



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

DESARROLLO DE UN MODELO PREDICTIVO PARA IDENTIFICAR LA
PROBABILIDAD DE ROBO DE VEHÍCULOS EN LA CIUDAD DE SANTIAGO

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

BRUNO AYRTON GÓMEZ MONTECINO

PROFESOR GUÍA:
ÁNGEL JIMÉNEZ MOLINA

MIEMBROS DE LA COMISIÓN:
IGNACIO CALISTO LEIVA
RICHARD WEBER HAAS

SANTIAGO DE CHILE
2018

RESUMEN DE LA MEMORIA PARA OPTAR AL
TÍTULO DE: Ingeniero Civil Industrial
POR: Bruno Ayrton Gómez Montecino
FECHA: 10 Septiembre 2018
PROFESOR GUÍA: Ángel Jiménez

DESARROLLO DE UN MODELO PREDICTIVO PARA IDENTIFICAR LA PROBABILIDAD DE ROBO DE VEHÍCULOS EN LA CIUDAD DE SANTIAGO

El robo de vehículos en Santiago, es un fenómeno que se encuentra en aumento en los últimos años. El costo promedio de un vehículo asegurado asciende a cerca de \$6.000.000. Considerando los robos de vehículos ocurridos en el año 2015, sin considerar los vehículos que fueron recuperados, los costos asociados al robo ascienden a un monto cercano a los \$59.910 millones de pesos. No solo hay costos económicos asociados, hay personas que sufren sensación de inseguridad o traumas que deben ser tratados con ayuda psicológica.

En esta memoria se desarrolló un modelo predictivo para la detección de lugares de robo de vehículos en la ciudad de Santiago, basándose en datos proporcionados por la asociación de aseguradoras de automóviles. Además, se utilizaron las siguientes fuentes de información: datos de contexto extraídos de imágenes de los lugares de robo para contar con una caracterización *in situ*; una caracterización de lugares de Santiago en función de puntos de interés social, y variables temporales y de huida. El modelo desarrollado fusiona las fuentes anteriores por medio de diferentes redes neuronales. Los resultados permiten clasificar lugares donde han ocurrido robos con una exactitud del 66%, precisión del 69% y memoria del de 61%.

Se utilizaron también diversas técnicas de aprendizaje profundo para encontrar patrones asociados al robo de vehículos. Dentro de los hallazgos se encuentra una tendencia alta y significativa al robo en lugares cercanos a centros educativos, centros comerciales masivos, centros de belleza tales como gimnasios y centros de estética. También, existe una tendencia al robo al acercarse al Costanera Center y alejarse del centro de Santiago.

Existe mayor propensión de robo en horarios de menor tráfico y al anochecer, mientras que la variable de huida de un lugar definida como la velocidad de escape en este punto, considerando efectos de tráfico no resulto estadísticamente significativa en el estudio.

TABLA DE CONTENIDO

Capítulo I. Introducción	1
Capítulo II. Antecedentes Generales	2
2.1 Proyecto FONDEF	2
2.2 Justificación del tema	2
2.3 Efectos asociados al robo de vehículos en Chile	5
2.3.1 El robo de vehículos	5
2.3.2 Causas asociadas al robo de vehículos	7
Capítulo III. Definiciones de la memoria	8
3.1 Hipótesis	9
3.2 Objetivo General	9
3.3 Objetivo Específicos	10
3.4 Alcances	10
3.5 Resultados esperados	11
Capítulo IV. Marco Conceptual	12
4.1 Trabajos relacionados	12
4.1.1 Estudios sobre el robo de vehículos	12
4.1.2 Estudios sobre otros tipos de robos	13
4.1.3 Estudios usando imágenes de Google Street View	14
4.1.4 Estudios usando imágenes	15
4.2 Modelos de Machine Learning	21
4.2.1 Regresión Logística	21
4.2.2 Random Forest	22
4.2.3 Support Vector Machine	24
4.3 Modelos de Deep Learning	24
4.3.1 Redes neuronales	25
4.3.2 Entrenamiento	32
4.3.3 Sobreajuste en redes neuronales	34
4.4 Métricas de evaluación de modelos	34
Capítulo V. Metodología	36
5.1 Marco referencial	36
5.1.1 Tecnologías utilizadas	36
5.1.2 Herramientas utilizadas	37
5.2 Modelo descriptivo usando imágenes	38
5.3 Proceso KDD	40
5.4 Primera etapa del proceso KDD	41
5.4.1 Lugares de robo y de no robo en Santiago	41
5.4.2 Construcción de base de imágenes usando GSV	45
5.4.3 Construcción de base de capacidad de huida	49
5.4.4 Construcción de base de lugares de interés en Santiago	50
5.4.5 Resumen de bases de datos utilizadas	52
5.4.6 Transformaciones	58
5.4.7 Modelos de predicción implementados	59
5.5 Segunda etapa del proceso KDD	65
5.5.1 Arquitectura de Fusión de datos	65

Capítulo VI. Resultados	66
6.1 Resultados de la primera etapa del proceso KDD	66
6.1.1 Resultados de puntos de interés	66
6.1.2 Resultados de capacidad de huida	70
6.1.3 Resultados de imágenes	72
6.2 Resultados de la segunda etapa del proceso KDD	74
Capítulo VII. Discusión y trabajos futuros	75
7.1 Discusión sobre caracterización geográfica y puntos de interés	75
7.2 Discusión sobre variables temporales y de huida	76
7.3 Discusión sobre predicción usando imágenes	77
7.4 Discusión sobre modelo de fusión de datos	78
7.5 Limitaciones actuales y Propuestas de continuidad de trabajo	80
7.6 Otras áreas de investigación y posibles aplicaciones	81
Capítulo VIII. Conclusiones	84
Capítulo IX. Bibliografía	85
Capítulo X. Apéndices	90
10.1 Apéndice A: Imágenes de Google Street View	90
10.2 Apéndice B: Imágenes de Plan Cuadrante	90
10.3 Apéndice C: Información contenida en Base de AACH	91
10.4 Apéndice D: Modelo Descriptivo	92
10.5 Apéndice E: Categorías secundarias de puntos de interés	93
10.6 Apéndice F: Descripción de variables de puntos de interés	94
10.7 Apéndice F: Detalle resultados modelo logit Puntos de interés	102
10.8 Apéndice G: Detalle modelo logit de Capacidad de huida	104
10.9 Apéndice H: Entrenamiento con imágenes	105

Capítulo I. Introducción

Cerca del 22% de los registros de delitos al patrimonio y de mayor connotación social (DMCS) en el año 2017 se encuentran relacionados al robo de autos o sustracción de objetos de o desde un vehículo y cerca del 98% de estos delitos están actualmente sin detenidos, donde la mayor concentración de estos se encuentra en la Región Metropolitana con un 45%.

Aproximadamente cerca de 8000 robos y hurtos de vehículos asegurados ocurren al año según una base de datos de siniestros de la Asociación de aseguradoras de autos de Chile (AACH). Esta situación resulta un problema en lo económico considerando que los vehículos asegurados en promedio tienen un avalúo cercano a los 6 millones de pesos. Además, existe un daño psicológico ya que las personas que sienten vulnerada su seguridad, llegando algunos a requerir asistencia psicológica para poder recuperarse y superar estos eventos de estrés.

Este fenómeno es un problema para las personas, empresas privadas como aseguradoras e instituciones estatales, donde destacan las municipalidades y carabineros de Chile por su rol en la prevención y recuperación de vehículos robados. Como consecuencia de este fenómeno, parte del presupuesto público es destinado a financiar proyectos que mejoran las condiciones de seguridad e incentivan propuestas de investigación con el fin de abordar y mitigar este problema.

El proyecto de memoria abordado surge como uno de los proyectos de investigación asociado a un fondo de fomento al desarrollo científico y tecnológico (FONDEF), el cual tiene como objetivo desarrollar un observatorio digital de delincuencia, diseñando un sistema inteligente de apoyo a las instituciones públicas y privadas, para disminuir el número de delitos.

La memoria, tiene por objetivo caracterizar el robo de automóviles, usando información geográfica, basándose en información proporcionada por Google y la base de datos de siniestros de la AACH. La memoria consta de tres secciones relevantes. En primer lugar, Levantar bases de datos de imágenes de las calles por medio de Google Street View (GSV), para conocer el robo *in situ*, encontrar puntos de interés social en Santiago, para caracterizar socialmente un punto de robo e información del tráfico para caracterizar la huida de un lugar. En segundo lugar, aplicar técnicas de *machine learning* y *deep learning* a cada fuente de datos por separado, para caracterizar y encontrar patrones asociados al robo. En tercer lugar, elaborar un modelo de predicción de robo de vehículos en Santiago integrando las fuentes de datos.

Capítulo II. Antecedentes Generales

2.1 Proyecto FONDEF

La memoria surge por medio de un Fondo de Fomento al Desarrollo Científico y Tecnológico (FONDEF) entregado por el Gobierno de Chile. El proyecto comprende la creación de un observatorio digital de delincuencia en Chile que busca desarrollar un sistema inteligente de apoyo a la industria de aseguradores chilena y a carabineros de Chile. La fecha de inicio y termino son 01/11/2016 y 01/11/2018 respectivamente y su código de identificación es *ID16I10222*.

El objetivo es desarrollar un observatorio digital capaz de caracterizar el *modus operandi* de los delincuentes en el robo de autos. Se busca entender de mejor manera cómo funciona el *modus operandi* de los robos de vehículos para posteriormente reducir el número de delitos de este tipo, por medio del diseño de un sistema de monitoreo y posteriormente un observatorio del robo de automóviles en Chile por medio de levantamiento y análisis de información.

La investigación se está llevando a cabo con investigadores de los departamentos de Ingeniería Industrial, de Ciencias de la Computación y la Universidad Católica. Este proyecto cuenta con diversas líneas de investigación en las que destaca un proyecto de investigación que tiene por objetivo estudiar el fenómeno de los robos haciendo uso de algoritmos de extracción de datos de las redes sociales y medios digitales. Esta memoria se enmarca en realizar un modelo que permita predecir y caracterizar los robos de automóviles de Santiago utilizando tecnologías de *deep learning*, *machine learning* y herramientas computacionales de Google y Amazon.

2.2 Justificación del tema

El robo de vehículos tiene una tendencia al aumento [A1] y para las personas esto representa una preocupación porque el robo puede afectar su patrimonio e integridad. Los costos económicos en ocasiones incluyen la compra de un nuevo vehículo, terapias psicológicas, contratación de servicios de seguridad o compra de productos tecnológicos como cámaras, contratación de seguros, servicios de monitoreo remoto, corta corriente u otros [A2]. Los costos sociales asociados al robo de vehículo, pueden producir reacciones fisiológicas y psicológicas como inseguridad, estrés, depresión u otros trastornos [A3], [A4].

En términos económicos, hay estudios que estiman que el costo por evento, llevado a dólares en el año 2010, sin considerar casos donde hubo fallecidos tiene un costo cercano a los US\$9.300 dólares para los estadounidenses (Economic Costs of Crime – Chalfin, 2014). En el año 2014, el robo de vehículos en Estados Unidos involucró costos por más de \$4.5 millones de dólares a nivel nacional [A1], [A5].

En lo que a robos con violencia se refiere, existe una gran preocupación del estado y la población, esto debido a la serie de reacciones psicológicas y fisiológicas que produce haber sido víctima de un robo (con y sin violencia). Usualmente, las personas que se enfrentan a este tipo de experiencias sufren por la idea de perder la vida o un ser querido, sufrir lesiones físicas de diversa consideración y/o además viven una sensación de impotencia.

En ocasiones, las personas afectadas por un robo con violencia requieren de terapia psicológica porque sufren un episodio de stress postraumático, donde pueden aparecer emociones de horror o indefensión. En un estudio se encontraron 22,6% de los sujetos expuestos a un asalto desarrollaron un Trastorno por Estrés Postraumático (Breslau N, 1991) lo cual puede estar acompañado de pesadillas, desconfianza social, alteraciones del sueño, irritabilidad, angustia, crisis de pánicos y otro tipo de manifestaciones psicológicas. Cabe destacar que los robos sin violencia también pueden llegar a producir efectos psicológicos negativos en las personas, aunque en un menor grado.

Las personas y familias no son los únicos involucrados y afectados con el robo de vehículos, también estas otras organizaciones del Estado como Carabineros de Chile y privadas como las aseguradoras, bancos u otros. Estas organizaciones destinan recursos monetarios y tiempo, buscando dar solución al problema de la delincuencia.

Los autos son robados según la Asociación de Aseguradores de Chile (AACH) para el desarme y venta de piezas, las cuales son utilizadas y compradas como repuesto, porque los precios son menores y hay locales que venden artículos robados. Otros vehículos son robados para ser revendidos o como medio de transporte para realizar otro tipo de delitos, como asaltos, *portonazos*, robos a cajeros automáticos, hogares, locales comerciales o estaciones de servicios, entre otros.

Los robos de vehículo son los que tienen el mayor nivel de impunidad, cercana al 99%. Esta cifra comparada con el resto de los delitos que atentan contra la propiedad es de las más altas y el promedio de impunidad es cercano al 80%, como se puede observar en la tabla 1.

Provincia de Santiago	Total de casos	Sin detenidos	Ratio impunidad
Robo con Violencia	782	737	0.942
Robo con Intimidación	2454	2364	0.963
Robo por Sorpresa	1370	1229	0.897
Lesiones	1663	1292	0.777
Homicidios	18	12	0.667
Violaciones	64	55	0.859
DELITOS VIOLENTOS	6351	5689	0.896
Robo de vehículo	973	966	0.993
Robo objeto de o desde Vehículo	2221	2207	0.994
Robo en lugar habitado	1068	999	0.935
Robo en lugar no habitado	841	741	0.881
Otros robos con fuerza	215	185	0.86
Hurtos	3989	2385	0.598
DELITOS CONTRA LA PROPIEDAD	9307	7483	0.804

Tabla 1: Número de delitos en Chile [Elaboración propia con datos del departamento de análisis criminal, Carabineros de Chile]

Actualmente, la metodología en que se aborda este tipo de delitos desde la prevención, investigación y sanción tienen un bajo nivel de sofisticación y a su vez un bajo nivel tecnológico para analizar estos fenómenos [A1].

La mayoría del conocimiento se tiene por la experiencia. Existen escasas herramientas tecnológicas en Chile para caracterizar, geolocalizar, visualizar patrones y predecir robos o zonas de riesgo. Algunas de las soluciones tecnológicas empleadas que contribuyen a combatir los delitos se encuentran en Carabineros de Chile, destacando la página de Plan cuadrante¹ y un software que define donde ocurrirán los delitos².

La página de plan cuadrante es un modelo de gestión policial comunal, el cual por medio de los patrullajes de carabineros en la ciudad van levantando información respecto a factores de riesgo situacional, social, vial y de incendios forestales. Indicando la ubicación exacta, por medio de su geolocalización, una descripción del factor de riesgo y fotografías de la situación. Algunos de los ejemplos que se pueden encontrar son lugares con luminarias quebradas, iluminación deficiente, problema de aceras en mal estado, donde se informa también, los días que lleva sin solución (Para ver imágenes ir a Apéndice B: Imágenes de Plan Cuadrante).

¹ Plan Cuadrante 20 Carabineros de Chile. Sitio web: <http://plancuadrante20.carabinerosdechile.cl/> (consultado 10 Abril 2018).

² Consulta digital. Sitio web: <http://www2.latercera.com/noticia/carabineros-usara-primer-software-capaz-predecir-donde-ocurriran-delitos> (consultado 10 Abril 2018).

El software que define los patrullajes de carabineros consiste en un modelo de predicción de delitos que permite reorganizar los patrullajes buscando reducir la criminalidad en las calles, haciendo uso de información histórica de la institución. Según el departamento de Análisis Criminal de Carabineros y jefe de la sección de Información territorial este software es capaz de predecir probabilidades de ocurrencia de delitos entre un 35% a 40% lo que está en línea con otros softwares internacionales.

2.3 Efectos asociados al robo de vehículos en Chile

2.3.1 El robo de vehículos

Según los datos de AACH, el número de robo de vehículos ha ido al alza, el año 2015 se registra la mayor cantidad de robos históricos de la base de datos, correspondiente a un total de 9.985. Si se compara el 2015 con el 2011, a hubo un aumento del 30% respecto al 2011. Entre enero y abril del 2017 ya han sido levantados 3.052 casos de siniestro de vehículos asegurados por robo. Según el DERV, la tasa de hallazgo de autos robados ha bajado³.

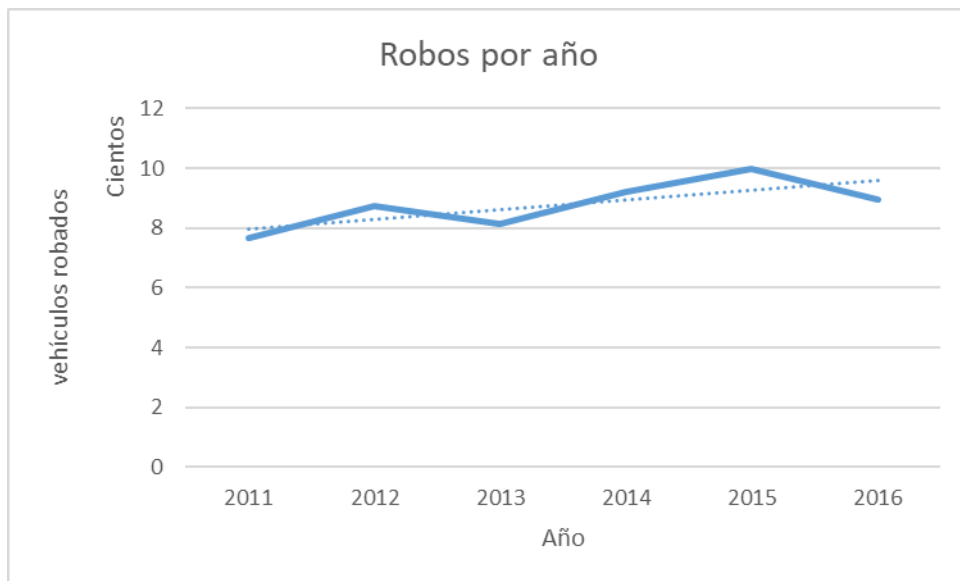


Ilustración 1: Evolución del robo de vehículos asegurados en Chile [Elaboración propia en base a datos de la AACH]

El costo promedio de un vehículo asegurado calculado a partir de la base de siniestros de AACH, asciende a cerca de \$6.000.000. Considerando los robos de vehículos ocurridos en el año 2015, sin considerar los vehículos que fueron recuperados, los costos asociados al robo ascienden a un monto cercano a los

³ Consulta digital AACH, Sitio Web:

<http://portal.aach.cl/Noticia.aspx?N=792&T=Un%20auto%20asegurado%20por%20hora%20se%20roba%20en%20Chile:%20volumen%20sube%206%25%20a%20abril> (Consultado 05 Abril 2018).

\$59.910 millones de pesos. Considerando la tasa de recuperación de vehículos de [A1] para el año 2015, correspondiente al 63%, entonces el monto asciende a \$22.166 millones de pesos, sin considerar daños que puedan tener los vehículos recuperados.

Analizando la distribución de delitos contra la propiedad entre los años 2012 y 2016 en la Ilustración 2, el comportamiento de estos delitos no presenta cambios significativos. Se aprecia una leve disminución porcentual de robo de vehículos respecto al resto de los delitos, aunque esto en ningún caso implica una disminución del robo de vehículos, mas bien, podría indicar un aumento más significativo en otro tipo de delitos.




Ilustración 2: evolución de la distribución de delitos. [Elaboración propia con datos del departamento de análisis criminal, Carabineros de Chile]

Analizando geográficamente la concentración de delitos en la Ilustración 3, la mayoría se concentra en la región metropolitana, con un valor aproximado al 43%. En la región metropolitana también la cantidad de habitantes es cercana a los 7.12⁴ millones aproximadamente y es también donde se encuentra la mayor concentración de la población en Chile.




Ilustración 3: Distribución de delitos según ubicación [Elaboración propia con datos del departamento de análisis criminal, Carabineros de Chile]

⁴ Resultados Censo 2017. Sitio Web <https://resultados.censo2017.cl/Region?R=R13> (Consultado 04 Septiembre 2018).

2.3.2 Causas asociadas al robo de vehículos

Dentro de las causas asociadas al problema, encontramos que los recursos son limitados. Carabineros de Chile no puede cubrir cada una de las calles de Santiago aumentando la presencia de patrullas, debido a los costos económicos y humanos que una decisión como esta involucra. Las patrullas llevan a cabo sus actividades y patrullajes dependiendo del conocimiento y experiencia de los robos.

