, ha identificado claramente las áreas críticas que requieren atención y ha proporcionado una base sobre la cual pueden construirse futuras soluciones.

Además, este proyecto ha demostrado la viabilidad de aplicar técnicas avanzadas de visión por computadora y aprendizaje automático en la industria maderera, un sector que hasta hace poco había dependido en gran medida de métodos manuales o semi-automáticos. Al explorar y experimentar con estas tecnologías, este trabajo contribuye a un cambio gradual hacia la automatización y digitalización de la industria, lo cual es esencial para mejorar la precisión, la eficiencia y, en última instancia, la sostenibilidad de las operaciones madereras.

Para entender de mejor forma los resultados obtenidos, se procederá a analizar de una forma más profunda los errores encontrados y formas en las que estos podrían ser mitigados.

6.2. Análisis de Errores y Recomendaciones de Mejoras del Algoritmo

Esta sección se centrara en identificar y analizar los errores inherentes al algoritmo de seguimiento implementado y que fueron encontrados en el análisis, explorando las razones subyacentes y proponiendo posibles soluciones para mejorar su rendimiento y precisión. Este análisis se realizará utilizando el algoritmo con un parámetro de Vida Máxima de 3, ya que de esta forma se tienen más casos interesantes que visualizar.

6.2.1. Error de Velocidad Inicial:

En el contexto del desarrollo y mejora de algoritmos de seguimiento, uno de los obstáculos más críticos a superar es la gestión adecuada del denominado “Error de Velocidad Inicial”. Este problema surge específicamente al momento de asignar velocidades iniciales a los troncos recién detectados dentro del sistema. La raíz de este desafío radica en que, en muchas ocasiones, las velocidades iniciales otorgadas no logran capturar fielmente la dinámica real de

movimiento de los troncos, resultando en una disminución notable de la precisión en las predicciones de trayectoria desde el mismo instante de su inicialización. Un ejemplo palpable de esta problemática se observa durante el análisis del Evento C31B1, donde se evidencia una discrepancia significativa entre las velocidades iniciales estimadas y las velocidades reales de los troncos (Ver Figuras 38, 39, 40, 41, 42 y 43).

Al detenerse en el análisis de troncos específicos, con identificadores 6, 14 y 18, situados en el extremo derecho de la imagen capturada, se destaca que, aunque estos se mueven en gran medida en la dirección correcta, la velocidad que se les había asignado inicialmente no alcanza para que estos lleguen a su posición real en los frames subsecuentes. El tronco con ID 6 ejemplifica de manera clara esta dificultad, moviéndose hacia la dirección adecuada pero a una velocidad que resulta insuficiente, lo que culmina en una discrepancia notoria en el frame siguiente. Por otra parte, el tronco con ID 18, aunque se mantiene en una proximidad relativa a su posición esperada, también padece de una estimación de velocidad inicial imprecisa. El caso del tronco con ID 14 es aún más problemático, ya que no solo avanza a una velocidad incorrecta sino que también se desplaza en una dirección equivocada, convirtiéndose en una trayectoria fantasma en el estado de seguimiento subsiguiente.

Dentro del análisis de las causas algorítmicas que podrían estar detrás de estos errores, es plausible considerar inicialmente que la selección de un valor de velocidad inicial podría no ser la óptima. Sin embargo, se añade la complejidad de que, dependiendo de la posición específica del tronco dentro del camión o el frame en el cual se inician las nuevas trayectorias, estas deberían, idealmente, tener velocidades iniciales diferenciadas que consideren la geometría específica del problema. Una solución potencial a este dilema sería reemplazar el valor fijo de la velocidad inicial por uno dinámico que varíe según las variables mencionadas. No obstante, se debe tener en cuenta que la precisión de la velocidad inicial también se ve afectada por heurísticas adicionales implementadas en el algoritmo, las cuales presentan sus propias limitaciones.

Por ejemplo, en la heurística que propone el uso de velocidades de troncos adyacentes como referencia para determinar la velocidad de un tronco en particular, se ha observado que este método no resulta eficaz, especialmente porque tiende a fallar en los últimos troncos detectados, donde la inexactitud en la estimación de velocidades iniciales es más común. Este patrón de fallo se debe principalmente a que, en los frames que aún no logran mostrar el banco de madera en su totalidad, es más probable que los troncos adyacentes a los recién detectados también hayan sido inicializados recientemente. Dado que estos troncos vecinos están en las primeras fases de su seguimiento, existe una alta probabilidad de que sus velocidades iniciales no se hayan estimado con precisión.

La implicación de este fenómeno es que, al utilizar las velocidades de estos troncos adyacentes como base para asignar una velocidad a un tronco recién detectado, se está recurriendo a referencias que ya están marcadas por inexactitudes en sus propias estimaciones de velocidad. Esta cadena de decisiones basadas en datos erróneos conduce a una propagación del error de velocidad inicial a través de los nuevos troncos, exacerbando el problema en vez de mitigarlo. En esencia, al confiar en velocidades de troncos que no han tenido suficiente tiem-

po para que sus trayectorias se estabilicen y reflejen una dinámica de movimiento realista, el algoritmo perpetúa y amplifica el error de velocidad inicial en lugar de corregirlo.

Una mejora sugerida para esta heurística consiste en evitar referenciar las velocidades de troncos recientemente inicializados, limitando las referencias únicamente a troncos cuyas trayectorias ya hayan tenido tiempo de estabilizarse y, por lo tanto, sean más fiables.

En el análisis profundo de la heurística basada en el modelo estadístico, destinada a estimar la velocidad de un tronco en función de su ubicación actual dentro de la imagen, es esencial reconocer una limitación fundamental de este enfoque: no toma en cuenta adecuadamente la dimensión temporal y la dinámica cambiante del contexto en el que se mueven los troncos. Específicamente, este modelo falla al no considerar que un tronco ubicado en una determinada posición en un frame inicial del evento puede presentar una velocidad completamente distinta a la de otro tronco que se encuentre en la misma posición pero en un frame más avanzado del evento.

Para abordar este desafío y mejorar la precisión de las estimaciones de velocidad, una propuesta de mejora para esta heurística sería incorporar un componente que considere la evolución temporal del evento. Esto implicaría ajustar la estimación de velocidad no solo en base a la posición actual del tronco dentro del campo de visión, sino también tomando en cuenta cuánto tiempo ha transcurrido desde el inicio del evento.

Incorporar esta dimensión temporal se puede hacer utilizando la información del frame actual con respecto al primer frame del evento, lo que actuaría como una especie de estimador de cercanía/lejanía del camión con respecto a la cámara. Esta estimación se justifica debido a que los camiones deben moverse a una velocidad relativamente fija, lo cual es un requerimiento para que INSTALOG funcione de buena forma.

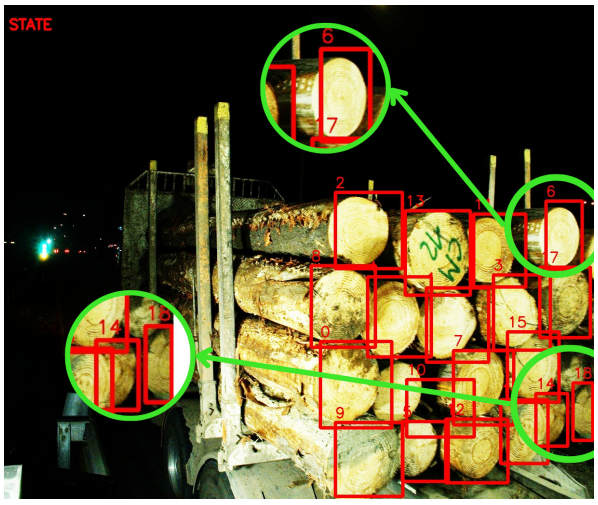


Figura 38: Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Estado Inicial.

Fuente: Elaboración Propia.

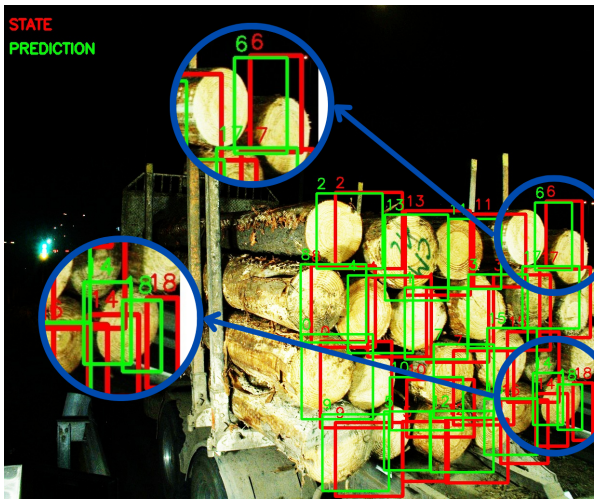


Figura 39: Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Estado Inicial y Predicciones.

Fuente: Elaboración Propia.

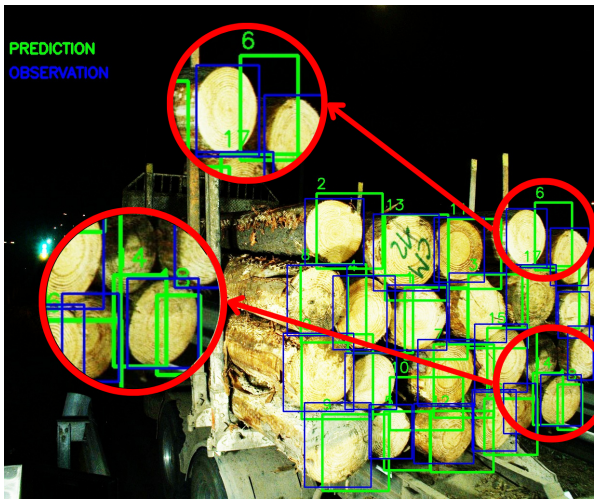


Figura 40: Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Predicciones y Observaciones

Fuente: Elaboración Propia.

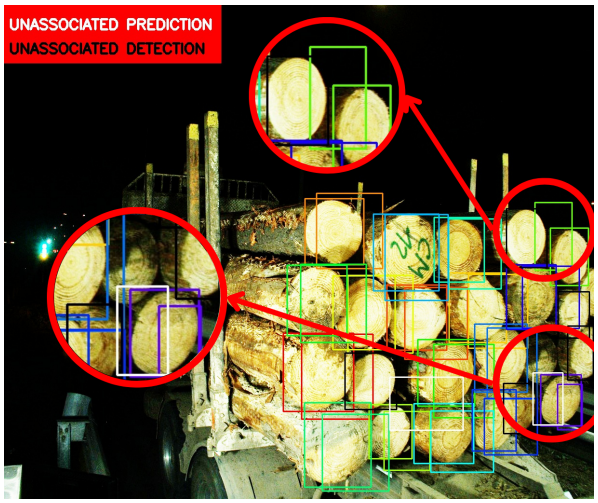


Figura 41: Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Asociaciones.

Fuente: Elaboración Propia.

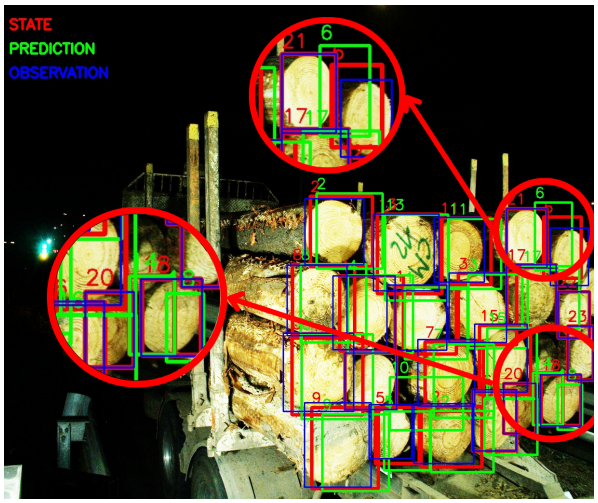


Figura 42: Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Nuevo Estado, Predicciones y Observaciones.