El estado invierte en seguridad modernizando y aumentando los elementos de seguridad, aumentando la iluminación de los lugares, contratando cuidadores, entre otros. Aun así, pero estas inversiones y acciones no han sido suficientes para combatir la delincuencia.

Se desconoce parte del *modus operandi* de los delincuentes lo que impide anticiparse. Carabineros conoce las razones por lo cual los vehículos son robados y entrega recomendaciones sobre medidas de resguardo para evitar el robo de vehículos. Conocen también que hay comunas en las que hay mayor concentración de robos de vehículos. Sin embargo, no se tiene certeza sobre cómo el entorno afecta la decisión de robo, es decir, cuáles son los puntos de interés social que hacen más propenso un lugar al robo, o qué factores temporales influyen más, como el tráfico o el horario.

Lo anterior va en línea con estudios que emplean información de múltiples fuentes como demográfica, económica, educacional y del clima en la predicción y ocurrencia de robos [A6], [A7], [A8]. Hay estudios que indican que la apariencia y composición social de los barrios afecta la actividad criminal [A9], esto da una idea que la información de contexto está directamente relacionada a los crímenes.

Aumentar el nivel de conocimiento sobre el *modus operandi* podría permitir mejorar las rutas de patrullaje y tener un mayor conocimiento de las zonas de riesgo de Santiago.

Existen lugares en Santiago donde hay mayor propensión al robo de vehículos, esto se debe a que estas zonas en Santiago tienen una vulnerabilidad mayor. Las razones que explican esta situación son variadas, tales como la poca vigilancia, ausencia de cámaras de seguridad, falta de iluminación, lugares escondidos, poca visibilidad por la vegetación, entre otras. La existencia de zonas de mayor vulnerabilidad se debe a la toma de decisiones racionales por parte de los ladrones, quienes según [A10] buscan maximizar su beneficio y minimizar el riesgo.

Carabineros de Chile advierte la existencia de algunas de estas zonas y entrega las siguientes recomendaciones⁵ a los conductores: Estacionar en lugares seguros e iluminados, dejar los vehículos con llave y seguros activados, verificar permanentemente el estado de las cerraduras y seguros, no dejar artículos o documentación a la vista, usar traba volante y freno de manos o instalar dispositivos de seguridad como corta corriente u otros. La literatura señala que hay características que hacen más vulnerable un lugar al robo, por lo que hay una oportunidad de estudiar cómo el contexto influye en el robo de vehículos.

Una solución posible a los problemas de recursos y desconocimiento al *modus operandi* de los delincuentes es predecir las probabilidades de robo de vehículos en función de datos de contexto, aplicando diferentes técnicas de ingeniería como *machine learning* y *deep learning*. Obtener resultados de esto permitiría a la policía mejorar la performance y efectividad en la predicción de lugares de riesgo en Santiago.

Capítulo III. Definiciones de la memoria

La memoria de título busca saber hasta qué punto los modelos de *machine* y *deep learning* son capaces de caracterizar y predecir el robo de vehículos usando información de contexto, por medio de imágenes de Santiago, información de puntos de interés social, variables temporales y de huida de un lugar.

Se definen a continuación algunas variables estudiadas en la memoria:

- Cercanía al centro de la ciudad y a un centro comercial: Se calcula usando la distancia que existe entre el punto de robo y el centro de Santiago y el Costanera center. En el caso de la memoria se utiliza como centro de Santiago la Plaza de Armas.
- Capacidad de huida: Puede ser definida en función de la facilidad que tiene un vehículo para huir de un lugar. Las variables más relevantes son la congestión que existe en un lugar y la dificultad de desplazamiento que puede recorrer un automóvil. Esto, puede ser capturado a través de la distancia que recorre un vehículo para desplazarse a cierto lugar y al tiempo que se demora en una hora particular, ambas variables pueden ser obtenidas por medio de servicios de Google.
- El tipo y concentración de puntos de interés social en un lugar: se estudia el contexto de un lugar por medio de los puntos de interés social cercanos, como colegios, supermercados y otros (Mas detalle en

⁵ Campaña preventiva de robos de vehículos. Sitio Web: <http://www.emol.com/noticias/nacional/2007/01/08/241526/carabineros-lanzo-campana-preventiva-para-evitar-robos-de-vehiculos.html> (Consultado 05 Marzo 2018)

Apéndice E: Categorías secundarias de puntos de interés donde se muestran las categorías estudiadas).

- Temporalidad: Definiendo ventanas de tiempo de dos horas en el día, para estudiar si existe mayor concentración de robos en algunas horas del día y también medir aspectos temporales como el tráfico.
- Características *in situ* de los lugares: Esto puede ser recopilado a través de imágenes de las calles de Santiago usando Google Street View (GSV)

3.1 Hipótesis

Basado en la literatura se postula que las variables que influyen en el hurto de vehículos pueden resumirse en las siguientes hipótesis:

Es posible por medio de redes convolucionales y modelos tradicionales de *machine learning*, predecir la ocurrencia de robo en un lugar de Santiago con un buen desempeño, usando información de contexto por sí sola y conjuntamente.

Adicionalmente se proponen las siguientes hipótesis:

- Es posible predecir lugares donde han ocurrido robos de vehículo por medio de la caracterización de puntos de interés
- Existen puntos de interés de mayor relevancia para predecir lugares donde han ocurrido robos de vehículo
- Es posible predecir lugares donde han ocurrido robos de vehículos usando variables que caracterizan el tráfico
- Es posible utilizar imágenes para encontrar lugares y zonas donde han ocurrido robos
- Existe una mayor tendencia a que el robo de vehículos ocurra en el centro de la ciudad y en un centro comercial
- Las condiciones del tráfico influyen en el robo de vehículos
- Existe un efecto asociado a la hora del día en el robo de vehículos
- Los factores ambientales en conjunto tienen mayor capacidad explicativa que por sí solos

3.2 Objetivo General

Esta memoria tiene como objetivo general:

"Determinar los factores que afectan el riesgo de robos de automóviles en zonas y lugares de Santiago para contribuir a mejorar la capacidad de identificación de lugares riesgosos"

3.3 Objetivo Específicos

Como objetivos específicos relacionados a la estructura de los datos necesarios para la memoria, se encuentran:

- Encontrar lugares donde no han ocurrido robos de vehículos en Santiago.
- Generar una base de datos de imágenes de Santiago.
- Generar una base de datos de puntos de interés a lo largo de Santiago.
- Generar una base de datos de las condiciones de tráfico de diferentes lugares de Santiago.
- Caracterizar los lugares de Santiago en función de puntos de interés, condiciones de tráfico, imágenes y ocurrencia de robos.

Para caracterizar y encontrar patrones de robo:

- Aplicar técnicas de *machine learning* para encontrar patrones y predecir lugares donde han ocurrido robos de vehículos.
- Analizar la influencia y efecto de los puntos de interés en los lugares asociados al robo de vehículos.
- Analizar la influencia y efecto de las condiciones de tráfico y factores temporales asociados al robo de vehículos.

Para la predicción de la ocurrencia de robos de vehículo:

- Aplicar técnicas de *deep learning* para predecir lugares y zonas donde han ocurrido robos usando información de imágenes y puntos de interés.
- Entrenar y evaluar modelos de *machine learning* y *deep learning*.

3.4 Alcances

Los alcances de esta memoria involucran estudiar el fenómeno de robo de vehículos solo en la ciudad de Santiago de Chile, para automóviles, camionetas, todo terreno y Station Wagon asegurados. La razón de elegir Santiago se debe a la gran concentración de robos en Santiago lo que permite utilizar técnicas *deep learning*.

Las comunas estudiadas en esta memoria corresponden a Cerrillos, Cerro Navia, Conchalí, El Bosque, Estación Central, Huechuraba, Independencia, La Cisterna, La Florida, La Granja, La Pintana, Las Condes, Lo Barnechea, Lo Espejo, Lo Prado, Macul, Maipú, Ñuñoa, Padre Hurtado, Pedro Aguirre Cerda, Peñalolén, Providencia, Pudahuel, Puente Alto, Quilicura, Quinta Normal, Recoleta, Renca, San Bernardo, San Joaquín, San Miguel, San Ramon, Santiago, Vitacura.

La selección de estas comunas y de tipo de vehículos se debe a que concentran la mayor cantidad de datos de la AACH. Al tener una mayor cantidad de datos, también permite poder estudiar el fenómeno de robo de vehículos de una forma más consistente y robusta. Esto, también es una consecuencia de que el enfoque de la memoria es estudiar el fenómeno usando técnicas de *deep learning* y esta técnica requiere una cantidad de datos mayor que otros modelos convencionales de estadística.

Esta memoria solo comprende el estudio de factores de contexto asociados al robo de vehículos, por lo que no se consideran características del vehículo. Dentro de los factores de contexto se aborda el estudio de puntos de interés social que existen en la ciudad, el tráfico, para estudiar el comportamiento de huida de un lugar y características físicas del lugar in situ.

La razón de considerar factores ambientales y factores asociados al robo de vehículos en esta memoria se debe a que existe conocimiento sobre el comportamiento y patrones de robo de vehículos según tipo, valor y marca. Esto fue constatado en reuniones de trabajo del FONDEF. Por otro lado, hay una oportunidad en generar conocimiento sobre cómo el ambiente afecta a la decisión de robo.

Evidencia de esto es que los modelos de riesgo utilizados consideran cómo información más relevante las características del vehículo, datos del conductor y existencia de siniestros de este. No consideran información sobre el comportamiento del conductor como traslados, lugares donde se estaciona y horarios de desplazamiento. Por lo tanto, esta memoria contribuye también en dar un paso para ir considerando estas nuevas dimensiones.

3.5 Resultados esperados

Se espera que, al terminar la memoria, se cumpla con entregar:

- Base de datos de imágenes asociadas a lugares donde el robo de vehículos asegurados en Santiago es frecuente y donde no lo es.
- Base de datos con información de puntos de interés de la ciudad de Santiago.
- Modelo descriptivo de un lugar de Santiago.
- Modelo predictivo del robo de vehículos usando imágenes de Google Street View (GSV).
- Análisis sobre características de contexto influyentes en el robo de vehículos.
- Modelos de probabilidad de robo de un vehículo para Santiago.

- Metodología para la detección de características relevantes para el robo.

Capítulo IV. Marco Conceptual

4.1 Trabajos relacionados

4.1.1 Estudios sobre el robo de vehículos

Wash & Taylor (2007) [ERV1] estudiaron los elementos demográficos que influyen en los índices de robos de vehículos, sus conclusiones son que el nivel socioeconómico influye, donde a menor nivel socioeconómico hay mayor cantidad de robos.

Levy & Tartaro (2009) [ERV2] realizan un estudio comparando entre quienes han experimentado un robo de vehículos y más de uno para cinco variables en New Jersey, Copes y Cherbonneau (2006) presentan el caso de robo de llaves de vehículos. A partir de ambos estudios se puede concluir que los ladrones son racionales al cometer un delito.

Roberts (2012) [ERV3] realiza un estudio sobre la recuperación de vehículos robados, los resultados indican que los vehículos con menor probabilidad de ser encontrados son aquellos que tienen menor valor y también aquellos robos que ocurrieron cerca de las fronteras de Estados Unidos y México

Zulkifli, Ismail, & Razali (2013) [ERV4] hacen uso de modelos de regresión para analizar los robos de vehículos en Malasia, obtuvo que los vehículos con mayor propensión de robo son aquellos que tienen sobre ocho años de antigüedad, más de 1800 centímetros cúbicos, autos locales y aquellos que se encuentran en zonas céntricas

Suresh & Tewksbury (2012) [ERV5] analizan el robo de vehículos en la ciudad de Louisville en Kentucky para detectar las zonas más riesgosas de la ciudad. Destacan que la falta de cohesión social incide negativamente en la probabilidad de robo. Por otro lado, indica que las zonas donde hay un gran número de vehículos son más propensas a los robos.

Existen investigaciones que indican que estacionamientos residenciales en la acera y los estacionamientos públicos son lugares comunes para el robo de autos (Webb et al, 1992). Por otro lado, Gulliver (1991) y McCullough (1990) sugieren que los estacionamientos residenciales en la acera tienen mayor riesgo, mientras que los estacionamientos fueron identificados por Briggs (1991) con un alto riesgo (53%). Por lo tanto, si bien la evidencia no es concluyente respecto a cuál tipo de estacionamiento es más riesgoso, si existe claridad que son un foco potencial de robo.

Existen algunas características temporales que afectan en la conducta de los ladrones, por ejemplo, un 40% prefiere cometer robos en la oscuridad. Un 8% realiza sus delitos durante el día y el resto delinquen a cualquier hora del día.

Según una encuesta británica sobre crímenes de 1982 muestra que las áreas de mayor riesgo de robo son los estacionamientos de autos, centros comerciales, las vías de las calles y estacionamientos de clubes (NRMA 1989 Car Theft in New South Wales) y la mayoría de los delitos ocurría en la noche.

4.1.2 Estudios sobre otros tipos de robos

Bernasco, W., & Nieuwbeerta, P. (2004) estudian el fenómeno de robo de casas aplicando un modelo Logit condicional con y sin heterogeneidad para estudiar las variables: Nivel de heterogeneidad étnica; viviendas unifamiliares; Número potencial de objetivos en la zona de robo; Proximidad entre el lugar de robo y la vivienda del ladrón; movilidad o rotación residencial; riqueza esperada por el ladrón; proximidad de la zona de robo al centro de la ciudad. Los resultados obtenidos indican que solo las variables de viviendas unifamiliares, heterogeneidad étnica, proximidad al centro de la ciudad y el número potencial de objetivos de la zona de robo son significativos. También, encontraron que existe diferencia en el patrón de comportamiento de los ladrones jóvenes y según etnia.

Townsley, M., Birks, D., Ruitter, S., Bernasco, W., & White, G. (2016), estudiando el fenómeno de robo de casas han utilizado un modelo mixed logit y logit condicional para estudiar las variables: riqueza esperada del robo; Cohesión social; Vulnerabilidad del objetivo; Proximidad entre el lugar de robo y la vivienda del ladrón; Proximidad entre el lugar de robo y el centro de la ciudad; Número potencial de objetivos.

En resumen, en el caso de robos a casas, existen algunas dimensiones sobre las cuales los ladrones basan su elección, la accesibilidad a la propiedad, la expectativa de riqueza de la residencia, la facilidad de escape, nivel de vigilancia de la casa y otras.

Bernasco y Kooistra (2010; 2010b) indica que las zonas habitadas con mayor antigüedad también tienen una propensión mayor al robo que otras áreas que tienen sectores residenciales nuevo o no habitados. (Clare, 2009) asegura que existen barreras físicas (ríos y autopistas) y algunas condiciones del transporte público que influyen en la decisión. Por otro lado, (Bernasco, 2006) indica que las preferencias espaciales, es decir, el contexto físico del lugar donde ocurre el robo no afecta de forma diferente cuando los ladrones operan en grupos o individualmente.

Frith, M. J., Johnson, S. D., & Fry, H. M. (2017) usando un mixed logit aborda el fenómeno de robo de casas desde otra perspectiva, considerando variables

asociadas a las calles, particularmente caracterizándolas en función de la distancia y velocidad por la cual se puede transitar, viendo las calles de la ciudad como un grafo, con el objetivo de poder estimar de esta forma si la facilidad en la huida es una variable influyente para los ladrones.

Puede observarse por medio del análisis de robo de casas es que los robos tienen una conducta racional y los ladrones se comportan según patrones que depende tanto de características físicas, sociales y personales.

En [G1*] con el objetivo de mejorar los niveles de predicción de crimen utilizan una red neuronal profunda utilizando múltiples conjuntos de datos de Chicago e Illinois en EEUU, que aportan información del contexto ambiental, usando imágenes de GSV, información espacial y temporal. El modelo entrenado corresponde a una red que emplea una fusión de datos que consiste en una red CNN y dos redes convencionales con varias capas de neuronas, en que al final de estas tres redes, los outputs de cada red se fusionan y pasan por una cuarta red para clasificar el fenómeno de ocurrencia de crimen. Los resultados que obtienen son del orden del 84% de *precision*, 74% de *recall* y 83% de *AUC*.

4.1.3 Estudios usando imágenes de Google Street View

Otro tipo de investigaciones [B1], [B2], [B3] señalan que Google Street View es una herramienta útil para el estudio y caracterización de un lugar. Algunos de los estudios requieren la observación directa a través de un trabajo de campo, donde los observadores conducen o caminan por los vecindarios (Rundle, Bades, Richards, Neckerman, Teittler, 2011; Sampson y Raudenbush, 1999). Estas inspecciones en campo permiten a los observadores evaluar las condiciones del vecindario y medir u obtener algunas relaciones o características del crimen u otro tipo de conducta social (Jones, Pebley, Sastry, 2011).

Google Street View aparece ante este tipo de estudio como una herramienta atractiva porque las inspecciones en terrenos son prohibitivas en costos y poco practicas si se requiere levantar información global a nivel regional o nacional, en múltiples áreas o áreas muy lejanas (Odgers, Caspi, Bates, Sampson y Moffitt, 2012; Rundle 2011).

Sin embargo, también GSV tiene algunas limitaciones como la temporalidad. Lo anterior se refiere a que la mayoría de las imágenes que se pueden recuperar usando la API de GSV de Google no son fotos actuales y tienen fechas de captura diferentes.

En ocasiones, se constató en visitas a terreno que a diferencia de las imágenes de GSV en la realidad habían hecho algunas construcciones o había periodos de arreglos, por lo que hay información que podría no ser capturada. Otro tipo

de limitaciones tienen que ver con los ángulos y el nivel detalle que se puede capturar en fotos a diferencia de lo que se puede ver presencialmente, por GSV podrían no poder verse algunos sectores de los barrios porque al momento de la foto algunos autos impiden la visión de algunos sectores, tampoco se pueden apreciar en detalle factores como grafitis, daños en la infraestructura de los edificios, suciedad en el suelo, deterioro del pavimento y otros elementos que podrían no ser capturados.

Sin embargo, pese a las limitaciones la literatura indica que el conocimiento generado por medio del análisis de imágenes de Google puede ser empleado para analizar un lugar.

En [B4] usando imágenes de Google Street View y redes CNN, demuestran que es posible predecir los establecimientos alrededor de la imagen tales como hospitales u otro tipo de establecimientos. Adicionalmente, muestran que es posible medir ratios de crímenes en un área mirando una escena.

En [B5] estudian la habilidad de las redes CNN para predecir a que ciudad pertenecen las imágenes usando 100.000 un conjunto de datos de imágenes de Google Street View de 10 ciudades de diferentes países. Los resultados obtenidos respaldan que las redes CNN son capaces de clasificar las imágenes a la ciudad que pertenecen. Cinco ciudades tienen un *accuracy* sobre el 75%, mientras que solo dos ciudades tienen porcentajes de *accuracy* menores al 40%. Si se compara la clasificación de la red con una clasificación aleatoria del 10%, los resultados obtenidos son bastante buenos.

4.1.4 Estudios usando imágenes

En primer lugar, para tener una idea de cómo los modelos de clasificación de imágenes y detección de objetos han sido utilizados en la literatura es necesario tener conocimiento sobre cuales son algunos de los problemas a los que se ha buscado dar solución y sobre los cuales los clasificadores han sido entrenados y evaluados:

- CIFAR-10: Consiste en un conjunto de 60.000 imágenes de 10 clases a color de 32x32. Cuenta con 6.000 imágenes por clase, las cuales son usadas para entrenar distintos modelos de clasificación de imágenes y determinar su rendimiento. Para su uso se usan 50.000 imágenes para entrenamiento y 10.000 para test, correspondientes a 5000 y 1000 por clase.
- CIFAR-100: Este conjunto de datos a diferencia de CIFAR-10 contienen 100 clases y solo 600 imágenes por clase, por lo que para los entrenamientos se utilizan 500 y 100 para test por cada clase.
- PASCAL VOC es un conjunto de datos que nació el año 2006 con el objetivo de realizar una competencia sobre clasificación, segmentación

y detección de objetos en imágenes, este conjunto de datos es público y contiene 20 clases, conteniendo imágenes obtenidas desde Flickr, por lo que hay imágenes de la ciudad, calles, estaciones, etc.