Fuente: Elaboración Propia.

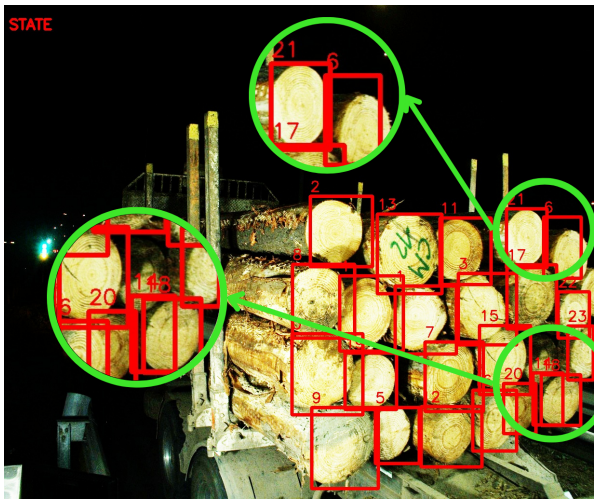


Figura 43: Ejemplo de Error de Velocidad Inicial (Vida Máxima = 3) - Evento C31B1, Nuevo Estado.

Fuente: Elaboración Propia.

6.2.2. Error de Asociación:

El “Error de Asociación” surge en situaciones donde la proximidad de las trayectorias entre sí complica su correcta asociación con los troncos detectados. Este problema se manifiesta especialmente cuando varias trayectorias, ninguna de las cuales se superpone completamente con la detección real, compiten por asociarse a un mismo tronco, llevando a decisiones erróneas por parte del sistema. Un caso emblemático de este error se observa en el Evento C24B2, donde las trayectorias de los troncos con ID 7 y 11 presentan complicaciones en su asociación (Ver Figuras 44, 45, 46, 47, 48 y 49)

Inicialmente, ambas trayectorias están correctamente posicionadas sobre sus respectivos troncos. Sin embargo, tras avanzar a la fase de predicción, solo una mitad de cada trayectoria se alinea adecuadamente con el tronco correspondiente. El uso del criterio de Intersección sobre Unión (IoU) por parte del algoritmo conduce a una asociación incorrecta: la trayectoria ID 7 se vincula al tronco destinado a la trayectoria ID 11. Este error no solo desplaza erróneamente la trayectoria ID 11, sino que también crea un tronco fantasma, una trayectoria sin correspondencia real en la imagen.

Una solución intuitiva sería mejorar la precisión en la predicción de velocidades para reducir la frecuencia de estos errores. Si bien el perfeccionamiento de las predicciones podría mitigar el problema, también es crucial explorar soluciones que permitan manejar adecuadamente asociaciones erróneas incluso con predicciones imperfectas.

Una alternativa considerada fue el algoritmo DeepSORT, que, basándose en la estructura del SORT, incorpora el uso de redes neuronales en el proceso de asociación. Esta mejora permite

considerar características visuales extraídas directamente de la imagen para realizar asociaciones más precisas entre trayectorias y detecciones. Aunque la implementación de redes neuronales promete abordar efectivamente el problema de asociaciones erróneas, implica el desafío de desarrollar y entrenar el modelo con un conjunto de datos adecuadamente anotado, lo que representa un esfuerzo significativo en términos de tiempo y recursos.

La consideración de DeepSORT como solución destaca la importancia de balancear la precisión de asociación con la factibilidad práctica de implementación. La decisión de avanzar hacia esta dirección debe sopesar cuidadosamente los beneficios de mejorar la exactitud en las asociaciones frente a la inversión requerida para el entrenamiento y mantenimiento de modelos basados en aprendizaje profundo.

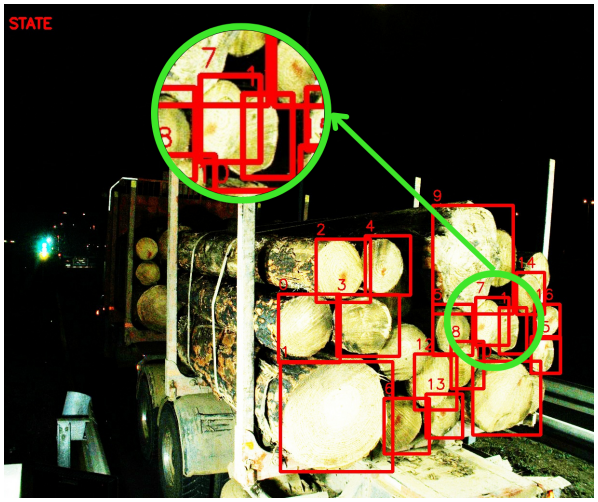


Figura 44: Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Estado Inicial. Fuente: Elaboración Propia.

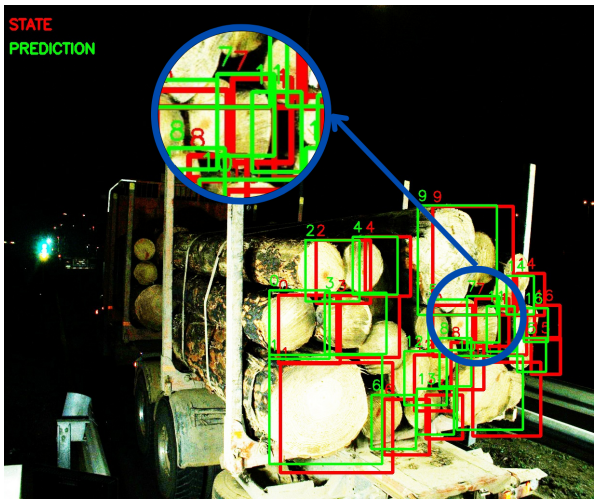


Figura 45: Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Estado Inicial y Predicciones.