- MNIST: Consiste en un conjunto de datos de dígitos escritos a mano, el cual cuenta con 60.000 ejemplos para entrenamiento y 10.000 para testear
- SVHN: Corresponde a un conjunto de datos que es similar al MNIST, a diferencia de que este incorpora una cantidad mayor de imágenes de dígitos y proviene de un problema significativamente complejo del mundo real, correspondiente a reconocer dígitos y números en imágenes de casas, edificios u otras construcciones en las calles.
- IMAGENET⁶: Corresponde a un conjunto de datos utilizado para la evaluación y competencias para la detección y localización de objetos en imágenes o videos. Cuenta con 1.2 Millones de imágenes de entrenamiento, 50.000 imágenes en el conjunto de validación y 150.000 imágenes de test, con cerca de 1000 imágenes en cada categoría. Se encuentran imágenes de distintas plantas, animales, vehículos, etc.

Uno de los modelos desarrollados y utilizados para la clasificación de imágenes tiene que ver con *Neares Neighbor Classifier* (NNC). Sin embargo, las investigaciones sobre su capacidad para clasificar imágenes no son buenas. En [Z1] se entrena un modelo usando los datos de CIFAR-10 obteniendo una capacidad predictiva cercana al 34%.

Algunas ventajas de este método son su fácil implementación e interpretación. Adicionalmente, este método de clasificación tiene costos computacionales de entrenamiento casi inexistentes en comparación a los modelos basados en redes neuronales. Sin embargo, una vez entrenado, la clasificación de una imagen es más costosa dado que debe hacer una comparación con cada imagen usada en el entrenamiento y en comparación con las redes una vez que ha sido entrenado, la tarea de clasificación más rápida.

Support Vector Machine (SVM) agrega una nueva característica correspondiente a una función de puntajes, que luego es utilizado en redes. SVM optimiza minimizando las funciones de costo sobre los parámetros de la función de puntaje. El rendimiento de este método predictivo en [Z2] es probado con CIFAR-10, alcanzando aproximadamente un desempeño del 39%. La técnica de *random forest* tiene un rendimiento cercano al 49% y las redes neuronales *multy-perceptron* con 100 neuronas tienen una performance cercana al 49%.

⁶ Este conjunto de datos también se encuentra en la literatura como "ImageNet Large-Scale Visual Recognition Challenge" o "ILSVRC"

Los modelos basados en SVM son un método de entrenamiento computacional intermedio, con un menor costo en la predicción en comparación a NNC. Esto, se debe a que una vez entrenado el modelo solo funciona por medio de los parámetros que se obtienen de la optimización sin tener que reutilizar la data de entrenamiento para poder clasificar una imagen.

Softmax, Corresponde a un clasificador lineal, similar a SVM. La diferencia es su función de pérdida y el output corresponde a probabilidades de que un input equivalga a una clase, a diferencia de SVM donde los outputs corresponden a scores. Comparándolos en termino de rendimiento, estos casi no tienen diferencias. Su ventaja principal es que los resultados obtenidos de la clasificación son más intuitivos respecto a su par SVM.

Alex Krizhevsky (2010) [F1] Entrenó una red convolucional *Deep Belief Network* (DBN) para clasificar imágenes de dígitos (CIFAR-10), logrando obtener resultados de clasificación correspondientes al 78,9%.

Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun (2016) [F2] Entrenaron diferentes modelos de *deep learning* y consiguieron errores del 6.43% (6.61 ± 0.16) en problemas de clasificación de dígitos (CIFAR-10), la mejor performance correspondió a una red que tenía 110 capas llamada ResNet y 1.7 millones de parámetros.

Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun [F3] Estudiando redes Fast R-CNN consiguió un desempeño del 73.2% con los datos de PASCAL VOC 2017 test set, mientras que la detección de resultados en PASCAL VOC 2012 test set obtuvo una performance del 70.4%

Yichuan Tang (2013) [F4] demuestra una pequeña pero consistente ventaja en remplazar la capa Softmax en convolutional neural network para problemas relacionados a clasificación de imágenes por una capa de Super Vector Machine en la última capa de la red.

Roh, M. C., & Lee, J. Y. (2017, May) [F5] plantea las limitaciones para la detección de objetos pequeños con Fast/Faster R-CNN, proponiendo y redefiniendo el sistema de bloques. Propone una red llamada RF-CNN la que tiene como objetivo detectar patentes de autos y personas en imágenes de alta resolución. Los resultados muestran que RF-CNN tiene mayor performance que clasificadores anteriores, para este tipo de tareas.

W Sakla, G Konjevod (2017) [F6] propone algunas modificaciones en los parámetros de Faster R-CNN para la detección de objetos pequeños, aplicando este modelo en la detección y localización de vehículos a través de imágenes aéreas (VEDAI, Base de datos). Los resultados indican que la ratio promedio de precisión cercano al 93%.

S Azadi, J Feng, T Darrell (2017) [F7] proponen que se puede aumentar la detección de objetos en una imagen considerando la información de contexto de la imagen completa, es decir, plantea que los objetos aparecen en las imágenes con cierta correlación dependiendo del entorno. Proponen así un método *Learning Detection with Diverse Proposal* (LDDP), que considera la información contextual, mejorando la categorización y detección.

En la Tabla 2 se muestran algunos resultados en modelos de predicción asociados a la detección de objetos y clasificación de imágenes para el problema de PASCAL VOC 2007.

Modelo	mAP (PASCAL VOC 2007)
R-CNN	66.0%
Fast R-CNN	66.9%
Faster R-CNN	67.0%
YOLO - SSD	63.4%
Faster R-CNN with iterative refinement	67.7%
Faster R-CNN with LSTM refinement	67.4%
YOLO Fast	52.7%

Tabla 2: Performance de modelos de redes neuronales [Elaboración propia]

Algunos de estos algoritmos han sido desarrollados buscando minimizar los tiempos de entrenamiento y clasificación, esto dado que las aplicaciones que puede tener un clasificador en tiempo real son un campo de investigación. Por ejemplo, en los problemas de pilotaje automático y otros han sido creados buscando mejorar la performance independiente de los tiempos de procesamiento. Otro tipo de redes han privilegiado más el desempeño sacrificando tiempo de entrenamiento.

En [F8] se entrena una red CNN para clasificar 1000 diferentes clases de imágenes en ImageNet LSVRC-2010, consiguiendo en el conjunto de test errores top-1 y top-2 de 37.5% y 17.0%.

En la literatura, se distinguen dos tareas claves en los trabajos que utilizan imágenes, que se muestran en la Ilustración 4. El primero, corresponde a la clasificación de objetos o imágenes según algún tipo de categorización, es decir, clasificadores que al recibir una imagen lo clasifican en un avión, automóvil u otro. Segundo, hay clasificadores que tienen la tarea de identificar y clasificar la existencia de elementos en el interior de una imagen.

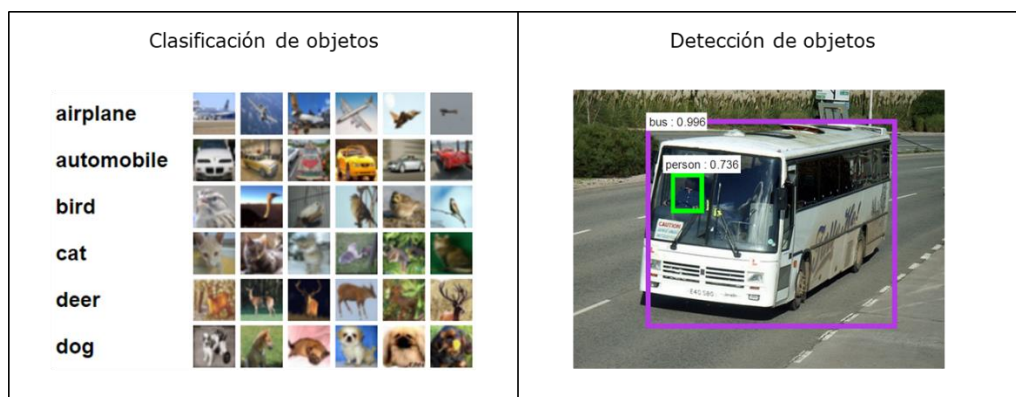


Ilustración 4: Ejemplo de clasificación y detección de objetos en imágenes. Imágenes extraídas de [Z4, F3]

La etapa de detección o reconocimiento de objetos puede ser dividida en dos grandes categorías, la propuesta de regiones basada en clasificadores como R-CNN, Fast R-CNN, Faster R-CNN, Faster R-CNN con iteraciones de refinamiento y Faster R-CNN con LSTM refinamiento y regresiones basadas en algoritmos como YOLO y SSD. En los modelos anteriores Faster R-CNN es lo que ha dado mejores resultados en PASCAL VOC 2007.

Los métodos anteriores se basan en redes neuronales convolucionales (CNN) y para realizar una clasificación de objetos en la imagen hay tres pasos. El primero, hace una generación de propuesta de regiones por medio de la búsqueda selectiva en una imagen. El segundo, Realiza una extracción de características en cada una de las regiones propuestas a través una red CNN y finalmente, en la tercera etapa, se realiza la clasificación del objeto contenido en la región propuesta.

Las redes anteriores están orientadas a la detección y clasificación de objetos en tiempo real, por lo tanto, los esfuerzos de estas redes están orientados a disminuir los tiempos de detección y clasificación de objetos y también, a mejorar los desempeños en la clasificación.

En la literatura existen otras arquitecturas de redes neuronales tales como AlexNet, ZFNet, VGGNet, VGG-16, VGG-19, GoogleNet ResNet-V4, Inception-V4, ResNet y otras más. Las características de algunas de estas redes son explicadas en la sección de Redes neuronales (4.3.1). El desempeño de estas redes se resume en el siguiente gráfico:




Ilustración 5: Resumen del rendimiento de arquitecturas CNN [F9]

Donde el *accuracy* se mide por medio del error top-1, el tamaño de la circunferencia para cada red, representa la cantidad de parámetros a estimar al momento de entrenar la red neuronal y el número de operaciones. Algunas características como el tamaño, parámetros a estimar y profundidad de cada red se muestran en la Tabla 3.

Modelo	Tamaño	Parametros	Profundidad
Xception	88 MB	22,910,480	126
VGG16	528 MB	138,357,544	23
VGG19	549 MB	143,667,240	26
ResNet50	99 MB	25,636,712	168
InceptionV3	92 MB	23,851,784	159
InceptionResNetV2	215 MB	55,873,736	572
MobileNet	17 MB	4,253,864	88
DenseNet121	33 MB	8,062,504	121
DenseNet169	57 MB	14,307,880	169
DenseNet201	80 MB	20,242,984	201

Tabla 3: Detalle de los modelos⁷

Es importante destacar que el rendimiento de las redes en términos computacionales puede generar diferencias sobre como estas se usan, si es necesario obtener información en tiempo real de las imágenes, hay ciertas redes como las VGGNet que pueden no ser las más adecuadas. En ese caso, es mejor privilegiar aquellas redes más veloces, las cuales además han obtenido buenos resultados para las distintas labores de clasificación.

Respecto a la elaboración de los conjuntos de entrenamiento y test, se hacen algunas observaciones importantes para validar que es posible entrenar una

⁷ Página oficial de Keras. Sitio Web: <https://keras.io/> (Consultado 01 Marzo 2018)

red con los datos disponibles. Si se observa la composición del conjunto de datos de ImageNet [F10], este conjunto de datos cuenta con más de 14 millones de imágenes, Sin embargo, cuenta con un gran número de categorías (cerca de 30), pero el número de subcategorías es aún mayor. En promedio, el número de imágenes que hay por subcategoría es menor a las 1000 imágenes.

En [F11] Se entrena un modelo de Deep Convolutional Neutral Network con la finalidad de entrenar un clasificador de reconocimiento de escenas. Para esto se seleccionan 2.448.873 imágenes correspondientes a 205 categorías de lugar, con un conjunto de entrenamiento, de máximo 5000 imágenes y mínimo 1500 imágenes por categoría, mientras que, el conjunto de validación cuenta con cerca 100 imágenes por categoría

En [F12], [F13] se ha trabajado con el conjunto CIFAR-10 donde cada una de las 10 categorías cuenta con 6000 imágenes por clases, mientras que en CIFAR-100 cada una de las clases contiene 600 imágenes.

Lo anterior, da una idea de que el número de imágenes utilizadas para el problema de reconocimiento de lugares y zonas de robo para esta memoria es suficiente, para entrenar clasificadores basados en redes neuronales.

Los modelos de detección y clasificación que mejor funcionan en el estado del arte usando como datos imágenes son los modelos basados en *convolutional neural network (CNN)*. Las redes CNN poseen diversas arquitecturas para la resolución de problemas, algunas más profundas que otras, algunas redes hacen segmentación e identificación de objetos, mientras que otras se usan para la clasificación de fenómenos.

4.2 Modelos de Machine Learning

4.2.1 Regresión Logística

Los modelos de regresión son utilizados para poder explicar el comportamiento de un fenómeno por medio de un conjunto de variables explicativas. La regresión logística permite estudiar particularmente el comportamiento probabilístico de un fenómeno dado que toma como valores 1 cuando el fenómeno ocurre o 0 cuando el fenómeno no ocurre.

Este modelo permite clasificar la probabilidad de que un fenómeno ocurra por medio de la siguiente expresión de probabilidad:

$$p(x_i) = \frac{1}{1 + e^{-(\beta_0 + \sum \beta_i x_i)}}$$

Los parámetros por estimar, correspondientes a los β_i permiten entender cómo afectan a la ocurrencia del fenómeno, aumentando o disminuyendo la probabilidad de ocurrencia. Estas variables se evalúan estadísticamente y se estiman minimizando la log-verosimilitud ajustada a los datos que se tienen clasificados, correspondiente a:

$$\mathcal{LL}(\beta) = Ln[\mathcal{L}(\beta)] = \sum_i \{y_i Ln[p(x_i)] + (1 - y_i) Ln[1 - p(x_i)]\}$$

Para utilizar este modelo, se determina un punto de corte \bar{X} para indicar si el fenómeno predicho ocurre. De esta manera se logra la clasificación. En términos matemáticos:

$$\begin{aligned} p(x_i) \geq \bar{X} &\rightarrow y_i = 1 \\ p(x_i) < \bar{X} &\rightarrow y_i = 0 \end{aligned}$$

Se utiliza este modelo en algunos estudios dada su flexibilidad y simplicidad para poder agregar heterogeneidad e interpretar los resultados. Lo anterior, es una característica positiva para estudiar el robo de autos porque se desconocen los factores que indiquen el robo de vehículos, por lo que este método permite entender mejor el fenómeno.

Para la selección de variables relevantes en esta memoria se utiliza el algoritmo de Backward [F14], consiste en que inicialmente todas las variables entran a la ecuación primero y luego son eliminadas una a una si es que estas no contribuyen en el desempeño de la regresión. Por lo tanto, es un proceso iterativo de selección de variables.

4.2.2 Random Forest

Consiste en un modelo de *machine learning* que utiliza como base los árboles de decisión los cuales permiten clasificar, descomponiendo un conjunto de datos en dos o más subconjuntos de datos. Para ello se debe seleccionar una variable dependiente, al igual que el modelo de regresión logística y variables independientes o explicativas con las que se entrena el clasificador. Este modelo genera N árboles de decisión en función de la selección aleatoria de m variables explicativas. Posteriormente, después de la generación de muchos árboles de decisión procede a ponderar la importancia de cada una de las variables explicativas.

Se recomienda en [F15] que el número de variables óptimas a elegir en la generación de cada árbol aleatorio es del orden de $\log_2(M + 1)$.

Para medir la importancia [F16], [F17] de cada variable en RandomForest, existen dos criterios: (1) *Mean Decrease Accuracy (IncNodePurity)*, entregando una medida de cuánto aumenta la pureza de la clasificación si se agrega esta variable en los árboles de decisión, (2) *Mean Decrease Gini*

(*IncMSE*) que entrega una medida de cuánto empeora la pureza de selección cuando esta variable no se encuentra en el árbol de decisión.

En ocasiones, el conjunto de variables independientes que se entrega al modelo es muy grande, por lo que es necesario realizar una selección de características relevantes. Para esto se utiliza el algoritmo de Boruta [F18], este algoritmo es diseñado como un *wrapper* para random Forest, el cual funciona determinando cuales son las variables relevantes y de poca importancia para clasificar en el modelo.

Un método *wrapper* es aquel que busca entre los posibles subconjuntos de atributos, evaluando el potencial predictivo de las variables, lo cual es costo computacionalmente dado que la cantidad de subconjuntos a revisar crece exponencialmente en la cantidad de atributos.

La medida de importancia de un atributo se obtiene a partir de la pérdida de precisión de la clasificación causada por la permutación aleatoria del valor de los atributos entre objetos. Se computa separadamente para todos los árboles de decisión generados en random forest que contienen el atributo para la clasificación. Entonces, el promedio y la desviación estándar de la pérdida de precisión del modelo es computada. Cabe destacar que este método de selección de variables no está directamente relacionado a la significancia estadística, por lo tanto, es necesario complementar con otros métodos para estudiar lo anterior.

Un ejemplo de la visualización de un árbol de decisión de aprecia en la Ilustración 6.

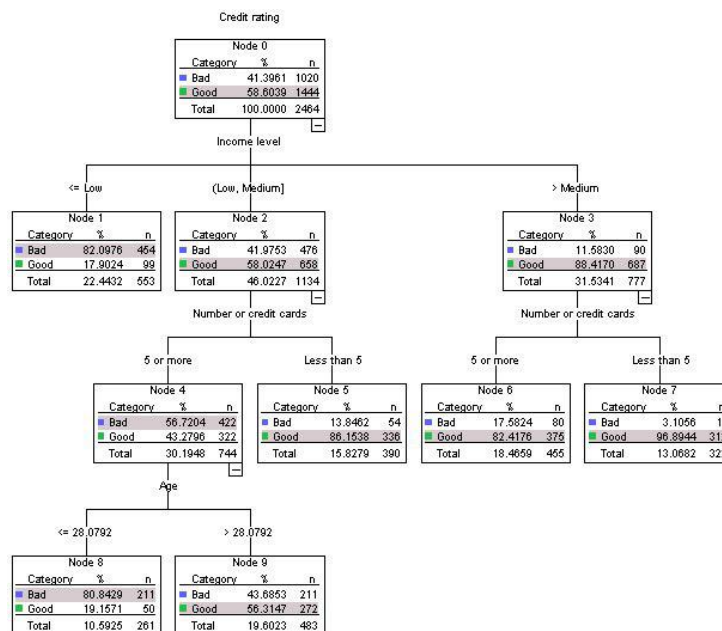


Ilustración 6: Ejemplo de árbol de decisión

4.2.3 Support Vector Machine

Consiste en un modelo de clasificación orientado a la clasificación binaria, basado en minimizar el error cuadrático de la clasificación. Este modelo de clasificación funciona por medio de la construcción de hiperplanos que permiten separar los datos.

Sea un vector de características $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$, mientras que el valor a predecir es una variable binaria $z_i \in \{-1, 1\}$, por lo tanto, se puede representar la probabilidad o el score del fenómeno como:

$$z_i = x_i^T \cdot w + b$$

Donde w corresponde a los coeficientes que definen el hiperplano. El problema de optimización que se busca resolver para obtener los valores de w, b corresponde a:

$$\begin{aligned} \min_w & \left(\frac{1}{2} \cdot \|w\|^2 + C \sum_{i=1}^n \xi_i \right) \\ \text{s. a} & \quad y_i(x_i^T \cdot w) \geq 1 - \xi_i \\ & \quad \xi_i \geq 0 \end{aligned}$$

Donde ξ_i son las variables de holgura del problema de minimización, estas variables de holgura son utilizadas porque en la mayoría de los problemas que se resuelven, no son perfectamente separables, por lo tanto, se busca una solución aproximada y para esto se usan variables de holgura, las cuales permiten encontrar una solución penalizando los errores de clasificación en la función objetivo, la cual es controlada por medio del parámetro C .

Este método de clasificación puede ser reformulado, para obtener un clasificador no lineal, usando un *kernel* tricks, sin embargo, lo anterior dificulta la extracción de características relevantes del modelo. Por lo tanto, para esta memoria solo se entrenan clasificadores lineales de SVM.

4.3 Modelos de Deep Learning

Consiste en una técnica de aprendizaje basado en redes neuronales, sin embargo, a diferencia de estas se habla de *deep learning* cuando existen múltiples capas de redes neuronales en las capas intermedias. Existen distintos tipos de capas dependiendo de si son redes recurrentes, convolucionales o de neuronas. En el caso de esta memoria, se usarán CNN porque son las que tienen mejor desempeño en predicciones con imágenes.

Como se mencionó anteriormente, existen distintas arquitecturas de redes neuronales enfocadas a distintos problemas de la vida real, por ejemplo, las arquitecturas basadas en redes neuronales recurrentes se utilizan con

frecuencia en problemas de identificación y clasificación de patrones secuenciales a través del tiempo, principalmente porque son redes que trabajan con memoria, por lo mismo también hay aplicaciones en problemas basados en texto. Las arquitecturas basadas en redes convoluciones son frecuentemente utilizadas en los campos de procesamiento de imágenes y también en procesamiento de texto. En resumen, las arquitecturas de redes neuronales permiten desarrollar modelos de clasificación asociados a imágenes, textos, sonidos, secuencias, entre otros.

Los modelos de *deep learning* al igual que otros modelos de *machine learning* pueden ser entrenados por medio de un conjunto de datos etiquetados, como aprendizaje supervisado en función de datos no etiquetados, por medio de aprendizaje no supervisado. Las arquitecturas de redes neuronales aprenden a través de grandes conjuntos de datos, esto es una consecuencia de la gran cantidad de parámetros que es necesario estimar y esto a su vez, es una consecuencia de la gran cantidad de neuronas y capas que existen en las arquitecturas.

4.3.1 Redes neuronales

Esta memoria utiliza arquitecturas de redes neuronales convolucionales o Convolutional Neural Networks (CNN). Las cuales poseen a modo de ejemplo las siguientes capas en su estructura:




Ilustración 7: Estructura simplificada de una red convolucional

Es importante destacar que la cantidad de capas que tiene una CNN es variable y depende del problema. Suelen usarse una gran cantidad de combinaciones en las redes CNN, especialmente en las capas de convolución y de *pooling*, por lo tanto, hay arquitecturas que tienen varias capas de convolución en serie, una detrás de otra, lo mismo en el caso de *pooling*. En ocasiones, estas repeticiones de capas ocurren varias veces o se aplican distintas capas en paralelo para el mismo mapa de características proveniente de la red anterior.

En ocasiones hay más de una capa de entrada, pues un problema puede tener diferentes tipos de datos y también, hay arquitecturas que cuentan con varias capas de neuronas (dense layer).

4.3.1.1 Capa de entrada

La *Input Layer* o capa de entrada, corresponde a la capa que permite la entrada de datos, ya sea de entrenamiento, test o de clasificación a partir de

los cuales se espera entrenar o clasificar, esta capa de entrada puede recibir diferentes tipos de datos. Por ejemplo, en el caso de imágenes a color (RGB) de 640x640 la capa de entrada recibe valores en dimensiones de 640x640x3, esto se debe fundamentalmente a que una imagen a color puede ser representada como tres matrices de tamaño 640x640, donde cada valor de esta matriz tiene valores entre 255 y 0, lo que simboliza la intensidad del color en rojo, verde o azul, por lo mismo se habla de imágenes a color como imágenes RGB.

4.3.1.2 Convolución en una imagen

Sea una imagen I en una escala de blanco y negro, la cual se encuentra definida por la función:

$$I: \{1, \dots, n_1\} \times \{1, \dots, n_2\} \rightarrow W \subseteq \mathbb{R}, (i, j) \rightarrow I_{i,j}$$

Se observa en primer lugar que una imagen puede ser representada como un array de tamaño $n_1 \times n_2$, en el caso que sea una imagen a color, la diferencia radica en que I puede ser presentado por un Array con tres arráis $I^i \rightarrow i \in \{1,2,3\}$.

Dado el filtro $K \in \mathbb{R}^{2h_1+1 \times 2h_2+1}$, la convolución discreta de la imagen I con el filtro K se encuentra dada por:

$$(I * K)_{r,s} = \sum_{u=-h_1}^{h_1} \sum_{v=-h_2}^{h_2} K_{u,v} \cdot I_{r+u,s+v}$$

Donde el filtro se encuentra definido como:

$$K = \begin{pmatrix} K_{-h_1,-h_2} & \cdots & K_{-h_1,h_2} \\ \vdots & K_{0,0} & \vdots \\ K_{h_1,-h_2} & \cdots & K_{h_1,h_2} \end{pmatrix}$$

4.3.1.3 Capa de convolución

Si consideramos una capa de convolución l . Cada capa de convolución recibe como input el mapa de características de alguna de las capas anteriores L , por lo tanto, el mapa de características que recibe la capa l puede ser representado como m_l^r , donde r puede ir desde 1 a $l - 1$.

En la capa, el mapa de características recibido es sometido a una serie de operaciones de convolución:

$$Y_i^{(l)} = B_i^{(l)} + \sum_{j=1}^{m_l^r} K_{i,j}^{(l)} * Y_j^{(l-1)}$$

Donde $B_i^{(l)}$ corresponde a una matriz de sesgo y $K_{i,j}^{(l)}$ es el filtro de tamaño $2h_1^{(l)} + 1 \cdot 2h_2^{(l)} + 1$ conectado al j^{th} mapa de características de la capa r con el i^{th} mapa de características de la capa l . Cuando se aplica una convolución discreta en la región válida de la imagen o en el mapa de características (obviando los bordes), el resultado del tamaño de la operación queda representado como:

$$m_2^{(l)} = m_2^{(r)} - 2h_1^{(l)} \quad ; \quad m_3^{(l)} = m_3^{(r)} - 2h_2^{(l)}$$

Gráficamente una capa de convolución realiza operaciones de convolución tomando los datos de una imagen I y los opera con un filtro K transformando los datos originales de la imagen I en otro, como se aprecia en la Ilustración 8.




Ilustración 8: Ejemplo de convolución sobre una matriz

La operación se realiza sobre todos los datos de la Imagen I , para esto recorre la imagen por medio de subconjuntos del mismo tamaño que la ventana del kernel haciendo una multiplicación de cada $S_{I_{ij}} \cdot K_{ij} = I_{K_{ij}}$ entre los valores del kernel y la ventana, posteriormente se toma otro subconjunto de datos de la imagen moviéndose x unidades hacia la derecha de la imagen I o y unidades hacia debajo de la imagen I , de esta forma se recorre toda la imagen. El tamaño del Kernel y el desplazamiento tanto hacia el lado o abajo que hace entre un subconjunto de datos de la imagen y otro son parámetros que se determinan en la convolución.

En el caso de una capa convolucional, lo que ocurre es que existen múltiples Kernel, y el resultado de realizar múltiples convoluciones sobre una imagen es básicamente obtener un mapa de características particulares de una imagen,

como un tipo de forma en particular, color u otro (Ilustración 9). También, suele denominarse a esta operación filtros sobre la imagen:




Ilustración 9: Ejemplo de aplicar un filtro de convolución sobre una imagen

Las capas convoluciones no solo toman los datos de la imagen original, sino que también, pueden tomar los datos de su capa predecesora, lo cual permite a su vez generar un conjunto de mapa de características a partir del anterior, lo cual permite profundizar a medida que la red se entrena en una serie de patrones que luego permiten al modelo poder realizar una clasificación del objeto de entrada.

4.3.1.4 Capa de pooling

En el caso de la capa de Pooling, esta capa tiene por objetivo reducir la dimensionalidad de los datos entregados por la capa anterior, lo cual contribuye a una menor carga en el cálculo tanto del entrenamiento de la red como de la clasificación de objetos. Esto se logra por medio de un filtro que, a diferencia del filtro de convolución, realiza una operación como el promedio, el mínimo o máximo sobre los datos de la capa predecesora, similar al proceso descrito en la Ilustración 10. Donde al tener un conjunto de datos de 8x8 y aplicar una operación de *maxpooling* con un filtro de tamaño 2x2 y moviéndose 2 unidades hacia el lado y hacia abajo (atributo denominado *padding*), entonces se obtendrá el máximo valor sobre cuatro subconjuntos de datos transformando la imagen en un conjunto de 4x4.




Ilustración 10: Ejemplo de la operación de max pooling en un conjunto de datos

Las diferentes arquitecturas de redes neuronales convoluciones (CNN), se basan fundamentalmente en cómo se ordenan las capas de pooling y de convolución y también la cantidad de capas de una o de otra que tiene la red.

4.3.1.5 Capas Fully connected

Sea la capa l una capa fully connected. Si la capa $(l - 1)$ es una capa *fully connected*. Si capa l recibe como input un mapa de características denotado por m_i^r donde r es una capa de convolución con dimensiones $m_2^r \times m_3^r$, entonces la $i - esima$ unidad en la capa l puede ser representada como:

$$z_i^{(l)} = \sum_{j=1}^{m_1^r} \sum_{r=1}^{m_2^r} \sum_{s=1}^{m_3^r} w_{i,j,r,s}^{(l)} \cdot (Y_j^r)_{r,s}$$

Donde $w_{i,j,r,s}^{(l)}$ corresponden los pesos conectados a la unidad en la posición r, s in la $j - esima$ mapa de características de la capa r y la $i - esima$ unidad de la capa l

En el caso que r sea una capa *fully connected*, entonces la operación efectuada corresponde a:

$$z_i^{(l)} = \sum_{k=0}^{m^r} w_{i,k}^l \cdot y_k^r$$

Donde $z_i^{(l)}$ corresponde a los actuales inputs, $w_{i,k}^{(l)}$ los pesos y $y_k^{(r)}$ los outputs. La Dense Layer o también Fully Connected Later, es una capa que consta de muchas neuronas y que se conecta con el mapa de características obtenido de la operación de las capas anteriores, cada una de estas neuronas luego y por medio del ajuste de los parámetros permite clasificar el objeto del input.

La Output Layer, corresponde a la capa final que usualmente corresponde a una capa Softmax que entrega una clasificación del objeto anterior, asignándole un score o un nivel de probabilidad dependiendo de la función de activación de las neuronas que la componen.

Un ejemplo de lo anterior puede verse en un modelo de clasificación como el descrito en la Ilustración 11, donde a partir de una imagen de un auto y una serie de capas descritas anteriormente la red determina si la imagen es un auto, un camión u otro vehículo.

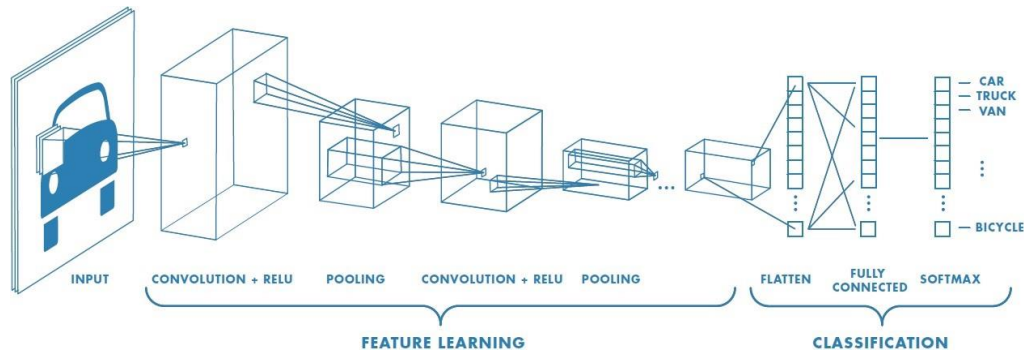


Ilustración 11: Ejemplo de un clasificador de vehículos

4.3.1.6 Arquitecturas de redes CNN

Los modelos basados en arquitecturas DenseNet tienen una menor cantidad de parámetros a estimar y la arquitectura de su red les otorga una ventaja cuando son entrenadas, eso se debe principalmente a la conexión escalada de sus capas, también conocido como arquitecturas feed-forward (Ilustración 12) que permite preservar el nivel de información a medida que la información va pasando a través de las capas [F19].




Ilustración 12: Arquitectura de la red DenseNet [F19]

En el caso de las redes VGG16 (Ilustración 13) y VGG19, ambas redes del tipo VGGNet cuentan con una mayor cantidad de parámetros a estimar por la gran cantidad de capas que tienen estas arquitecturas, lo que significa a su vez que son modelos que requieren una mayor carga computacional, para su entrenamiento. La diferencia entre ambas arquitecturas radica en que la última tiene 3 capas adicionales.

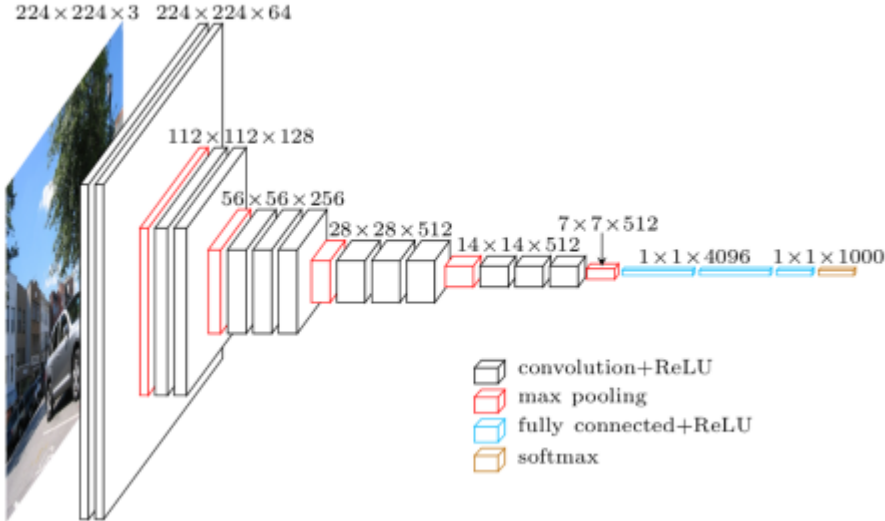


Ilustración 13: Arquitectura VGG16

La red Inception-V3 a diferencia de las arquitecturas anteriores, cuentan con una estructura de diferentes módulos (para ejemplo observar la Ilustración 14), que constan de la aplicación de filtros de convolución en paralelo y su posterior concatenación al final, la cual pasa a otros módulos con diferentes composiciones. Esta arquitectura le otorga una gran ventaja sobre las redes VGGNet dado que permite reducir la cantidad de parámetros a estimar, lo que reduce su costo computacional




Ilustración 14: Ejemplo de módulo de una red Inception [F20]

Las redes ResNet son similares a las redes VGGNet, sin embargo, agregan conexión entre una o más capas similares o lo que realizan las redes DenseNet

(Ilustración 12). En la Tabla 3, se observa un resumen de la cantidad, tamaño y profundidad de algunos de los modelos que se han utilizado.

También se encuentran presentes las arquitecturas que constan solamente capas *dense layer*, con un gran número de neuronas, a las que suele llamar *Deep Neural Network (DNN)* y su arquitectura base puede observarse a continuación:




Ilustración 15: Arquitectura simplificada de Deep Neural Network (DNN)

Donde la *dense layer* consiste en múltiples capas *fully connected*, con gran cantidad de neuronas interconectadas entre una capa y otra como se puede observar en la Ilustración 17.

4.3.2 Entrenamiento

El entrenamiento es realizado por medio de ajuste de los pesos w que componen la red neuronal, buscando minimizar una función objetivo, la cual puede ser interpretada como una medida de error entre la predicción $y(x_n)$ y el valor real t_n . Las opciones de clasificación incluyen la suma de los errores cuadrados dada por:

$$E(w) = \sum_{n=1}^N E_n(w) = \sum_{n=1}^N \sum_{c=1}^C (y_k(x_n, w) - t_{n,k})^2$$

Y también por la entropía cruzada:

$$E(w) = \sum_{n=1}^N E_n(w) = \sum_{n=1}^N t_{n,k} \cdot \log(y_k(x_n, w))$$

Donde $t_{n,k}$ corresponde a la k –ésima entrada del valor real t_n . Las formas de entrenamiento son por: entrenamiento estocástico, donde se elige un valor de entrada de forma aleatoria y los pesos de la red son actualizados basados en el error $E_n(w)$; entrenamiento por Batch, donde todos valores de entrada son procesados y los pesos son actualizados basados en $E(w) = \sum_{n=1}^N E_n(w)$; el entrenamiento online, donde cada valor de entrada es procesado solo una vez

y los pesos de la red son actualizados basados en el error $E_n(w)$; Entrenamiento por mini-batch donde se elige un subconjunto aleatorio $M \subseteq \{1, \dots, N\}$ llamado mini-batch. Este conjunto de entrenamiento es procesado y los pesos son actualizados basados en el error acumulativo $E_M(w) = \sum_{n \in M} E_n(w)$.

El método de gradiente descendiente es una técnica de optimización de primer orden, el cual utiliza información asociada a la derivada de E_n y puede, en conclusión, ser utilizado como una combinación con el error de *backpropagation* descrito más adelante en esta sección, donde el método de Newton es un método de segundo orden y necesita evaluar la matriz Hessiana H_n de E_n o una aproximación de la matriz Hessiana en cada paso de iteración.

El gradiente descendiente, utilizando un ratio de aprendizaje γ se desplaza en una dirección más empinada de descenso, para acercarse cada vez más al mínimo en cada iteración, Por lo tanto, la actualización del paso dado se encuentra dada por:

$$\Delta w[t] = -\gamma \frac{\delta E_n}{\delta w[t]} = -\gamma \nabla E_n(w[t])$$




Ilustración 16: Ejemplo de optimización por gradiente descendiente [F20+]

El método de Newton es un método de Segundo orden como fue mencionado. Cuando se usa este método, el peso $\Delta w[t]$ es actualizado usando la siguiente expresión:

$$\Delta w[t] = -\gamma \left(\frac{\delta^2 E_n}{\delta w[t]^2} \right)^{-1} \cdot \frac{\delta E_n}{\delta w[t]} = -\gamma (H_n(w[t]))^{-1} \cdot \nabla E_n(w[t])$$

El error *backpropagation*, es usado para evaluar el gradiente $\nabla E_n(w[t])$ de la función de error E_n de en cada uno de los pasos del entrenamiento. Este algoritmo consta de lo siguientes pasos:

1. Propaga el valor de entrada x_n a través de la red para conseguir el valor de entrada y de salida de cada unidad.
2. Calcular el error para la unidad de salida:

$$\delta_i^{(L+1)} = \frac{\delta E_n}{\delta y_i^{(L+1)}} f'(z_i^{(L+1)})$$

3. Determina para las capas intermedias usando el error de propagación:

$$\delta_i^{(l)} = f'(z_i^{(l)}) \sum_{k=1}^{m^{(l+1)}} w_{i,k}^{(l+1)} \delta_k^{(l+1)}$$

4. Calcular las derivadas requeridas:

$$\frac{\delta E_n}{\delta w_{j,i}^{(l)}} = \delta_j^{(l)} y_i^{(l-1)}$$

4.3.3 Sobreajuste en redes neuronales

Este método como se aprecia en la Ilustración 17, consiste en que en el proceso de entrenamiento de la red neuronal, eliminar aleatoriamente o más bien, inactivar algunas neuronas y las conexiones que están tienen con neuronas de capas posteriores o anteriores, lo que obliga al resto de las neuronas a intentar capturar otro tipo de patrones y de esa forma diversificar el aprendizaje de la red. En cada proceso de iteración en el entrenamiento la literatura recomienda que la inactividad de la neurona en el ciclo debe ocurrir con una probabilidad cercana a 0.5 [F21] de forma independiente para maximizar el aprendizaje de la red.




Ilustración 17: Ejemplo de proceso de Dropout en una red neuronal [F21]

4.4 Métricas de evaluación de modelos

Para evaluar el rendimiento de los modelos, se construyen y calibran los modelos en función de un porcentaje de los datos etiquetados, usualmente ronda el 80%, mientras que el 20% de los datos son usados para evaluar cómo se comporta el modelo. En general hay cuatro posibilidades que se describen en la siguiente tabla:

		Predicción	
		Cp	Cn
Etiquetado	Cp	TP: Verdadero positivo	FN: Falso negativo
	Cn	FP: Falso positivo	TN: Verdadero negativo

Tabla 4: Matriz de confusión

Las métricas de evaluación corresponden a:

- La exactitud (*Accuracy*) permite medir la fracción de las predicciones que fueron correctas. Tiene como desventaja que cuando las clases de no están balanceadas, al entrenar un clasificador basándose en esta métrica priorizará obtener mejores resultados para la clase más grande lo que conduce a errores en clases de menor tamaño.

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)}$$

- La Precisión (*Precision*) mide la capacidad de un clasificador para etiquetar una muestra como positiva cuando en realidad es negativa, lo que permite tener una idea de

$$Precision = \frac{TP}{(TP + FP)}$$

- La Sensibilidad (*recall*) mide la capacidad de un clasificador para encontrar todas las muestras de una clase de forma correcta, es decir, disminuir los falsos negativos.