Fuente: Elaboración Propia.

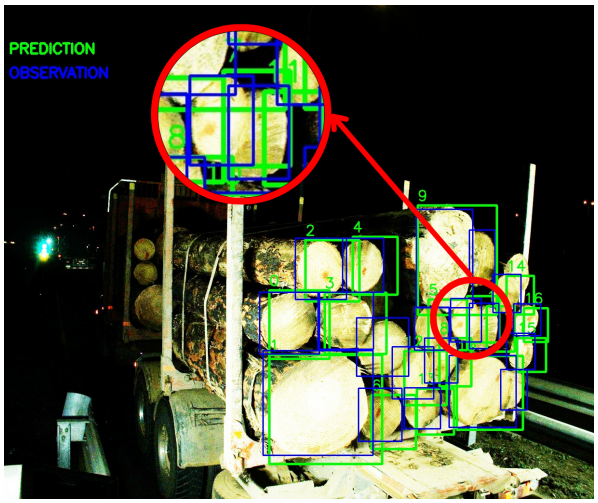


Figura 46: Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Predicciones y Observaciones.

Fuente: Elaboración Propia.

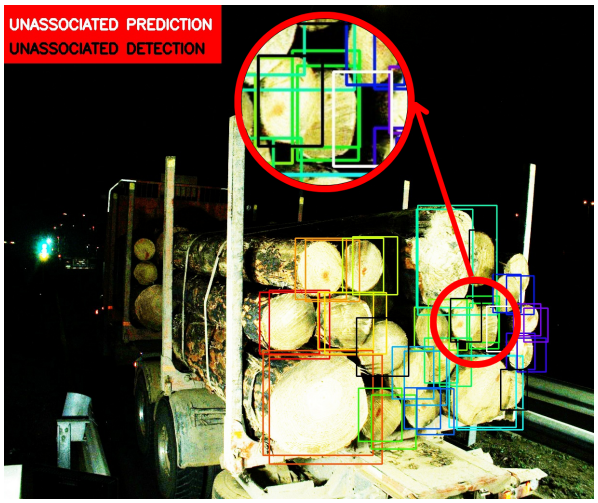


Figura 47: Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Asociaciones.
Fuente: Elaboración Propia.

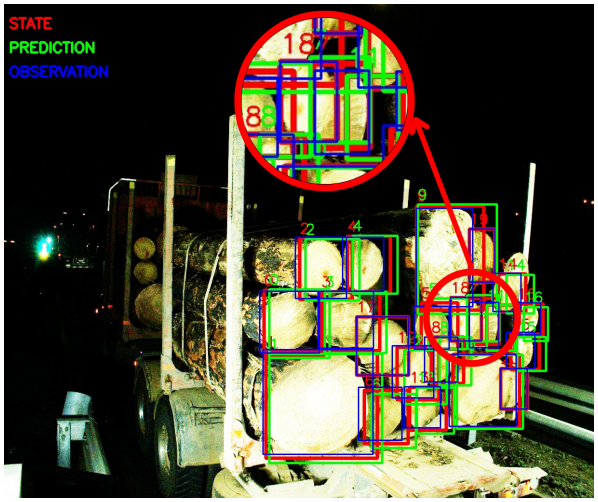


Figura 48: Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Nuevo Estado, Predicciones y Observaciones.
Fuente: Elaboración Propia.

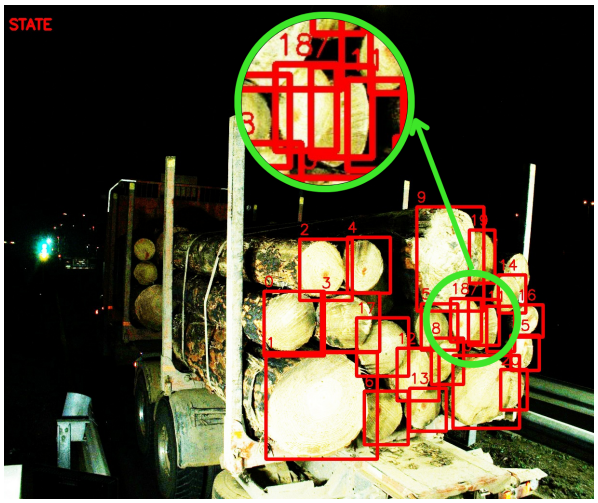


Figura 49: Ejemplo de Error de Asociación (Vida Máxima = 3) - Evento C24B2, Nuevo Estado. Fuente: Elaboración Propia.

6.3. Conclusiones Finales

Finalmente se puede concluir que, aunque el algoritmo de seguimiento demuestra un potencial significativo para mejorar el conteo y seguimiento de troncos en movimiento, aún existen desafíos importantes que abordar. Las discrepancias entre los análisis cuantitativo y cualitativo subrayan la importancia de continuar refinando el algoritmo, con un enfoque particular en mejorar la precisión de las predicciones y la calidad de las asociaciones entre predicciones y detecciones reales. Este estudio destaca la complejidad de implementar soluciones de seguimiento en entornos reales y subraya el valor de una evaluación comprensiva para el desarrollo de tecnologías más eficientes y precisas en el futuro.