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

- F1: es una medida de equilibrio entre la precisión y sensibilidad. Donde el valor β es el que permite asignar una importancia mayor o a la precisión o a la sensibilidad, donde F1 es útil para evitar el problema del desbalanceo de clases del *accuracy*.

$$F1 = \frac{(1 + \beta^2) \cdot Precision \cdot Recall}{(\beta^2 \cdot precision) + Recall}$$

Capítulo V. Metodología

5.1 Marco referencial

La presente sección tiene por objetivo contextualizar al lector respecto a algunos elementos importantes que son mencionados y usados durante la memoria, como tecnologías y herramientas necesarias para comprender cómo ha sido llevado a cabo este trabajo de título.

5.1.1 Tecnologías utilizadas

Para la implementación de modelos y una serie de tareas relacionadas al proceso KDD se utilizó como lenguaje de programación Python, dado que permite la automatización, programación, cuenta con un gran soporte a nivel web y una serie de paquetes que facilitan la programación de distintas técnicas de *machine learning* y *deep learning*, además de permitir el uso de diferentes APIs y cuenta con librerías que ejecutan Web Scraping. La decisión de utilizar este lenguaje de programación se basa en el gran soporte que tiene en la web.

Adicionalmente a Python se utilizó R-Studio para implementar técnicas de *machine learning* como random forest, SVM y modelos logit. Se privilegia el uso de R-Studio en este tipo de implementaciones porque a juicio del memorista la utilización de las librerías relacionadas a *machine learning* es de más fácil implementación que Python.

Para la programación de modelos basados en DNNs y CNNs se utilizó la librería de TensorFlow en Python, para instalar esta librería se recomienda seguir los pasos de instalación del Sitio Web Oficial⁸.

Tensorflow, corresponde a una librería de Google, especialmente diseñada para la programación de *deep learning*. En esta memoria se usa esta librería por su nivel de soporte, aunque existen otras alternativas para realizar *deep learning* como Caffe, Theano, Keras, Lasagne, Cognitive Toolkit.

Una de las grandes dificultades actuales para trabajar con *deep learning* es el costo computacional que implica entrenar estos modelos, sin embargo, una de las herramientas que ayuda considerablemente en la solución de este problema es CUDA. Corresponde a estructura de cálculo en paralelo de NVIDIA que permite el uso de las tarjetas gráficas de los computadores (GPU) para hacer procesamiento. El beneficio de esta herramienta es la disminución

⁸ Instalación de Tensorflow en Window. Sitio Web: https://www.tensorflow.org/install/install_windows (Consultado 10 Septiembre 2018)

significativa de los costos de procesamiento y entrenamiento de técnicas de *deep learning*.

Como se menciona en el párrafo anterior, los costos computacionales son altos, especialmente en el entrenamiento de redes CNNs. Para dar solución a este problema, esta memoria utiliza Amazon Web Service.

Amazon Web Service, corresponde a un servicio de Amazon que permite utilizar servidores con distintas especificaciones técnicas, dependiendo del nivel de computación o problema que se quiera abordar. En el caso de la memoria se utiliza una instancia llamada G3.8xlarge la cual cuenta con 2 GPU con una capacidad sumada de 16GB de video, 32 Núcleos de CPU y 244 GB de memoria RAM y un disco duro SSD de 250GB.

Se usa además una instancia que cuenta con sistema operativo *Windows Server 2016*, aunque existe la posibilidad de utilizar Linux. En esta memoria se usa Windows porque a diferencia de Linux, para utilizar la instancia con una interface gráfica, solo basta con conectarse al servidor por medio de la aplicación *Remote Desktop Connection* que está en Windows, mientras que para utilizar una interface gráfica de Linux es necesaria la instalación de varios paquetes.

Se recomienda que al crear la instancia G3.8xlarge se use un ambiente de *deep learning*⁹, en esta memoria se usa el ambiente: *English-Deep-Learning-2018.06.13 (ami-4621633e)*, la recomendación se basa en que este ambiente ya cuenta con todos los paquetes necesarios para programar en Deep learning instalados y configurados, correspondientes a CUDA, Tensorflow, Python, e incluso tiene otras librerías de *deep learning* como MaxNet, Caffe y otras.

5.1.2 Herramientas utilizadas

Parte de la información obtenida en el uso de esta memoria usa *Web Scraping*, consiste en un set de técnicas utilizadas para obtener información de un sitio web de forma automática evitando de esta forma la extracción manual de información.

Adicionalmente para obtener información de Santiago se utilizan las APIs de Google. Las APIs corresponden a servicios ofrecidos por Google, los cuales

⁹ Soporte de Deep Learning en Amazon frameworks. Sitio Web: <https://aws.amazon.com/machine-learning/amis> (Consultado 10 Septiembre 2018)

permiten por medio de una aplicación acceso a diferentes consultas de información que ellos poseen. En este caso se utilizan las librerías de Google para Python, de esta forma se pueden programar consultas masivas para la extracción de información.

En esta memoria se hace uso de las APIs de Google Street View, Geolocation y Distance-Matrix las cuales permiten recuperar imágenes de una calle de Santiago, georreferenciar una dirección y calcular el tiempo y la distancia estimada que demora un vehículo en desplazarse entre dos puntos respectivamente.

Para usar las APIs de Google es necesario, tener una cuenta de Google y registrarse en la plataforma de Google Cloud. Realizado lo anterior, Google permite generar una clave para el uso de las APIs, la cual otorga acceso a realizar consultas. Se recomienda que antes de utilizar las APIs de Google, se revisen las políticas de cobro y el límite máximo de consultas gratuitas que se permitan en ese momento.

Para programar e implementar *deep learning*, se recomienda utilizar la librería de Keras. Esta, puede ser utilizada con Python y su ventaja es que facilita la programación de redes neuronales profundas con múltiples capas haciendo uso de Tensorflow. Además, cuenta con una gran cantidad de documentación¹⁰ y flexibilidad

5.2 Modelo descriptivo usando imágenes

La caracterización de una calle puede dividirse en tres ambientes diferentes. En primer lugar, lo que tiene relación con la Calzada, la vereda y el entorno privado-público, como se puede observar en la Ilustración 18.

¹⁰ Documentación oficial de Keras. Sitio Web: <https://keras.io> (Consultado 10 de Septiembre 2018)




Ilustración 18: Modelo descriptivo

La distribución de elementos presentes en los ambientes anteriores cubren el espacio desde el suelo hacia arriba. Por ejemplo, los árboles que se observan en la ilustración anterior solo pertenecen al ambiente de la vereda. Para poder clasificar e identificar los elementos que se pueden encontrar en imágenes de Google Street View, la metodología utilizada fue la inspección de imágenes de Google.

El modelo descriptivo contempla los elementos de las fotos, el ambiente al que pertenecen, una subcategoría y una forma en que este puede ser medido. En la Tabla 5, se presenta un resumen de los algunos de los elementos más significativos a encontrar en una imagen para el problema asociado al robo de vehículos (Ver Apéndice D: Modelo Descriptivo, para más detalle).

Subcategoría	Variable de medición
casa	Tamaño, Cantidad de casas
Edificio	Tamaño, Cantidad de edificios
Estacionamiento	Presencia (B)
Vacío	Tamaño
Árbol	Cantidad de árboles, Tamaño de arboles
Autos - Acción - Existencia	Estacionado (B), Movimiento (B) - Cantidad de autos
Micros	Presencia (B), Presencia-Troncales-locales (B)
Pista de buses	Pista en la misma vía (B), Presencia de bandejon central (B)
Estacionamiento	Laterales (entre calle y terreno privado)
Portón	Presencia (B)
Muralla	Presencia (B)
Reja Libre (Con visión interior)	Presencia (B)
Arbusto (Usualmente los que están en las rejas)	Presencia (B)
Reja Tapada (Sin visión interior)	Presencia (B)
Estacionamiento vereda	Presencia (B)

Tabla 5: Resumen del modelo descriptivo de una imagen de GSV

5.3 Proceso KDD

Para esta memoria se utiliza el proceso *Knowledge Discovery in Database* (KDD) en dos etapas. Antes, se explica esta metodología que permite encontrar patrones en un gran conjunto de datos y generar a partir de ellos relaciones inesperadas que sean de interés y generen valor para los poseedores de dicha información, buscando relaciones no triviales que escapen a la opinión experta o que permitan respaldarla. El objetivo principal de esta metodología es entregar una herramienta al procesamiento de datos y para eso, se constituye de una serie de pasos iterativos.

Al ser un proceso iterativo, es posible volver a una etapa previa en caso de que no se obtengan resultados satisfactorios. En los siguientes pasos se describen las etapas del proceso KDD:

1. Integración o Selección: Se eligen las variables y las fuentes de información a utilizar. Se crean también las bases de datos que necesita el estudio.
2. Preprocesamiento: Corresponde al proceso de análisis y limpieza de los datos que se utilizan en el estudio, dando solución a aquellos datos ausentes, fuera de rango o con problemas, empleando en ello distintas técnicas para repararlos o eliminarlos.
3. Transformación: Corresponde a la generación de nuevas variables a partir de las variables originales.
4. Minería de datos: Corresponde a la aplicación de algoritmos o modelos de minería de datos que permiten identificar patrones a partir de los datos

5. Interpretación y Evaluación: Esta última fase tiene como objetivo usar medidas que permitan evaluar la performance de los algoritmos empleados en la etapa de minería de datos. Adicionalmente, tiene por objetivo interpretar los resultados obtenidos en el proceso completo, buscando generar conocimiento. En caso de que los resultados no sean interpretables o las evaluaciones no sean ad-hoc es necesario volver a iterar

La primera etapa de KDD consiste en entrenar diferentes modelos de predicción basados en redes neuronales convolucionales con el fin de validar si es posible determinar la ocurrencia de robos en Santiago a partir de imágenes obtenidas de Google Street View. Además, se entrenan otros modelos de *deep learning* y *machine learning* con el objetivo de validar si es posible determinar cuáles son las variables y la capacidad de predicción de variables asociadas a lugares de interés en Santiago, efectos temporales y la rapidez para evacuar en un lugar de Santiago. En resumen, hay distintas fuentes de datos y acá se realizan modelos por separados para predecir y obtener patrones.

La segunda etapa del proceso KDD, se realiza la integración de todas las fuentes de datos mencionadas en el párrafo anterior. Aplicando un modelo de *deep learning* que permite la concatenación de esta información y luego entrenar un clasificador, en función de distintos tipos de datos, lo que se conoce como *Data Fusion* [G1].

5.4 Primera etapa del proceso KDD

5.4.1 Lugares de robo y de no robo en Santiago

Uno de los desafíos de la memoria es identificar aquellos lugares donde no han ocurrido robos de vehículos en la ciudad de Santiago. Lo primero que se hace para encontrar estos lugares es levantar zonas en Santiago.

Para esto se define una zona de Santiago (Z_{ij}) como un cuadrado delimitado por cuatro coordenadas longitud y latitud, o también dos segmentos, uno que cubre la longitud y otro la latitud, de esta forma se define:

$$Z_{ij} = \{ \Delta_{longitud}^i, \Delta_{latitud}^j \} i \in \{0, \dots, D_i - 1\}, j \in \{0, \dots, D_j - 1\}$$

Donde $\Delta_{longitud}^i$ corresponde al segmento i -ésimo en longitud, donde i tomar valores entre $\{0, \dots, D_i - 1\}$, lo que representa la cantidad de celdas en que se divide Santiago en el eje de la longitud. $\Delta_{latitud}^j$ corresponde al segmento j -ésimo en latitud pudiendo tomar valores entre $\{0, \dots, D_j - 1\}$, lo que representa la cantidad de celdas en que se divide Santiago en el eje de la latitud. De esta

forma Z_{ij} corresponde a la celda i, j del mapa. Para construir este mapa cada segmento se define como:

$$\Delta_i^0 = \{Min_l, Min_l + \Delta_l\}$$

$$\Delta_i^r = (Max\{\Delta_i^{r-1}\}, Max\{\Delta_i^{r-1}\} + \Delta_l) \quad r \in \{i, j\}$$

Donde:

$$Min_l = \min(I_l) \quad l \text{ in } \{longitud, latitud\}$$

$$Max_l = \max(I_l) \quad l \text{ in } \{longitud, latitud\}$$

$$\Delta_l = \frac{Max_l - Min_l}{D_l} \quad l \text{ in } \{longitud, latitud\}$$

Donde I_l corresponde al conjunto de todos los valores de longitud o latitud, donde hubo un robo en la ciudad de Santiago.

D_l corresponden a la cantidad de intervalos en los que se divide Santiago en el eje de longitud o latitud respectivamente, estos parámetros se crearon para poder automatizar la generación del mapa de frecuencia de robos en Santiago. Δ_i corresponde al tamaño de segmento de cada celda de Z_{ij} .

Lo anterior permite construir celdas en Santiago, delimitadas por cuatro puntos con longitud y latitud. Dado que se tiene conocimiento de un lugar de robo como una coordenada geográfica, ahora bastaría comprobar a cual celda de Santiago pertenece el robo. Finalmente, realizando esto de forma iterativa para cada uno de los lugares donde ocurrieron robos, se puede contar cuantos robos han ocurrido en cada una de las celdas de Santiago.

Es claro que el tamaño del segmento (Δ_i) influye en el tamaño de la celda y a su vez, eso influye en la cantidad de robos contenidos en una celda, por lo tanto, se testearon diferentes tamaños de intervalos con el objetivo de tener una idea visual de cómo se distribuían las zonas de robo en Santiago.

Para realizar lo anterior, primero se usa como criterio que aquellas celdas donde la frecuencia de robos fluctúa entre 1 y 5 robos entre el 2011 y 2016, son zonas de bajo riesgo y aquellas con más de 5 robos de vehículos son zonas riesgosas.

Posteriormente, identificadas las zonas de bajo y alto riesgo se generaron puntos georreferenciados aleatorios para Santiago. El fin es generar más datos para zonas de bajo riesgo y de alto de riesgo.

La generación de puntos aleatorios tiene como objetivo adicional expandir la cantidad de datos totales con los que se está trabajando, esto se debe a la cantidad de datos necesarios para entrenar modelos, basados en redes neuronales profundas. Dado que ya se han identificado las zonas de riesgo y de bajo riesgo, se puede ver a cuál zona pertenece cada uno de los datos generados.

Se prueban diferentes tamaños de segmento (D_i), esto debido al efecto que produce un tamaño de celda más grande, que es concentrar una mayor cantidad de robos, por lo tanto, disminuyen considerablemente las zonas seguras.

Un tamaño de segmento (D_i) muy pequeño tiende a generar el fenómeno contrario, más adelante se utilizan tamaños de segmento pequeños con el fin de evaluar la capacidad de los modelos para detectar los lugares donde ocurren y no ocurren robos. Algunos resultados se pueden ver en la Ilustración 19.




Ilustración 19: Mapa de riesgo de robo en Santiago, para valores $D_i = \{40, 70, 150, 250\}$ [Elaboración propia en base a los datos generados a partir de la AACH]

En los gráficos de la Ilustración 19, las zonas azules, indican zonas donde ha habido poca concentración de robos, estos datos son generados aleatoriamente. Por otro lado, las zonas rojas indican lugares donde ocurrieron robos pertenecientes a la base de la AACH. Las barras laterales indican visualmente la concentración de los robos de vehículos en el eje x, correspondiente a latitud y para el eje y, correspondiente a la longitud.

El valor de los gráficos anteriores radica en mostrar que hay mayor concentración de robo de vehículos en el centro de Santiago y en el sector oriente.

Se proceden a identificar lugares donde han ocurrido robos y donde no han ocurrido. Para esto lo que se hace es dividir cada zona de Santiago en cuadrillas más pequeñas de 50 metros. El objetivo de esto es determinar lugares donde han ocurrido robos y donde no han ocurrido robos. Para luego estudiar si tanto las técnicas de *machine learning* y *deep learning* son capaces de clasificar lugares de robo y no robo de vehículos en Santiago.




Ilustración 20: Lugares y zonas de robo en Santiago [Elaboración propia]

En la Ilustración 20, a la izquierda está el gráfico de Santiago con una cuadrilla de 500 metros y se identifican zonas de alto y bajo riesgo, en color rojo y azul respectivamente, mientras que a la derecha se muestran lugares de robo y no robo en Santiago usando una cuadrilla de 50 metros.

La razón de utilizar esta metodología para levantar lugares donde han ocurrido y no han ocurrido robos es que no se cuenta con información sobre todos los puntos de longitud y latitud por donde pasan las calles de Santiago. Por lo tanto, al considerar lugares donde no han ocurrido robos fuera de las zonas de riesgo y bajo riesgo identificadas, estaría considerando lugares donde no

pasan calles y hay terrenos vacíos o privados, y que hay en mayor abundancia en la periferia de Santiago.

La idea de usar lugares donde hay y no hay robo en Santiago se debe a estudiar el fenómeno de robo en un lugar específico, porque al considerar un tamaño de cuadrilla más grande, como se observa la Ilustración 19, hay una mayor concentración de robos en el centro de Santiago y el sector oriente. Por lo tanto, es probable que las técnicas de *machine* y *deep learning* para detectar los lugares de robo terminen identificando que lugares están más cercanos al centro de Santiago y en el oriente son aquellos donde hay más robos y no cuales son los lugares donde se roba.

En resumen, un modelo entrenado sobre zonas podría clasificar lugares céntricos y en el sector oriente de Santiago y no necesariamente clasificar en función del lugar donde se robó. Adicionalmente, también es posible pensar que hay zonas que puedan ser riesgosas, pero al ser de 500x500 metros puede haber un lugar en esa zona que tenga ciertas características que lo hagan más seguro, por lo tanto, estudiar a nivel de zonas podría generar sesgos.

5.4.2 Construcción de base de imágenes usando GSV

Este primer proceso tiene por objetivo implementar técnicas de *machine learning* para entrenar un modelo que permita caracterizar un lugar en función del modelo descriptivo e imágenes de calles.

La base de datos de imágenes de Google Street View fue levantada por medio de la API de Google maps, la cual permite acceso a la ejecución de consultas automáticas a la base de datos de Google por medio de una cuenta Google, de esta forma se puede programar la extracción masiva de imágenes utilizando la geolocalización de los siniestros contenidos en la base de registro histórico de siniestros de la AACH y de lugares de Santiago levantada anteriormente.

Se destaca en que la sección 5.4.1 los lugares de Santiago son generados aleatoriamente, sin embargo, una gran cantidad de puntos que se pueden observar en las ilustraciones fueron generados aleatoriamente, por lo tanto, al solicitar a la API de Google Street View, para este punto aleatorio se busca la calle más cercana. Esto quiere decir que un punto (x_a, y_a) aleatorio luego de buscar su imagen más cercana se obtiene un punto (x_c, y_c) al cual se le llama corregido, porque es distinto al aleatorio. El punto (x_c, y_c) se obtiene al realizar un script en Python que permite recorrer los metadatos de cada una de las imágenes extraídas y cómo no se quiere evitar que hayan errores grandes, se utiliza este punto corregido en la memoria.

Para calcular el error existente entre el punto aleatorio y el corregido, se calcula $d((x_a, y_a), (x_c, y_c))$ donde d corresponde a la distancia Harvesiana. Los errores son del orden de 19 metros en promedio aproximadamente, (mínimo

de 0.2 metros, un primer cuartil de 16 metros, mediana de 15 metros, tercer cuartil de 28 metros y máximo de 51.3 metros). Dado que el tamaño de cuadrilla utilizado para las zonas y lugares podría ocurrir que un lugar esté mal asignado, se opta por utilizar la distancia corregida.

En el caso de los puntos que pertenecen a la base de la AACH, el promedio es de 7 metros aproximadamente (primer cuartil de 1.1 metro y tercer cuartil 10 metros).

Las imágenes de Google Street View tienen dimensiones de 640x640 y su campo de visión no es panorámico, sin embargo, la API de Google permite indicar los grados en que se quiere sacar una imagen, por lo tanto, la extracción de imágenes se realiza en 0° , 90° , 180° , 270° (Ejemplo de imágenes individuales en Ilustración 21). En consecuencia, cada siniestro cuenta con 4 imágenes separadas.



Ilustración 21: Fotos obtenidas de GSV en 0° , 45° , 90°

Para poder formar una imagen panorámica se utilizan técnicas de procesamiento de imágenes, ejecutando un script de Python que permite recorrer cada imagen y juntarlas, obteniendo imágenes panorámicas para cada siniestro (Ilustración 22).



Ilustración 22: Imagen panorámica construida por imágenes de GSV de 0° , 90° , 80° , 270°

La razón principal de esto es que las imágenes panorámicas aportan mucha más información de un lugar que una imagen que es capaz de cubrir solo un campo de visión aproximado de 45° .

Para el entrenamiento de redes CNN, se crea una carpeta que contiene las imágenes pre procesadas utilizando técnicas de aleatorización con saturación, contraste, brillo, transposición, matiz, flipping y cortes, para probar entrenar los modelos con imágenes con está aleatorización, pues según [61] de esta forma se construyen redes más robustas al tener diferentes tipos de variaciones presentes en imágenes naturales y hacen además predicciones más certeras, las variaciones que finalmente se utilizaron se pueden observar a modo de ejemplo en la Ilustración 23.



Ilustración 23: Ejemplos de variaciones aplicadas a las imágenes

Uno de los problemas a los que se enfrenta el estudio del fenómeno de robo de vehículos es el desbalance de los datos y una de ventajas de aplicar diferentes variaciones a las imágenes y generar data artificial es su uso para balancear conjuntos de datos con clases desbalanceadas. En el caso de esta memoria, como los lugares donde no han ocurrido robos de vehículo son más que aquellos donde han ocurrido robos de vehículos, se utiliza esta técnica de balanceo en aquellas clases con menos datos, para ampliar la cantidad de datos de entrenamiento y ver cómo se comportan los modelos entrenados con más datos.

Inicialmente el ratio entre un lugar donde no ha ocurrido robo y otro donde no ha ocurrido robo es menor al 10% en el caso de robos, sin embargo, luego de aplicar balanceo de datos el ratio aproximado puede llegar a un 50% entre ambas categorías.

La razón de hacer lo anterior, es evitar que los modelos generen sobreajuste para una única clase, generando de esta forma un "clasificador trivial". Esto se debe a que, si un conjunto de entrenamiento tiene un 90% de datos de clase A y solo un 10% de clase B, al entrenar una red si no se aplica ninguna técnica, la red tenderá a clasificar el 100% del conjunto de datos como clase A, lo cual entrega efectivamente un buen *accuracy*, pero en realidad el modelo no es capaz de clasificar un caso B.

Al generar datos, se aplican aleatoriamente los mismos filtros en las imágenes de la clase que tiene más datos, esta aplicación de filtros se aplica a medida que se cargan las imágenes. La finalidad es evitar que el modelo CNN aprenda a clasificar las clases fijándose únicamente en los filtros, por lo tanto, esta aleatorización homogeniza la aplicación de filtros en las distintas clases.

Otra de las transformaciones utilizadas en las imágenes corresponde al redimensionamiento de tamaño, esto se debe a que las imágenes de tamaño de 640x640 pixeles en RGB, elevan el costo computacional en el entrenamiento de las redes neuronales. Este costo, también depende de la profundidad de la red neuronal y la cantidad de imágenes que sean usadas para el entrenamiento. Por lo tanto, para mejorar la velocidad de entrenamiento y computo se redimensionan las imágenes a 224x224 pixeles. El tamaño usado se justifica a que es suficiente para ser utilizado en redes profundas descritas anteriormente, aún permite distinguir cuales son los elementos de la imagen y hay estudios que usan tamaños de imagen similar [G1], [F11].

Se realizaron algunas pruebas preliminares de identificación de objetos utilizando algunas redes pre entrenadas usando el conjunto de datos de ImageNet, sin embargo, la capacidad de identificación de elementos no es suficiente para la resolución del problema planteado, por lo tanto, se opta por entrenar redes inicializadas con pesos aleatorios.

Uno de los inconvenientes que tiene la API de Google Street View, corresponde a la extracción de imágenes que no corresponden a imágenes de las calles de Santiago (Ver Ilustración 24), el cual no es abordado en esta memoria. En primer lugar, porque estas imágenes son consideradas como ruido presente en todas las clases que se quiere clasificar, por lo tanto, el impacto en la clasificación de lugares de robo de vehículo es menor y, en segundo lugar, porque dar solución al problema de imágenes *indoor* y *outdoor* es un problema presente en la literatura, que involucra el entrenamiento de otra red, para la detección de ambientes y posterior filtrado, lo cual no es parte del alcance de la memoria.



Ilustración 24: Fotos incorrectas obtenidas de la API de Google

5.4.3 Construcción de base de capacidad de huida

Se desea estudiar en qué momento ocurre un robo y para esto se caracteriza el momento de robo en función de la capacidad de huida que tienen los ladrones en el robo de vehículos y la hora en que ocurre. Se utiliza la variable que indica la hora de robo del vehículo en la base de la AACH. Para esto, en primer lugar se definieron 12 variables binarias que indicaban el intervalo en que había ocurrido el robo. Cada uno de estos intervalos comprende 2 horas. Por lo tanto, el primer intervalo de tiempo corresponde desde las 00:00 a las 02:00, hasta llegar a las 24:00 horas.

Por otro lado, se cuenta con información del tráfico de Santiago. Para esto se genera la variable de congestión asociada al vehículo robado. La variable de congestión puede ser baja, media, alta y muy alta y comprende los siguientes horarios:

1. Baja de las 22:00 a las 24:00 y de las 00:00 a las 7:00
2. Media de las 7:00 a las 12:00 y de las 21:00 a las 22:00
3. Alta de las 12:00 a las 16:30 y de las 20:00 a las 21:00
4. Muy alta de las 16:30 a las 20:00

Como se conoce la hora a la que fue el robo, se puede tener una idea del tipo de congestión que había en las calles en ese momento, de esta forma se construye una variable binaria que permite caracterizar si el robo ocurrió en cierto contexto de tráfico. Los niveles de congestión fueron generados usando información de una autopista de Santiago.

Finalmente, se tiene información del momento donde ocurrió un robo de vehículo, pero no de cuando no ocurrió un robo. La solución a este problema es generar datos aleatorios de alguna hora donde no ocurrió un robo, lo que permite caracterizarlo en función del intervalo de tiempo y del nivel de congestión vehicular.

Posteriormente, se adiciona una variable a la base que contiene información correspondiente a la capacidad de huida, para esto se hizo uso de la API de Google Distance-Matrix la cual permite calcular el tiempo que se demora un

vehículo en desplazarse a una distancia definida desde un punto de origen y uno de destino.

Cabe destacar que el tiempo demorado depende de el punto de destino (x_f, y_f) y el punto de origen (x_o, y_o) que se entrega a la API de Google. Para simplificar la consulta, dado que la API Distance-Matrix tiene mucho mas restricciones en el número de consultas diarias que la de Street View. Se considera como punto de destino algún punto tal que $1000 < d((x_f, y_f), (x_o, y_o)) < 2000$ metros, donde d corresponde a la distancia harvesiana. El límite inferior y superior se eligieron por inspección, fundamentalmente porque distancias muy pequeñas no permiten ver fluctuaciones del tráfico y distancias muy grandes tienden a homogeneizar y eliminar el efecto del tráfico.

Los resultados de la API Distance-Matrix son la distancia, duración sin considerar efectos del tráfico y duración considerando los efectos del tráfico. Para poder tener una medida de huída del lugar se construyeron las variables de velocidad con efecto tráfico y sin efecto tráfico.

Luego y a modo de ejemplo, un punto de la ciudad puede ser caracterizado en términos de la variable de capacidad de huida, horario de robo y si está en un horario de tráfico o no. Un ejemplo de cómo quedarían caracterizados los lugares de Santiago se puede observar en la tabla siguiente:

Punto de la ciudad	0a2	...	22a24	Hora bajo trafico	...	H. Muy alto gráfico	vel_avg_traffic	vel_avg_nontraffic
Lugar 1	1	0	0	1	0	0	6.318	6.318
Lugar 2	0	1	0	0	0	1	6.115	5.496

Tabla 6: Caracterización de un punto de Santiago según capacidad de huida

5.4.4 Construcción de base de lugares de interés en Santiago

Para poder generar la base que contiene información correpondiente a puntos de interes en Santiago se hizo uso de la página Civico, correspondiente a una página colaborativa, donde los mismos habitantes registran distintos puntos de interés social de Chile bajo un modelo de *crowdsourcing* basado en misiones, puntos y beneficios. Esta página cuenta actualmente cuenta con mas de 500.000 descargas y una gran cantidad de colaboradores.

se ejecutó un proceso de Web Scraping sobre la página de "*Civico.com*", para esto se usan las técnicas de web scraping existentes usando Python y las librerías de Selenium y BeautifulSoup. Ambas librerías están enfocadas y diseñadas para la automatización y extracción de inforamción de una página web. La cual consta de las siguientes etapas:

1. Extracción del codigo de la página web
2. Identificación y extracción de información por etiqueta de HTML
3. Estructuración de los datos

La página consta de los siguientes niveles de información, correspondientes a las categorías de puntos de interés: Entretenimiento, restaurantes, Compras, Belleza y Bienestar, Turismo, Comercio, Salud, Servicios, La Ciudad, Tráfico y Transporte.

Mientras que cada punto de interés se encuentra representado por medio de una caluga de información como se observa en Ilustración 25 e Ilustración 26, donde se muestra la forma de la caluga en la página y su código fuente, el cual usando *Web Scraping* permite obtener la información.



Feria Libre Camino del Inca / Vecinal - El Bosque

Camino del Inca esq. Padre Hurtado

🕒 Cerrado a esta hora

Ilustración 25: Caluga de información. Página de CIVICO

```

▼<div class="col-md-12" id="search-results">
  ▼<div class="card-holder-container listings-cards">
    ▼<div class="card-list component-card-grid results">
      ▼<div class="card-component place-card" data-address="Camino del Inca esq. Padre Hurtado" data-icon="entretenimiento" data-latitude="-33.577764" data-longitude="-70.676551" data-name="Feria Libre Camino del Inca / Vecinal - El Bosque" data-url="/lugar/feria-libre-camino-del-inca-slash-vecinal-el-bosque-santiago">
        ▼<a href="/lugar/feria-libre-camino-del-inca-slash-vecinal-el-bosque-santiago" class="card-component-link-wrap" data-seo="{\"eventCategory\": \"Card Acción\", \"eventAction\": \"Home\", \"eventLabel\": \"\", \"event\": \"GAevent\" }\">
          ▶<div class="card-component-body owl-lazy lazy-hidden" style="background-image: url(\"https://res.cloudinary.com/civico/image/upload/c_fill,f_auto,fl_lossy,h_197,q_auto:low,w_360/v1413838092/entity/category/placeholder/50fec55331e93cc841000a4.jpg\");">...</div>
          ▼<div class="card-component-extra">
            ▼<div class="extra-info">
              <h2 class="name" itemprop="name">
                Feria Libre Camino del Inca / Vecinal - El Bosque
              </h2>
              <p class="streetAddress text" itemprop="streetAddress">
                Camino del Inca esq. Padre Hurtado
              </p>
              ▶<p class="text">...</p>
            </div>
          </div>
        </a>
      </div>
    </div>
  </div>

```

Ilustración 26: Código fuente de caluga de información. Página de CIVICO

En primer lugar se obtuvo manualmente todos los links por categoría de punto de interés, en segundo lugar haciendo uso de Firefox por medio de Selenium se realizaron una serie de iteraciones que permiten desplegar toda la información de la categoría. En tercer lugar, se extrajo por medio de selenium

el código completo html de la página web y haciendo uso de BeautifulSoup se procedió a extraer el string contenido en las siguientes etiquetas: "h2" de clase "name" y "p" de clase "streetAddress text" las cuales están contenidas en una etiqueta "div" de clase "card-component place-card".

El código generado, permitía extraer la información de cada categoría y luego obtener la información de cada punto de interés, estructurándola en una base de datos que contiene la variable de nombre del punto de interés, dirección, categoría del punto de interés, sub categoría y sub sub categoría. Obteniendo una base de datos con 133.758 puntos de interés en Santiago.

Posteriormente, dada la necesidad de trabajar con geolocalizaciones y no con direcciones se hace uso de la API de Google que permite obtener la geolocalización de cada una de las direcciones, agregando de esta forma a la base de datos dos columnas correspondientes a la longitud y latitud para cada punto de interés de Santiago.

5.4.5 Resumen de bases de datos utilizadas

Las bases de datos utilizadas a lo largo de la memoria pueden ser descritas como sigue:

- Registro Histórico de Siniestros: Esta base de datos contiene registros asociados a siniestros de robo de vehículos asegurados en Chile (Base de la AACH), donde se encuentra información relacionada al siniestro, al vehículo siniestrado, la información del cliente y datos de registro. Esta base de datos cuenta con 55626 siniestros correspondientes a la Asociación de Aseguradoras de Chile
- Registro de lugares de Santiago: Esta base de datos contiene ubicaciones aleatorias de Santiago donde se han registrado robos de vehículos asegurados y donde no hay registro de robos
- Puntos de interés de Santiago: Esta base de datos contiene información asociada a puntos de interés social como entretenimiento, restaurantes, compras, belleza y bienestar, turismo, comercio, salud, servicios, la ciudad y tráfico y transporte
- Capacidad de huida: Esta base de datos contiene información asociada tanto a distintos lugares de Santiago con información sobre la velocidad promedio y el tráfico en las calles.
- Imágenes de Google Street View: Esta base de datos cuenta con imágenes panorámicas aproximadas a los lugares donde ocurrieron los siniestros del registro histórico de siniestros y donde no se han registrado siniestros. Estas imágenes provienen de Google Street View.

5.4.5.1 Descripción de datos de la AACH

En primer lugar, esta base cuenta con cuatro dimensiones de información diferentes (Más detalles en Apéndice C: Información contenida en Base de AACH) correspondientes a información de contexto del vehículo siniestrado, del contratante y conductor del seguro, de las características del vehículo, además de datos asociados a la denuncia y búsqueda.

Solo se considera información relacionada al contexto de robo, particularmente la dirección de robo, el resto de la información no es considerada para efectos del estudio.

Se descarta usar información de los vehículo siniestrados porque no se tiene información de autos que hayan estacionados en un lugar donde haya ocurrido el robo y no hayan sido robados, por lo tanto, al no contar con esta comparación no se puede entrenar un modelo que permita estudiar si hay características intrínsecas del vehículo que influyen en el robo de vehículos o representa un problema de solución no trivial.

La información que hace referencia al contratante y conductor del vehículo no se considera porque no aportan información respecto a donde ocurren o no robos y no es objeto de estudio si las personas tienen características particulares que puedan incidir en la probabilidad de robo.

La información del proceso de búsqueda no es considerada porque no es parte del alcance de la memoria estudiar si el estado de búsqueda del vehículo tiene alguna significancia en los patrones de robo.

Algunas características de los datos se encuentran dadas por:

1. Completitud de los datos de dirección:

Dato de dirección	Cantidad (%)	Cantidad
Tiene dirección	83.2%	46293
No tiene dirección	16.8%	9333

Tabla 7: Datos con dirección [Elaborado con datos de AACH]

2. Sobre el tipo de vehículos contenidos en la base de datos:

Tipo de vehículo	Cantidad (%)	Cantidad
Automovil	43.5%	24205
Station Wagon	25.8%	14327
Camioneta	18.8%	10474
Otras categorías (Fuera del estudio)	11.9%	6620

Tabla 8: Tipo de vehículos [Elaborado con datos de AACH]

3. Siniestros según marca del vehículo:

Marca de Vehículo	Cantidad (%)	Cantidad
Hyundai	19%	9456
Toyota	14%	7157
Chevrolet	11%	5413
Nissan	10%	5122
Kia Motors	10%	4823
Suzuki	7%	3245
Subaru	3%	1538
Samsung	3%	1403
Mitsubishi	2%	1208
Mazda	2%	1175
Ford	2%	945
Ssangyong	2%	858
Desconocida	1%	643
Peugeot	1%	630
BMW	1%	546
Volkswagen	1%	540
Jeep	1%	503
Otras marcas	9%	4434

Tabla 9: Vehículos asegurados y robados según marca [Elaborado con datos de AACH]

4. Completitud de los datos relacionales al relato del siniestro:

Dato de relato	Cantidad (%)	Cantidad
Tiene relato	92%	51391
No tiene relato	8%	4235

Tabla 10: Datos con relato [Elaborado con datos de AACH]

Para filtrar cuales de datos de robo corresponden a Santiago, se desarrollaron códigos que permiten verificar la pertenencia de estos puntos en Santiago. Para esto, primero se usa OpenStreet Map que permite extraer la limitación de cada una de las comunas de Santiago en terminos de coordenadas de longitud y latitud, formando un poliedro de cada comuna. Esta información se obtiene realizando una consulta para cada una de las comunas de Santiago lo que permite definir una base de datos consolidada de cada una de las comunas.

Graficando estos valores, se puede obtener un gráfico de cada una de las comunas de Santiago que se están estudiando en esta memoria:




Ilustración 27: Limitación de comunas de Santiago [Elaboración propia con datos consolidadas de OSM]

La variable de dirección de siniestro en la base de la AACH cuenta con una serie de valores ausentes o incompletos. La base de siniestros contiene siniestros que no ocurrieron en Santiago, estos datos fueron eliminados, para llevar a cabo esta tarea se considera Santiago como un poliedro limitado por una serie de coordenadas de longitud y latitud (Formada por la unión de sus comunas). Por lo tanto, al geolocalizar cada punto de robo, se verifica si cada uno de estos puntos pertenece a alguno de los poliedros de las comunas de Santiago de la Ilustración 27.

La base de Siniestros cuenta con datos que no corresponden a vehículos, por lo tanto, todos aquellos robos que no sean automóviles, camionetas, todo terreno y Station Wagon son eliminados, porque no forman parte de los objetivos de estudio.

Inicialmente las direcciones están en formato string, por lo tanto, las direcciones de siniestro fueron geolocalizadas por medio de la API de geolocalización de Google.