ANEXOS

Evento	Conteo Real	Conteo Detectado	Conteo con Seguimiento	Diferencia Conteo Detectado - Real	Diferencia Conteo con Seguimiento - Real	Categoría
C1B1	35	34	35	-1	0	Mejor
C1B2	33	31	31	-2	-2	Igual
C2B1	37	36	36	-1	-1	Igual
C2B2	40	40	40	0	0	Igual
C3B1	16					
C3B2	22	22	22	0	0	Igual
C3B3	28	22	22	-6	-6	Igual
C3B4	28	28	28	0	0	Igual
C4B1	28	22	22	-6	-6	Igual
C4B2	33	33	33	0	0	Igual
C5B1	20	21	21	1	1	Igual
C5B2	18	17	17	-1	-1	Igual
C5B3	14	14	14	0	0	Igual
C5B4	15	15	15	0	0	Igual
C6B1	17					
C6B2	23	19	19	-4	-4	Igual
C6B3	24	12	12	-12	-12	Igual
C6B4	30	28	28	-2	-2	Igual
C7B1	36	36	36	0	0	Igual
C7B2	42	42	42	0	0	Igual
C8B1	28	28	28	0	0	Igual
C8B2	36	34	36	-2	0	Mejor
C9B1	33	33	33	0	0	Igual
C9B2	27	27	27	0	0	Igual
C9B3	30	28	29	-2	-1	Mejor
C9B4	35	35	35	0	0	Igual
C10B1	33	33	33	0	0	Igual
C10B2	27	27	27	0	0	Igual
C10B3	30	28	29	-2	-1	Mejor
C10B4	35	35	35	0	0	Igual
C11B1	45	40	40	-5	-5	Igual
C11B2	47	47	47	0	0	Igual
C12B1	22	22	22	0	0	Igual
C12B2	31	31	31	0	0	Igual
C13B1	21	21	21	0	0	Igual
C13B2	27	28	28	1	1	Igual

Tabla 8: Resultados Cuantitativos Detallados por Evento - Vida Máxima = 2 - Parte 1
Fuente: Elaboración Propia.

Evento	Conteo Real	Conteo Detectado	Conteo con Seguimiento	Diferencia Conteo Detectado - Real	Diferencia Conteo con Seguimiento - Real	Categoría
C14B1	29	29	29	0	0	Igual
C14B2	38	39	39	1	1	Igual
C15B1	39	38	38	-1	-1	Igual
C15B2	50	46	46	-4	-4	Igual
C16B1	39	38	38	-1	-1	Igual
C16B2	39	38	38	-1	-1	Igual
C17B1	24	24	24	0	0	Igual
C17B2	27	28	28	1	1	Igual
C17B3	37	37	37	0	0	Igual
C17B4	33	34	34	1	1	Igual
C18B1	29	28	29	-1	0	Mejor
C18B2	23	22	23	-1	0	Mejor
C18B3	37	35	37	-2	0	Mejor
C18B4	30	31	31	1	1	Igual
C19B1	31	31	31	0	0	Igual
C19B2	45	45	45	0	0	Igual
C20B1	61	56	57	-5	-4	Mejor
C20B2	79	75	79	-4	0	Mejor
C21B1	21	22	22	1	1	Igual
C21B2	37	37	38	0	1	Peor
C22B1	35	35	35	0	0	Igual
C22B2	27	27	27	0	0	Igual
C23B1	27	27	27	0	0	Igual
C23B2	36	35	35	-1	-1	Igual
C24B1	21	20	20	-1	-1	Igual
C24B2	22	20	21	-2	-1	Mejor
C24B3	40	37	39	-3	-1	Mejor
C24B4	38	39	39	1	1	Igual
C25B1	23	23	23	0	0	Igual
C25B2	28	29	29	1	1	Igual
C25B1	34	34	34	0	0	Igual
C25B2	41	42	42	1	1	Igual
C26B1	32	32	32	0	0	Igual
C26B2	39	38	38	-1	-1	Igual
C27B1	22	20	20	-2	-2	Igual
C27B2	17	17	17	0	0	Igual

Tabla 9: Resultados Cuantitativos Detallados por Evento - Vida Máxima = 2 - Parte 2
Fuente: Elaboración Propia.

Evento	Conteo Real	Conteo Detectado	Conteo con Seguimiento	Diferencia Conteo Detectado - Real	Diferencia Conteo con Seguimiento - Real	Categoría
C27B3	20	20	20	0	0	Igual
C27B4	20	21	21	1	1	Igual
C28B1	29	30	30	1	1	Igual
C28B2	37	37	37	0	0	Igual
C29B1	25	26	26	1	1	Igual
C29B2	33	35	35	2	2	Igual
C30B1	70	62	66	-8	-4	Mejor
C30B2	74	70	70	-4	-4	Igual
C31B1	24	24	24	0	0	Igual
C31B2	27	27	27	0	0	Igual
C32B1	50	46	47	-4	-3	Mejor
C32B2	35	35	35	0	0	Igual
C33B1	33	33	33	0	0	Igual
C33B2	47	44	44	-3	-3	Igual
C34B1	37	37	37	0	0	Igual
C34B2	33	35	35	2	2	Igual
C35B1	34	34	35	0	1	Peor
C35B2	42	42	43	0	1	Peor
C36B1	28	28	29	0	1	Peor
C36B2	36	36	39	0	3	Peor
C37B1	27	28	28	1	1	Igual
C37B2	38	38	38	0	0	Igual
C38B1	37	37	37	0	0	Igual
C38B2	46	45	46	-1	0	Mejor
C39B1	23	24	24	1	1	Igual
C39B2	30	30	30	0	0	Igual
C40B1	23	23	23	0	0	Igual
C40B2	28	28	28	0	0	Igual
C40B3	32	29	29	-3	-3	Igual
C40B4	33	33	33	0	0	Igual

Tabla 10: Resultados Cuantitativos Detallados por Evento - Vida Máxima = 2 - Parte 3
Fuente: Elaboración Propia.

Evento	Conteo Real	Conteo Detectado	Conteo con Seguimiento	Diferencia Conteo Detectado - Real	Diferencia Conteo con Seguimiento - Real	Categoría
C1B1	35	34	35	-1	0	Mejor
C1B2	33	31	32	-2	-1	Mejor
C2B1	37	36	36	-1	-1	Igual
C2B2	40	40	41	0	1	Peor
C3B1	16					
C3B2	22	22	22	0	0	Igual
C3B3	28	22	22	-6	-6	Igual
C3B4	28	28	28	0	0	Igual
C4B1	28	22	22	-6	-6	Igual
C4B2	33	33	33	0	0	Igual
C5B1	20	21	21	1	1	Igual
C5B2	18	17	17	-1	-1	Igual
C5B3	14	14	14	0	0	Igual
C5B4	15	15	15	0	0	Igual
C6B1	17					
C6B2	23	19	19	-4	-4	Igual
C6B3	24	12	12	-12	-12	Igual
C6B4	30	28	29	-2	-1	Mejor
C7B1	36	36	36	0	0	Igual
C7B2	42	42	42	0	0	Igual
C8B1	28	28	28	0	0	Igual
C8B2	36	34	37	-2	1	Mejor
C9B1	33	33	33	0	0	Igual
C9B2	27	27	27	0	0	Igual
C9B3	30	28	29	-2	-1	Mejor
C9B4	35	35	35	0	0	Igual
C10B1	33	33	33	0	0	Igual
C10B2	27	27	27	0	0	Igual
C10B3	30	28	29	-2	-1	Mejor
C10B4	35	35	35	0	0	Igual
C11B1	45	40	43	-5	-2	Mejor
C11B2	47	47	47	0	0	Igual
C12B1	22	22	22	0	0	Igual
C12B2	31	31	31	0	0	Igual
C13B1	21	21	21	0	0	Igual
C13B2	27	28	28	1	1	Igual

Tabla 11: Resultados Cuantitativos Detallados por Evento - Vida Máxima = 3 - Parte 1
Fuente: Elaboración Propia.

Evento	Conteo Real	Conteo Detectado	Conteo con Seguimiento	Diferencia Conteo Detectado - Real	Diferencia Conteo con Seguimiento - Real	Categoría
C14B1	29	29	29	0	0	Igual
C14B2	38	39	39	1	1	Igual
C15B1	39	38	38	-1	-1	Igual
C15B2	50	46	47	-4	-3	Mejor
C16B1	39	38	38	-1	-1	Mejor
C16B2	39	38	39	-1	0	Igual
C17B1	24	24	24	0	0	Mejor
C17B2	27	28	28	1	1	Igual
C17B3	37	37	37	0	0	Igual
C17B4	33	34	34	1	1	Igual
C18B1	29	28	29	-1	0	Mejor
C18B2	23	22	23	-1	0	Mejor
C18B3	37	35	37	-2	0	Mejor
C18B4	30	31	31	1	1	Igual
C19B1	31	31	31	0	0	Igual
C19B2	45	45	45	0	0	Igual
C20B1	61	56	61	-5	0	Mejor
C20B2	79	75	75	-4	-4	Igual
C21B1	21	22	22	1	1	Igual
C21B2	37	37	39	0	2	Peor
C22B1	35	35	35	0	0	Igual
C22B2	27	27	27	0	0	Igual
C23B1	27	27	27	0	0	Igual
C23B2	36	35	35	-1	-1	Igual
C24B1	21	20	20	-1	-1	Igual
C24B2	22	20	21	-2	-1	Mejor
C24B3	40	37	39	-3	-1	Mejor
C24B4	38	39	39	1	1	Igual
C25B1	23	23	23	0	0	Igual
C25B2	28	29	29	1	1	Igual
C25B1	34	34	35	0	1	Peor
C25B2	41	42	42	1	1	Igual
C26B1	32	32	32	0	0	Igual
C26B2	39	38	39	-1	0	Mejor
C27B1	22	20	20	-2	-2	Igual
C27B2	17	17	17	0	0	Igual

Tabla 12: Resultados Cuantitativos Detallados por Evento - Vida Máxima = 3 - Parte 2
Fuente: Elaboración Propia.

Evento	Conteo Real	Conteo Detectado	Conteo con Seguimiento	Diferencia Conteo Detectado - Real	Diferencia Conteo con Seguimiento - Real	Categoría
C27B3	20	20	20	0	0	Igual
C27B4	20	21	21	1	1	Igual
C28B1	29	30	31	1	2	Peor
C28B2	37	37	37	0	0	Igual
C29B1	25	26	26	1	1	Igual
C29B2	33	35	35	2	2	Igual
C30B1	70	62	67	-8	-3	Mejor
C30B2	74	70	70	-4	-4	Igual
C31B1	24	24	25	0	1	Peor
C31B2	27	27	27	0	0	Igual
C32B1	50	46	48	-4	-2	Mejor
C32B2	35	35	35	0	0	Igual
C33B1	33	33	33	0	0	Igual
C33B2	47	44	45	-3	-2	Mejor
C34B1	37	37	37	0	0	Igual
C34B2	33	35	35	2	2	Igual
C35B1	34	34	35	0	1	Peor
C35B2	42	42	44	0	2	Peor
C36B1	28	28	29	0	1	Peor
C36B2	36	36	36	0	0	Igual
C37B1	27	28	28	1	1	Igual
C37B2	38	38	39	0	1	Peor
C38B1	37	37	38	0	1	Peor
C38B2	46	45	46	-1	0	Mejor
C39B1	23	24	24	1	1	Igual
C39B2	30	30	31	0	1	Peor
C40B1	23	23	23	0	0	Igual
C40B2	28	28	28	0	0	Igual
C40B3	32	29	29	-3	-3	Igual
C40B4	33	33	33	0	0	Igual

Tabla 13: Resultados Cuantitativos Detallados por Evento - Vida Máxima = 3 - Parte 3
Fuente: Elaboración Propia.