Dado que cada comuna corresponde a un poliedro ubicado en un espacio, se verifica si un punto de robo, definido ahora como por su longitud y latitud pertenece o no a una comuna a partir de la georeferenciación de los datos de

robo, usando la API Geocoding de google, de esta forma los datos que finalmente fueron seleccionados se pueden observar en el siguiente gráfico:

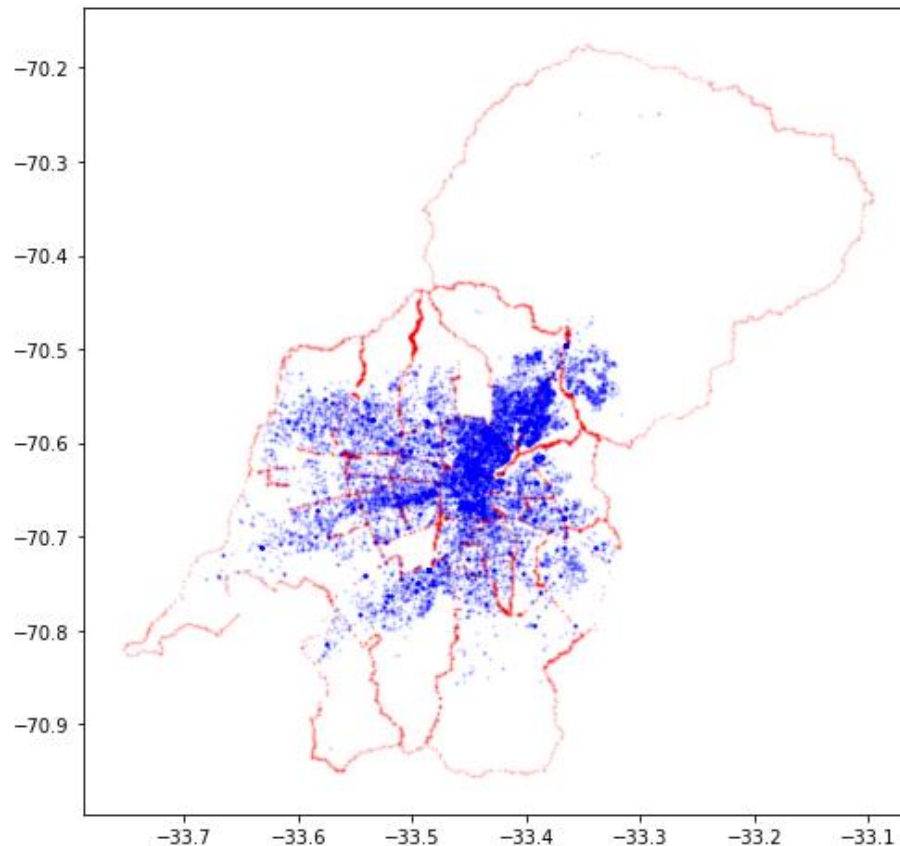


Ilustración 28: Gráfico de robo de vehículos en Santiago [Elaboración propia con datos consolidados de OSM y AACH]

5.4.5.2 Descripción de base de datos de puntos de interés

Esta base cuenta con dos categorizaciones de elementos de la ciudad, la categorización primaria y una subcategorización¹¹ para cada clase:

- Entretención: bares y discotecas, cine, cultura, deporte, juegos, parques y plazas, vida social
- Comercio: agrícola, alimentos, aseo y limpieza, climatización y/o aire acondicionado, comercios especializados, concesionarios y automotoras, construcción, cordonerías, cumpleaños y/o cotillón, decoración de hogar, electrodomésticos, kioscos, lotería, otros comercios, plásticos, prenderías y/o casas de empeño, reciclaje y/o chatarra, tiendas electrónicas

¹¹ También se le llamará categorización secundaria. Para ver detalles de que contienen las categorías secundarias revisar el Apéndice F: Descripción de variables de puntos de interés

- Salud: hospitales clínicas centros de salud, médicos y especialistas, previsión de salud, rescate médico, terapias naturales
- Servicios: academias y cursos, agencias de empleo, comunicaciones, deportivos, educativos, empresas y/o oficinas, financieros, mantenimiento de maquinaria, mascotas, otros servicios, para el auto y/o moto, para el hogar, servicio técnico, servicios especializados, servicios personales, servicios contables, vivienda
- La ciudad: Comisarias y/o carabineros, compañías de bomberos, conventos, embajadas, entidades oficiales y/o ministerios, fundaciones, iglesias, municipalidades, ONG, oficinas y dirección pública, otros organismos ciudad, seminarios
- Trafico y transporte: centros bip, ciclovías, estacionamientos, metro, Santiago en bici, Transantiago, urbano
- Turismo: aeropuertos, agencias de turismo, hospedaje, puntos de información, puntos de interés, terminal de transporte
- Belleza y bienestar: barberías y/o Barber shop, centros de pilates y/o yoga, maquilladores, para deportistas, para verse bien, spa
- Compras: Centros comerciales y/o mall, compras personales, hogar, joyas y accesorios, otras compras, para vestirse, para niños y bebés, regalos, tecnología, tetarías, tiendas de música y/o disquería, uniformes, venta de entradas, zapatería
- Restaurantes: Cafés y/o cafeterías, chilena, comidas rápidas, delivery a domicilios, fruterías y/o verdulerías, helados y/o postres, internacional, otros restaurantes, parrilladas, pescados y mariscos, picadas, vegetariano y/o naturista

Mientras que la distribución de datos según las categorías presentes se puede observar en la tabla siguiente:

Categoría	Cantidad (%)	Cantidad
Servicios	34.56%	46227
Comercio	20.26%	27101
Compras	12.67%	16951
Trafico y transporte	9.22%	12338
Restaurantes	8.37%	11198
Entretención	4.58%	6124
Salud	3.84%	5136
Belleza y bienestar	3.65%	4885
La ciudad	1.47%	1962
Turismo	1.37%	1836

Tabla 11: Puntos de interés en Santiago según categoría

Al igual que la base de datos de siniestros, inicialmente la base de direcciones de puntos de interés, se encuentra en formato string, por lo tanto, para poder hacer uso de esta información en la memoria es necesario convertir la dirección a una longitud y latitud, por lo que nuevamente se utilizó la API de geolocalización de Google.

Una vez obtenidos todos los puntos de longitud y latitud, la distribución de estos puntos de interés en la ciudad de Santiago se puede observar en la ilustración:




Ilustración 29: Distribución de puntos de interés en Santiago [Elaboración propia con base de puntos de interés]

La razón de convertir las direcciones de los puntos de interés a longitud y latitud es que este tipo de dato facilita determinar el nivel de cercanía con otro lugar de Santiago, por medio de alguna medida de distancia geométrica.

5.4.6 Transformaciones

5.4.6.1 Santiago caracterizado por puntos de interés

Se caracteriza la vecindad de un lugar de riesgo y uno de no riesgo con su entorno combinando la base de datos de puntos de interés de Santiago y la de lugares de Santiago. Para esto se define el entorno por medio de superficies circulares y anillos como se demuestra en la siguiente ilustración:

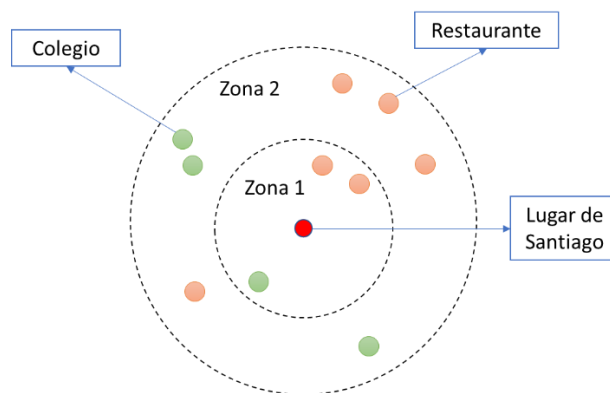


Ilustración 30: Ejemplo de caracterización de un punto de la ciudad

El objetivo es contar la cantidad de elementos como restaurantes, clínicas, negocios u otros puntos de interés social que hay en cada una de las zonas. Para esto se calcula la distancia geométrica que existe entre el lugar de estudio, el cual se ubicaría en el centro de la circunferencia y el punto de interés. Luego de calcular la distancia de un punto de interés, se verifica a que zona pertenece el punto de interés respecto al lugar, para esto se utilizan los siguientes criterios:

- Pertenece a la zona uno si la distancia se encuentra entre 0 a 500 metros (D1 o Zona 1)
- Pertenece a la zona dos si la distancia se encuentra entre 500 y 1000 metros (D2 o Zona 2)

Luego de identificar a que zona pertenece el punto de interés, este es contado a la subcategoría a la cual pertenece, de esta forma y a modo de ejemplo simplificado un punto de la ciudad podría ser caracterizado de la siguiente forma:

Punto de la ciudad	academias y cursos (D1)	Comida rápida (D1)	academias y cursos (D2)	Comida rápida (D2)
Lugar 1	5	2	5	2
Lugar 2	1	1	5	5

Tabla 12: Ejemplo de base de datos de caracterización de un punto de Santiago según puntos de interés

Obteniendo de esta forma una base de datos que describe un punto de Santiago en función de los diferentes tipos de puntos de interés que le rodean y la cercanía en que este se encuentra.

5.4.7 Modelos de predicción implementados

5.4.7.1 Modelos propuestos

Se entrenan modelos separados para cada fuente de datos descrita anteriormente, usando Random Forest, SVM-Lineal, Logit y redes neuronales. Se usan diferentes métodos para evaluar el nivel de predicción que tiene ese

conjunto de datos para predecir el fenómeno de robo de vehículos y también se usan otros para buscar patrones que expliquen el fenómeno.

Primero, se entrena un modelo que estudia la relación entre la ocurrencia de robo de vehículo en un lugar de Santiago y los puntos de interés social.

Segundo, se entrena un modelo que caracteriza el momento de robo de un lugar en función de cuando este ocurrió, a través de variables de tráfico, hora de ocurrencia del fenómeno y capacidad de huida.

Tercero, se entrena un modelo que permite predecir la ocurrencia de robo a partir de información *in situ*, la cual se captura por medio de imágenes de Google Street View.

Finalmente, se entrena un modelo conocido como *data fusión*, en resumen es una mezcla de distintos tipos de redes neuronales con diferentes inputs. El objetivo, es ver el nivel de predicción en la ocurrencia de robo de vehículos en un lugar combinando las distintas fuentes de información.

Se recuerda en este punto que los lugares de Santiago son representados como una cuadrilla de 50x50 metros. La variable dependiente es una variable binaria que toma valor 1 si ocurrió un robo en el lugar o 0 cuando no ocurrió un robo en ese lugar.

El conjunto de datos de entrenamiento y test para la aplicación de modelos se compone de un 80% de datos para el entrenamiento y un 20% para test. Un ejemplo de la distribución de estos datos puede ser vista en la Ilustración 31, en rojo se muestran los lugares donde ha ocurrido un robo de autos y en azul donde no ha ocurrido robo de autos.




Ilustración 31: Conjunto de entrenamiento y test (izquierda y derecha respectivamente)

Cabe destacar que en la elaboración del conjunto de datos se agregó una restricción, donde la mínima distancia entre un punto y otro es de 25 metros (En [G1] se utiliza una distancia de aproximadamente 10 metros entre puntos). Esto es para evitar que haya datos en el caso de las imágenes que prácticamente no tengan variación, esto es para evitar tener un resultado más realista una vez que se evalué la performance de los modelos, esta restricción también aplica para el resto de los conjuntos de datos, pero en esencia se aplicó esta restricción para el conjunto de imágenes.

5.4.7.2 Modelos aplicados a Puntos de interés

Para entender el fenómeno de los puntos de interés, es decir, encontrar aquellas categorías que tienen mayor influencia o aquellas que son estadísticamente significativas en los robos de vehículos, se entrenaron modelos de *machine learning* con el objetivo de entender el comportamiento de estas variables.

Las variables que entran a estos modelos corresponden al conteo de puntos de interés por categoría secundaria descritos en el Apéndice E: Categorías secundarias de puntos de interés.

El modelo base a entrenar para el modelo logit y SVM corresponde a:

$$Y_i = \sum_{j \in J} \sum_{i \in I} \sum_{d \in D} \beta_{jd} \cdot X_{ijd} + \alpha_1 \cdot F_1 + \alpha_2 \cdot F_2 + \varphi$$

Donde Y_i es la variable binaria del dato i -ésima, que toma valor 1 en el lugar en el que ocurrió un robo y 0 en un lugar donde no ha ocurrido un robo según la base de la AACH.

El dato X_{ijd} corresponde a la cantidad de puntos de interés que tiene un lugar de Santiago en una zona. i corresponde al dato i -ésimo de Santiago y j la categoría del punto de interés social y $d = \{1,2\}$ corresponde a la zona en que se está realizando el conteo, donde $d = 1$ corresponde al radio de 0 a 0.5 kilómetros y $d = 2$ corresponde al radio de 0.5 a 1 kilómetro. β_{jd} corresponde al coeficiente asociado a la categoría j -ésima de interés y X_{ij} corresponde a la cantidad de puntos asociados a la categoría j -ésima de interés asociados al dato i -ésimo.

Mientras que F_1 corresponde a la distancia del punto i a plaza de armas y F_2 la distancia al costanera center. Por otro lado, los valores α_1 y α_2 corresponden a los coeficientes asociados a esa variable.

Para la selección de características en el modelo logit se utiliza el algoritmo de "Backward" para la selección de variables. En el caso de Random Forest se utiliza el algoritmo de Boruta para la selección de variables en el modelo y finalmente se entrena un modelo de Support Vector Machine (SVM) lineal para luego recuperar las variables más relevantes.

Este modelo al igual que el de regresión logística y SVM, tiene como variable dependiente la ocurrencia de un robo y las variables explicativas las asociadas.

En el caso de Random Forest la selección de variables no tiene la misma estructura que los modelos anteriores, se utilizan como parámetros la generación 5000 árboles de decisión, donde cada árbol contiene la selección de 8 variables aleatorias para su entrenamiento.

5.4.7.3 Modelos aplicados a Capacidad de huida

Para entender el fenómeno de huida de un lugar y cómo este influye en el robo de vehículos, se ajustan los modelos en el caso del modelo logit y SVM correspondiente a:

$$Y_i = \sum_{t \in \{1, \dots, 12\}} \beta_t \cdot T_{ti} + \sum_{r \in \{1, \dots, 4\}} \alpha_r \cdot C_{ri} + \gamma \cdot V_i + \varphi$$

Donde Y_i es una variable binaria del dato i , que toma valor 1 si en ese momento ocurrió un robo y 0 si en ese momento no ocurrió un robo. La variable T_{ti} indica el intervalo de tiempo en que ocurrió el suceso i (Toma valor 1 si ocurrió en el intervalo t o 0 en caso contrario) y β_t permite ver el efecto asociado al robo en un intervalo. C_{ri} indica el nivel de tráfico que tenía el registro i (Toma valor 1 si ocurrió con el nivel de tráfico r o 0 en caso contrario), mientras que α_r corresponde al coeficiente que explicaría cómo el nivel de tráfico afecta al momento de robo. La variable V_i Indica la velocidad promedio de huida

asociada al dato i , mientras que γ corresponde al coeficiente que explica como la velocidad de huida afecta al robo. El índice $t \in \{1, \dots, 12\}$ porque se construyen 12 intervalos de tiempo, mientras que $r \in \{1, \dots, 4\}$ porque se definen cuatro niveles de tráfico.

También se aplica un modelo Random Forest que utiliza como variables explicativas las mismas descritas anteriormente.

5.4.7.4 Modelo de redes CNN sobre imágenes

Para el estudio de modelos de predicción utilizando imágenes son aplicadas diferentes arquitecturas de redes CNN. Se utilizan las arquitecturas de DenseNet y ResNet, además de otras redes propias inspiradas, las cuales se denominan BGM, basadas en los modelos VGG pero con menor cantidad de capas y profundidad.

Se prueban 4 modelos diferentes BGM. Como se mencionó, tienen estructura similar a los VGG, difieren por una menor cantidad de capas y neuronas finales en la clasificación. La variación entre cada uno de los modelos BGM es que los modelos BGM4 y BGM6 contienen capas de *average pooling*, mientras que BGM3 y BGM5 contienen capas de *max pooling*, mientras que BGM5 y BGM6 tienen una mayor cantidad de neuronas en las capas finales en comparación a BGM3 y BGM4.

El fenómeno a estudiar corresponde al robo de vehículos en un lugar, caracterizado a través de imágenes. El modelo puede ser representado por medio de la siguiente figura:




Ilustración 32: representación de los modelos utilizados

Donde n_1 y n_2 son las neuronas finales que permiten obtener un score o probabilidad de robo de vehículo. Cada una de las imágenes de Santiago, se encuentra etiquetada según si en ese lugar ocurrió un robo o no.

Las arquitecturas de redes utilizadas en [G1], [F11] usan imágenes de tamaños menores o iguales a 224x224 RGB para entrenar clasificadores para reconocimiento de lugares o escenas. En el caso de la memoria, el tamaño original de las imágenes es de 640x640 RGB, sin embargo, las imágenes de este tamaño elevan considerablemente el costo computacional de los modelos, por lo tanto, las imágenes fueron redimensionadas a 224x224 en RGB, para

disminuir el costo computacional, apoyándose en que los trabajos enunciados anteriormente que muestran resultados favorables usando imágenes de ese tamaño.

A parte de los modelos anteriores, se entrena otro modelo, usando una red BGM4 pero la etiqueta de las imágenes es diferente, las neuronas n_1 y n_2 representan una zona de alto riesgo o de bajo riesgo, a diferencia del modelo anterior que representa un lugar de robo o un lugar donde no ha habido robos. Se define como zona riesgosa aquella donde han ocurrido más de 5 robos, mientras que una zona de bajo riesgo tiene menos de 5 robos en un cuadrante de 500x500 metros. El objetivo de este modelo es ver la capacidad predictiva de una red CNN en espacios más grandes.




Ilustración 33: representación de los modelos utilizados

Adicionalmente, se entrena un modelo de data fusión con imágenes panorámicas. Este modelo a diferencia de los modelos anteriores donde solo se considera como inputs imágenes con 90° de visión, ahora utiliza cuatro inputs, correspondientes a 4 imágenes que al juntarlas permiten tener una noción panorámica de 360°. Esta red a diferencia de las anteriores es más profunda y se entrena solo con la etiqueta de lugar de robo. Se puede observar la arquitectura de esta red en la ilustración siguiente:

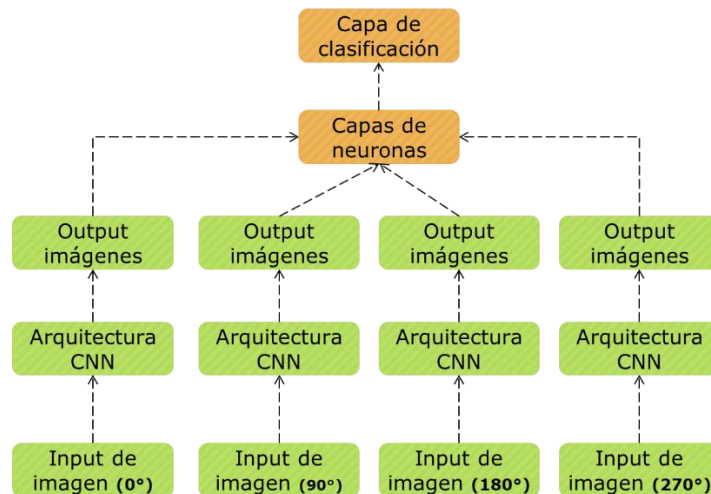


Ilustración 34: Modelo CNN para imágenes panorámicas

El objetivo de este modelo es ver la capacidad predictiva de una red CNN utilizando un contexto panorámico de los lugares.

5.5 Segunda etapa del proceso KDD

5.5.1 Arquitectura de Fusión de datos

En la Sección 5.4.7, se estudia el desempeño de los modelos entrenados con las bases de dato de forma independiente. Esto, permite tener una idea del nivel explicativo que tiene cada fuente de datos y también, permite aplicar técnicas y modelos de *machine learning* para descubrir, cuáles de las variables de cada fuente de datos son las que tienen mayor nivel explicativo sobre el fenómeno de robo de vehículos.

En esta segunda etapa de KDD se realiza una fusión de datos, usando diferentes modelos, los cuales se pueden observar en la Ilustración 35. El objetivo es construir un modelo más robusto para la clasificación de lugares de robo en Santiago, esto es parte de las hipótesis planteadas inicialmente en la memoria "los factores ambientales en conjunto tienen mayor capacidad explicativa que por sí solos", esto puede ser explicado entendiendo que la decisión de robo se basa en múltiples factores, que se combinan entre ellos.

El modelo de fusión de datos se realiza por medio de la composición de diferentes redes neuronales o también, puede interpretarse como una fusión de diferentes conjuntos de datos que buscan dar explicación a un fenómeno.

Se probaron tres modelos diferentes. El primero, corresponde a un modelo que aplica una red CNN y el output de esta red se concatena con el input de puntos de interés. El segundo modelo, incluye capas de neuronas antes de realizar la fusión de los datos de puntos de interés y el output de la red CNN. El tercer modelo, incluye capas de neuronas en el input del conjunto de datos de puntos de interés y después de realizar CNN, después de pasar por estas capas de neuronas se realiza una concatenación y nuevamente se agregan capas de neuronas antes de la clasificación.

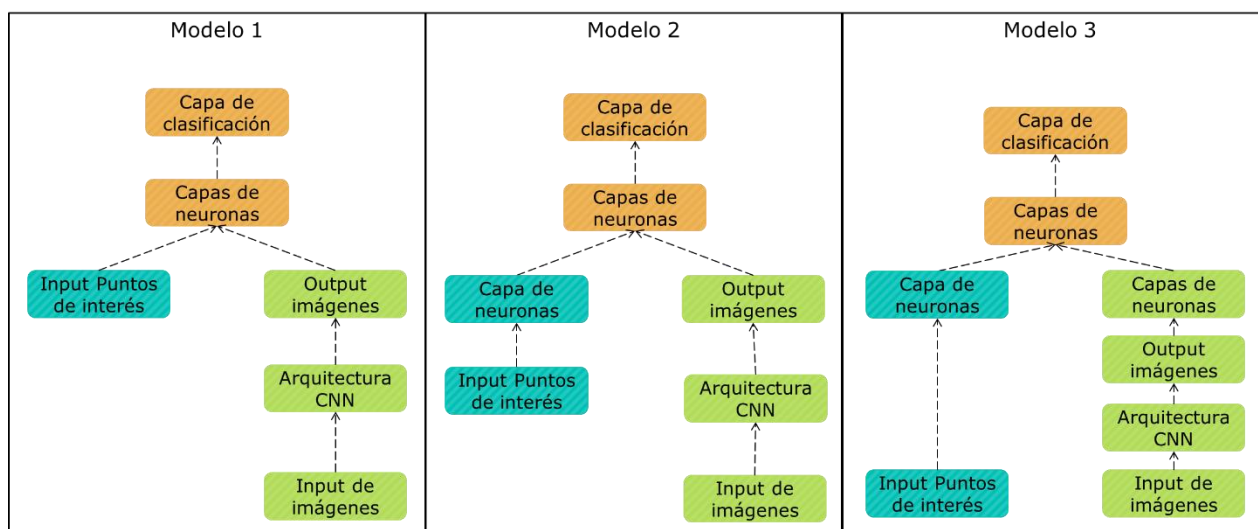


Ilustración 35: Descripción de modelos de predicción

Las capas de neuronas agregadas en el modelo 2 y 3 antes de la fusión de datos tienen por objetivo que los modelos generen relaciones independientes en cada conjunto de datos antes de realizar relaciones conjuntas, mientras que la capa final aplicada después de la fusión tiene por objetivo estudiar los efectos combinados e interacciones que pueda existir para la clasificación del fenómeno.