REFERENCIAS BIBLIOGRÁFICAS

[1] R. Zon, “Forests and human progress,” *Geographical Review*, vol. 10, no. 3, pp. 139–166, 1920. [Online]. Available: http://www.jstor.org/stable/207748

[2] FAO, “Forest product consumption and production,” https://www.fao.org/forestry/statistics/80938@180723/en/, accessed: 2023-09-14.

[3] *Global forest sector outlook 2050: Assessing future demand and sources of timber for a sustainable economy*. FAO, Oct. 2022. [Online]. Available: https://doi.org/10.4060/cc2265en

[4] E. Pardo, , and J. C. Bañados, *Directorio de la Industria Forestal Chilena 2023*. INFOR, 2023. [Online]. Available: https://doi.org/10.52904/20.500.12220/32624

[5] T. Moskalik, . Tymendorf, J. van der Saar, and G. Trzciński, “Methods of wood volume determining and its implications for forest transport,” *Sensors*, vol. 22, no. 16, p. 6028, Aug 2022. [Online]. Available: http://dx.doi.org/10.3390/s22166028

[6] S. Landscheidt and M. Kans, “Automation practices in wood product industries: Lessons learned, current practices and future perspectives,” in *The 7th Swedish Production Symposium SPS, 25-27 October, 2016, Lund, Sweden*. Lund University, 2016.

[7] WOODTECH, “Woodtech,” https://www.woodtechms.com/, accessed: 2023-08-16.

[8] ——, “Logmeter,” https://www.woodtechms.com/logmeter, accessed: 2023-08-16.

[9] R. Szeliski, *Computer vision: algorithms and applications*. Springer Nature, 2022.

[10] R. Klette, *Concise Computer Vision - An Introduction into Theory and Algorithms*, 01 2014.

[11] X. Zhang, X. Wang, and C. Gu, “Online multi-object tracking with pedestrian re-identification and occlusion processing,” *The Visual Computer*, vol. 37, pp. 1089–1099, 2021.

[12] A. Yilmaz, O. Javed, and M. Shah, “Object tracking: A survey,” *Acm computing surveys (CSUR)*, vol. 38, no. 4, pp. 13–es, 2006.

[13] P. Viola and M. Jones, “Rapid object detection using a boosted cascade of simple features,” in *Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001*, vol. 1. Ieee, 2001, pp. I–I.

[14] S. Thrun, M. Montemerlo, H. Dahlkamp, D. Stavens, A. Aron, J. Diebel, P. Fong, J. Gale, M. Halpenny, G. Hoffmann *et al.*, “Stanley: The robot that won the darpa grand challenge,” *Journal of field Robotics*, vol. 23, no. 9, pp. 661–692, 2006.

[15] J. Berclaz, F. Fleuret, E. Turetken, and P. Fua, "Multiple object tracking using k-shortest paths optimization," *IEEE transactions on pattern analysis and machine intelligence*, vol. 33, no. 9, pp. 1806–1819, 2011.

[16] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 779–788.

[17] Z. W. Pylyshyn and R. W. Storm, "Tracking multiple independent targets: Evidence for a parallel tracking mechanism*," *Spatial Vision*, vol. 3, no. 3, pp. 179 – 197, 1988. [Online]. Available: https://brill.com/view/journals/sv/3/3/article-p179_3.xml

[18] M. Fernández-Sanjurjo, B. Bosquet, M. Mucientes, and V. M. Brea, "Real-time visual detection and tracking system for traffic monitoring," *Engineering Applications of Artificial Intelligence*, vol. 85, pp. 410–420, 2019. [Online]. Available: https://www.sciencedirect.com/science/article/pii/S0952197619301691

[19] C. R. del Blanco, F. Jaureguizar, and N. Garcia, "An efficient multiple object detection and tracking framework for automatic counting and video surveillance applications," *IEEE Transactions on Consumer Electronics*, vol. 58, no. 3, pp. 857–862, 2012.

[20] H. Wang, J. Zhu, W. Dai, and J. Liu, "A re-id and tracking-by-detection framework for multiple wildlife tracking with artiodactyla characteristics in ecological surveillance," in *2019 IEEE International Conference on Real-time Computing and Robotics (RCAR)*. IEEE, 2019, pp. 901–906.

[21] X. Fu, K. Zhang, C. Wang, and C. Fan, "Multiple player tracking in basketball court videos," *Journal of Real-Time Image Processing*, vol. 17, pp. 1811–1828, 2020.

[22] D. Zeng, I. Liu, Y. Bi, R. Vennell, D. Briscoe, B. Xue, and M. Zhang, "A new multi-object tracking pipeline based on computer vision techniques for mussel farms," *Journal of the Royal Society of New Zealand*, pp. 1–20, 2023.

[23] M. Bashar, S. Islam, K. K. Hussain, M. B. Hasan, A. B. M. A. Rahman, and M. H. Kabir, "Multiple object tracking in recent times: A literature review," 2022.

[24] A. O' Riordan, T. Newe, D. Toal, and G. Dooly, "Stereo vision sensing: Review of existing systems," 12 2018.

[25] (2011) Visión artificial para todos. [Online]. Available: https://visionartificialparatodos.wordpress.com/2011/01/24/vision-estereoscopica/

[26] L. Lipton, "Foundations of the stereoscopic cinema: a study in depth," *(No Title)*, 1982.

[27] W. R. Sherman and A. B. Craig, "Understanding virtual reality: interface, application, and design," *(No Title)*, 2004.

[28] T. Toutin, "Geometric processing of remote sensing images: models, algorithms and methods," *International journal of remote sensing*, vol. 25, no. 10, pp. 1893–1924, 2004.

[29] P. I. Corke, W. Jachimczyk, and R. Pillat, *Robotics, vision and control: fundamental algorithms in MATLAB*. Springer, 2011, vol. 73.

[30] R. Hartley and A. Zisserman, *Multiple view geometry in computer vision*. Cambridge university press, 2003.

[31] S. N. Sakib, "Lidar technology-an overview," *IUP Journal of Electrical and Electronics Engineering*, vol. 15, no. 1, pp. 36–57, 2022.

[32] D. Scharstein and R. Szeliski, "A taxonomy and evaluation of dense two-frame stereo correspondence algorithms," *International journal of computer vision*, vol. 47, pp. 7–42, 2002.

[33] A. Geiger, J. Ziegler, and C. Stiller, "Stereoscan: Dense 3d reconstruction in real-time," in *2011 IEEE intelligent vehicles symposium (IV)*. Ieee, 2011, pp. 963–968.

[34] R. E Woods and R. C Gonzalez, "Digital image processing," 2008.

[35] M. Freeman, *Pro Photographer's D-SLR Handbook*. Sterling Publishing Company, Inc., 2008.

[36] J. A. Jensen, *Estimation of blood velocities using ultrasound: a signal processing approach*. Cambridge University Press, 1996.

[37] E. Seeram, "Computed tomography image reconstruction," *Radiologic Technology*, vol. 92, no. 2, pp. 155CT–169CT, 2020.

[38] R. E Woods and R. C Gonzalez, "Digital image processing," 2008.

[39] R. E. Kalman, "A new approach to linear filtering and prediction problems," *Transactions of the ASME–Journal of Basic Engineering*, vol. 82, no. Series D, pp. 35–45, 1960.

[40] B. L. Stevens, F. L. Lewis, and E. N. Johnson, *Aircraft control and simulation: dynamics, controls design, and autonomous systems*. John Wiley & Sons, 2015.

[41] B. D. Anderson and J. B. Moore, *Optimal filtering*. Courier Corporation, 2012.

[42] A. Yilmaz, O. Javed, and M. Shah, "Object tracking: A survey," *Acm computing surveys (CSUR)*, vol. 38, no. 4, pp. 13–es, 2006.

[43] N. J. Gordon, D. J. Salmond, and A. F. Smith, "Novel approach to nonlinear/non-gaussian bayesian state estimation," in *IEE proceedings F (radar and signal processing)*, vol. 140, no. 2. IET, 1993, pp. 107–113.

[44] S. Thrun, W. Burgard, D. Fox *et al.*, "Probabilistic robotics, vol. 1," 2005.

[45] M. Isard and A. Blake, "A smoothing filter for condensation," in *Computer Vision—ECCV'98: 5th European Conference on Computer Vision Freiburg, Germany, June, 2–6, 1998 Proceedings, Volume I 5*. Springer, 1998, pp. 767–781.

[46] F. Gustafsson, F. Gunnarsson, N. Bergman, U. Forssell, J. Jansson, R. Karlsson, and P.-J. Nordlund, "Particle filters for positioning, navigation, and tracking," *IEEE Transactions on signal processing*, vol. 50, no. 2, pp. 425–437, 2002.

[47] E. L. Ionides, C. Bretó, and A. A. King, "Inference for nonlinear dynamical systems," *Proceedings of the National Academy of Sciences*, vol. 103, no. 49, pp. 18 438–18 443, 2006.

[48] Q. Wang, X. Zhan, Z. Wu, X. Liu, and X. Feng, "The applications of machine vision in raw material and production of wood products," *Bioresources*, vol. 17, no. 3, p. 5532, 2022.

[49] G. Figueroa-Mata, E. Mata-Montero, J. C. Valverde-Otárola, D. Arias-Aguilar, and N. Zamora-Villalobos, "Using deep learning to identify costa rican native tree species from wood cut images," *Frontiers in Plant Science*, vol. 13, p. 789227, 2022.

[50] N. Kumar, P. N. Belhumeur, A. Biswas, D. W. Jacobs, W. J. Kress, I. C. Lopez, and J. V. Soares, "Leafsnap: A computer vision system for automatic plant species identification," in *Computer Vision–ECCV 2012: 12th European Conference on Computer Vision, Florence, Italy, October 7-13, 2012, Proceedings, Part II 12*. Springer, 2012, pp. 502–516.

[51] M. Carpentier, P. Giguere, and J. Gaudreault, "Tree species identification from bark images using convolutional neural networks," in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2018, pp. 1075–1081.

[52] A. Bewley, Z. Ge, L. Ott, F. Ramos, and B. Upcroft, "Simple online and realtime tracking," in *2016 IEEE international conference on image processing (ICIP)*. IEEE, 2016, pp. 3464–3468.

[53] N. Wojke, A. Bewley, and D. Paulus, "Simple online and realtime tracking with a deep association metric," in *2017 IEEE International Conference on Image Processing (ICIP)*. IEEE, 2017, pp. 3645–3649.

[54] Y. Zhang, C. Wang, X. Wang, W. Zeng, and W. Liu, "Fairmot: On the fairness of detection and re-identification in multiple object tracking," *International Journal of Computer Vision*, vol. 129, pp. 3069–3087, 2021.

[55] L. Chen, H. Ai, Z. Zhuang, and C. Shang, "Real-time multiple people tracking with deeply learned candidate selection and person re-identification," in *2018 IEEE international conference on multimedia and expo (ICME)*. IEEE, 2018, pp. 1–6.

[56] X. Zhou, V. Koltun, and P. Krähenbühl, "Tracking objects as points," in *European conference on computer vision*. Springer, 2020, pp. 474–490.

[57] Y. Zhang, P. Sun, Y. Jiang, D. Yu, F. Weng, Z. Yuan, P. Luo, W. Liu, and X. Wang, "Bytetrack: Multi-object tracking by associating every detection box," in *European Conference on Computer Vision*. Springer, 2022, pp. 1–21.

[58] H. W. Kuhn, "The hungarian method for the assignment problem," *Naval research logistics quarterly*, vol. 2, no. 1-2, pp. 83–97, 1955.