Capítulo VI. Resultados

6.1 Resultados de la primera etapa del proceso KDD

6.1.1 Resultados de puntos de interés

Los resultados obtenidos en términos de predicción de cada uno de los modelos anteriores están descritos en la siguiente tabla:

Métrica	RandomForest	Logit iterativo	SVM lineal	DNN
Accuracy	0.657	0.60	0.62	0.65
Precision	0.656	0.71	0.66	0.65
Recall	0.658	0.34	0.50	0.64
F1	0.657	0.46	0.57	0.64

Tabla 13: métricas de desempeño obtenidos para el modelo de zonas aplicado a puntos de interés

Los resultados de las tablas anteriores se obtienen entrenando un conjunto de 10000 datos y 2000 datos de test, ambos balanceados perfectamente. Los datos corresponden a un subconjunto sacado del total de datos, pues se debe recordar que en realidad, se tienen caracterizados cerca de 110.000 lugares de Santiago, aunque en el total de datos hay un desbalance entre los lugares donde han ocurrido y no han robo de vehículos.

Luego, para obtener conocimiento sobre cuáles son los puntos de interés más relevantes en el fenómeno de robo de vehículos, se procede a hacer un ranking de las 25 variables más importantes en función del modelo Random Forest. Para esto se utiliza la métrica de "IncNodePurity" y también al algoritmo de Boruta.

Luego, se verifica de esas 25 variables más relevantes Forest si se encuentran o no en las 25 variables más relevantes del modelo SVM y si estas son estadísticamente significativas en el modelo logit y el signo que tienen sus coeficientes (Para ver el detalle de todas las variables revisar el Apéndice F: Detalle resultados modelo logit Puntos de interés). El resumen puede observarse en la siguiente tabla:

Variables relevantes asociadas al robo de vehículos				
Random Forest - Ranking de variables		Comparación		
Variables	Ranking	R - SVM	Logit	signo
distancia al Costanera Center	1	Si	***	-
servicios personales (D2)	2	Si	***	+
distancia a Plaza de Armas	3	Si	***	+
transantiago (D2)	4		.	-
para verse bien (D2)	5	Si	***	+
educativos (D2)	6	Si	**	+
alimentos (D2)	7			
transantiago (D1)	8			
parques y plazas (D2)	9		*	+
otros servicios (D2)	10	Si	*	-
financieros (D2)	11	Si	***	-
servicios personales (D1)	12	Si	***	+
comunicaciones (D2)	13			
internacional (D2)	14			
hospitales clinicas centros de salud (D2)	15			
deco hogar (D2)	16		**	+
compras personales (D2)	17	Si		
para el auto y moto (D2)	18		***	+
comidas rapidas (D2)	19			
construccion (D2)	20			
alimentos (D1)	21			
educativos (D1)	22	Si	***	+
otros comercios (D2)	23	Si	*	-
otros servicios (D1)	24			
financieros 01 (D2)	25			

Tabla 14: Las 25 variables más importantes en la predicción del robo de vehículos

En la tabla se muestran las variables más relevantes en el modelo de random Forest y ordenadas de la más importante a la menos importante. R-SVM indica si esa variable está dentro del top 25 en el modelo SVM, mientras que la columna Logit indica la significancia estadística obtenida por esa variable y signo muestra si el coeficiente asociado a esa variable en el modelo logit es positiva o negativa (significancia estadística: 0 `***`, 0.001 `**`, 0.01 `*`, 0.05 `.` 0.1). Los valores vacíos en R-SVM y Logit muestran que la variable no estaba presente en el top 25 y no es estadísticamente significativa en el modelo logit o fue eliminada en el proceso de Backward. Los valores D1 y D2 entre paréntesis al costado de la variable indican el radio de 0 a 0.5km y de 0.5 a 1km respectivamente, recordando que se hicieron dos áreas de estudio.

Se destaca en color verde oscuro en la Tabla 14 a aquellas variables que aparecieron en los tres modelos, es decir, que se encuentra dentro de las 25 variables más relevantes en SVM y es estadísticamente significativa en el modelo logit. Mientras el color verde claro, muestra aquellas variables está presente o en el top 25 del modelo SVM lineal o es estadísticamente significativa en el modelo logit.

Cabe destacar que fueron ejecutadas varias iteraciones, y las variaciones respecto a los resultados mostrados en la Tabla 14 presentan diferencias

mínimas. En algunas ocasiones si hubo presencia de la variable de Transantiago y a aquellas relacionadas a restaurantes en Santiago.

Otro de los hallazgos relevantes tiene que ver con que en el caso del modelo de Random Forest el 57% de las variables que resultaron como relevantes, son variables que pertenecen a los puntos de interés de la zona D2¹² y si se observan las 20 variables de mayor importancia, un 80% de estas variables pertenecen a la superficie D2. En el caso del modelo Logit, usando Backward, el 56% de las variables que quedaron corresponde a la superficie D2. En el caso del modelo SVM el 52% de las variables del top 20 pertenecen a la superficie D2.

En resumen, los modelos señalan que el entorno cercano de puntos de interés es levemente más relevante que el entorno más cercano. Otro de los hallazgos que se pueden constatar, es la significancia estadística y la relevancia de la variable asociada a la cercanía al centro de Santiago y al Costanera Center. Aunque en el primer caso se asocia a la cercanía como un factor que aumenta el riesgo, mientras que en el segundo a una disminución del riesgo.

Para tener una idea más exacta de lo que representa cada una de las categorías de interés en los modelos de *machine learning*, se realiza un procedimiento de *text mining*, que permite caracterizar cada categoría de punto de interés en función de los elementos asociados a ella.

Esto se lleva a cabo por medio de un proceso. En primer lugar, hay una etapa de vectorización de todos los puntos de interés asociados a una categoría. Por ejemplo, uno de los puntos de interés de la categoría cultura tiene como descripción "Museo de arte contemporáneo". Por lo tanto, en primer lugar, se divide este texto en una lista de palabras correspondientes a "Museo", "de", "arte", contemporáneo ", segundo se eliminan los *stopwords*, quedando "Museo", "arte", "contemporánea".

Posteriormente se tiene una lista de muchas descripciones y vectores asociados a una categoría de interés como cultura y se realiza entonces un conteo de cuáles son las palabras más repetidas en esta categoría de interés. De esta forma, el resultado obtenido para la categoría de cultura puede expresarse como un vector de frecuencia de palabras asociadas a ella, que en este caso corresponde a teatro (70), galería (69), centro (60), cultural (52), arte (52), museo (50), casa (25), espacio (20), producciones (19), Santiago (17), donde el paréntesis indica el número de apariciones de esa palabra en las descripciones de cultura.

¹² La superficie D2 corresponde a la generada de restar la superficie de una circunferencia de radio de 1 kilómetro con la superficie D1 que se calcula como el área circular con radio de 0.5 kilómetros.

Finalmente, por medio de esta metodología se puede tener conocimiento de cuáles son los elementos que pertenecen a cada una de las categorías de puntos de interés estudiadas para la predicción de robo de vehículo en Santiago. En el Apéndice F: Descripción de variables de puntos de interés hay un detalle de todas las categorías.

Las variables que aparecen en los tres modelos pueden ser caracterizadas como sigue:

- **Para verse bien:** peluquería (1247), salón (592), belleza (377), gimnasio (191), centro (175), unisex (145), estética (133), fitness (104), Pacific (89), podología (67)
- **Servicios personales:** inmobiliaria (473), propiedades (417), abogado (407), abogados (375), hogar (356), ancianos (273), lavaseco (175), funeraria (156), corredores (136), inversiones (129)
- **Financieros:** banco (2821), cajero (1540), automático (1514), supercaja (1011), santander (880), redelcom (593), banefe (557), santiago (514), multicaja (464), servipag (391)
- **Educativos:** jardín (1877), infantil (1846), escuela (838), colegio (591), especial (281), instituto (173), centro (165), universidad (164), liceo (158), lenguaje (156)
- **Oros comercios:** Inversiones (510) comercial (419) importadora (407) compañía (197) inmobiliaria (189) exportadora (162) comercializadora (134) ingeniería (116) servicios (102) gas (97)
- **Otros servicios:** centro (1036), club (647), social (530), adulto (458), mayor (457), desarrollo (425), madres (280), comité (249), cultural (247), capacitación (235)

Las variables que aparecen en otro modelo:

- **Compras personales:** farmacia (1042), farmacias (837), mall (434), cruz (410), verde (403), Ahumada (364), Salcobrand (277), plaza (248), óptica (237), ópticas (203)
- **Parques y plazas:** plaza (2935), publica (706), feria (339), libre (318), santa (124), n (108), parque (104), sur (89), jose (78), rio (75)
- **Deco hogar:** muebles (419), mall (106), comercial (97), antigüedades (87), cerrajería (76), importadora (60), telas (57), tienda (55), pinturas (53), alfombras (52)
- **Para el auto y moto:** servicio (435), estación (381), repuestos (215), Copec (212), Shell (200), automotriz (178), Petrobras (153), av. (132), comercial (123), taller (98)

El resto de puede ser definido por:

- **Comunicaciones:** diseño (220), claro (213), publicidad (190), Entel (141), mall (124), movistar (97), plaza (97), editorial (92), producciones (84), servicios (79)
- **Hospitales clínicas centros de salud:** dental (558), centro (541), clínica (497), salud (248), dr (236), servicios (196), medico (186), dr. (154), odontológica (153), consulta (152)
- **Concesionarios y automotoras:** automotora (196), mall (192), plaza (189), automotriz (47), condes (44), Vespucio (43), oeste (40), sur (40), Vitacura (36), av. (34)
- **Alimentos:** almacén (2180), botillería (905), minimarket (719), supermercado (499), panadería (355), santa (320), pastelería (308), market (241), bazar (214), don (194)
- **Cafés y cafeterías:** café (542), cafetería (250), mall (69), coffee (64), plaza (58), starbucks (45), donuts (35), central (26), providencia (26), casa (26)
- **Transantiago:** paradero (11192), Transantiago (11192), metro (8), estación (7), bip (3), ph407 (2), ph408 (2), centro (2), v (2), bio (2)
- **Internacional:** restaurant (595), restaurante (510), sushi (127), china (116), mall (70), comida (70), plaza (53), Perú (48), casa (41), fu (36)

6.1.2 Resultados de capacidad de huida

Se entrenan modelos Logit con Backward y SVM lineal, obteniendo los siguientes desempeños:

Métrica	RandomForest	Logit iterativo	SVM lineal
Accuracy	0.604	0.595	0.581
Precision	0.623	0.732	0.579
Recall	0.487	0.270	0.530
F1	0.547	0.395	0.553

Tabla 15: Resultados obtenidos en la predicción de robo de vehículos usando variables de congestión y tiempo

El conjunto de datos cuenta con 6.000 registros y se utilizan conjuntos de entrenamiento y test de 80% y 20% respectivamente. También se probaron los resultados anteriores con un conjunto de aproximado de 17.000 datos, pero no hay cambios significativos. Los resultados obtenidos del modelo logit después del algoritmo de Backward para la primera simulación de datos (Para ver más detalles revisar el Apéndice G: Detalle modelo logit de Capacidad de huida) corresponden a los de la Tabla 16:

Variables	Estimate	S.E.
(Intercept)	0.7391	***
0:00a2:00	-0.65611	***
2:00 a 4:00	-0.99693	***
4:00 a 6:00	-1.25337	***
6:00 a 8:00	15.34673	
8:00 a 10:00	16.06108	
10:00 a 12:00	16.00314	
12:00 a 14:00	-15.84012	
14:00 a 16:00	-15.9816	
18:00 a 20:00	0.71714	***
20:00 a 22:00	15.99786	
trafico medio	-16.78392	
trafico alto	14.76558	
trafico muy alto	-1.38529	***

Tabla 16: Resultados obtenidos del modelo Logit, primera simulación

Se debe recordar a que la primera simulación, hace referencia a que los horarios de no robo de vehículos fueron simulados, para poder estudiar el fenómeno de robo. Fueron eliminadas las variables de capacidad de huida del lugar, definida como la velocidad promedio de desplazamiento que hay en el lugar en el proceso de Backward. Analizando los pesos de la función de SVM estos eran los que tenían menor peso.

En una segunda simulación y ajuste de un modelo logit se obtuvieron los siguientes resultados:

Variables	Estimate	S.E.
(Intercept)	0.97	***
trafico medio	-0.50	***
trafico alto	-0.81	***
trafico muy alto	-1.34	***
2:00 a 4:00	-0.55	***
4:00 a 6:00	-0.87	***
6:00 a 8:00	-1.12	***
8:00 a 10:00	-0.79	***
10:00 a 12:00	-0.52	***
12:00 a 14:00	-0.53	***
14:00 a 16:00	-0.47	***
16:00 a 18:00	-0.76	***
18:00 a 20:00	-0.49	***
20:00 a 22:00	0.17	**
22:00 a 24:00	0.26	***

Tabla 17: Resultados obtenidos del modelo Logit, segunda simulación

En estos resultados (Para ver más detalles revisar el Apéndice G: Detalle modelo logit de Capacidad de huida) se aprecia de forma más notoria el efecto temporal asociado al robo de vehículos, especialmente la tendencia a la baja en el robo de vehículos en la madrugada y una tendencia al aumento al anochecer. Se observa también como significativo el efecto del tráfico. Por otro lado, las variables asociadas a capacidad de huida también fueron eliminadas en el proceso de Backward y por lo mismo no aparecen en los resultados anteriores.

6.1.3 Resultados de imágenes

Se presenta a continuación la evolución de cada uno de los modelos utilizados al finalizar el *epoch* 30:

Metrica	Random	BGM3	BGM5	BGM6	RESNET	DENSENET	BGM4
Accuracy	0.500	0.567	0.559	0.554	0.577	0.592	0.598
Precision	0.500	0.570	0.590	0.570	0.580	0.600	0.600
Recall	0.500	0.570	0.560	0.550	0.580	0.590	0.600
F1	0.500	0.570	0.520	0.530	0.570	0.580	0.590

Tabla 18: Resumen de resultados

El entrenamiento de cada uno de estos modelos consta de 30 epoch y la cantidad total de datos de entrenamiento es de 40.000 imágenes y 8.000 de test, donde las clases tienen la misma proporción (50% y 50%). Los modelos alcanzan los mejores desempeños entre los epoch 15 y 20, después las redes tienden a sobre ajustarse levemente.

Otra de las combinaciones que se probaron buscando mejores resultados en la predicción, fue utilizar conjuntos más grandes de imágenes, sin embargo, esto produce que los datos queden desbalanceados. Entrenar un clasificador con las clases desbalanceadas produjo un clasificador trivial que solo se fijaba en la clase de no robo, correspondiente a la clase más grande.

Para solucionar el problema de desbalance, se hizo un aumento de datos, por medio de aplicación de diferentes filtros que se explican en la sección anterior agregando nuevas imágenes de robo aplicando filtros y aleatorizando las imágenes de lugares de no robo. Se aplican filtros sobre las imágenes de no robo para evitar que la red aprenda a clasificar una imagen de robo como aquella que tiene algún filtro aplicado. Sin embargo, los resultados no fueron mejores que los que se presentan en la Tabla 18 con las clases balanceadas.

Modelo	Precision	Recall	F1
BGM3_4ep	0.23	0.2	0.21
BGM3_5ep	0.26	0.03	0.05
BGM6_4ep	0.2	0.05	0.08
BGM4_15ep	0.21	0.03	0.05

Tabla 19: Resultados de modelos con data aumentada

Otra de las alternativas que se probó en el entrenamiento es el uso de redes pre entrenadas con ImageNet, sin embargo, los resultados obtenidos en la clasificación no mejoran respecto al uso de redes inicializadas con sus parámetros aleatorios.

La evolución del entrenamiento puede resumirse en los siguientes gráficos:




Ilustración 36: Accuracy en en cada epoch de entrenamiento para modelos con clases balanceadas

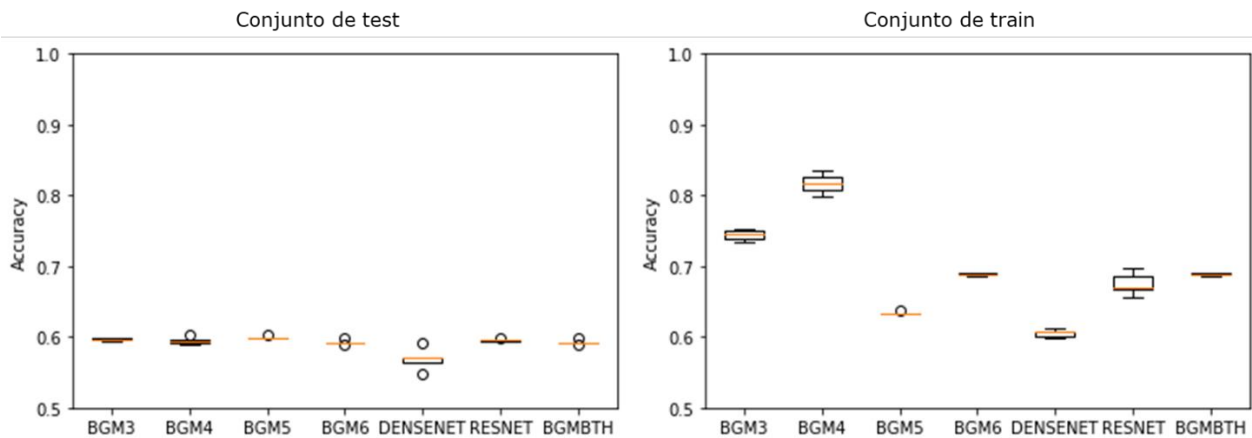


Ilustración 37: Mejores 5 accuracy en proceso de entrenamiento para modelos con clases balanceadas

Cabe destacar que los modelos BGM a diferencia de los de la literatura, son menos profundos y por lo tanto, en términos del costo computacional el entrenamiento es más rápido. Esto se debe a que al ser menos profundos se puede incrementar en *batch size* de entrenamiento lo que permite paralelizar más el entrenamiento del modelo, sin embargo, los resultados obtenidos no tienen grandes diferencias.

Los resultados del modelo utilizando imágenes panorámicas no tiene una mejora considerable respecto al modelo anterior, en ambos casos los mejores desempeños rondan un *accuracy* del 60%.

Los resultados obtenidos muestran un mejor desempeño del modelo de zonas por sobre el modelo de lugares (*Accuracy* del 67.5% versus 60% aproximadamente), para eso se hace una comparación en el entrenamiento de ambos modelos para la arquitectura de BGM4. Adicionalmente es claro que el desempeño del modelo de zonas es mejor que el resto de las arquitecturas (En Apéndice H: Entrenamiento con imágenes se puede apreciar que ningún *accuracy* es mejor al 60%). Se puede observar en el siguiente gráfico:




Ilustración 38: Comparación del modelo de lugares y zonas

6.2 Resultados de la segunda etapa del proceso KDD

Los resultados obtenidos en cada modelo de la segunda etapa de KDD se presentan en la siguiente tabla:

	Random	Modelo 1	Modelo 2	Modelo 3
Precision	0.500	0.600	0.590	0.690
Recall	0.500	0.640	0.720	0.610
F1-score	0.500	0.620	0.650	0.640
Accuracy	0.500	0.605	0.610	0.664

Ilustración 39: Resultados modelo de fusión de datos evaluados en el conjunto de test

Al entrenar los modelos, las clases de lugar de robo y no robo se encontraban balanceadas en 50% para robo y 50% para no robo. El cálculo del *precisión*, *recall* y *F1* corresponden a la clase de robo. Los mejores resultados en términos del *accuracy* fueron los del modelo 3, los que a su vez son levemente mejores que las predicciones obtenidas por el modelo de puntos de interés de forma independiente.

Capítulo VII. Discusión y trabajos futuros

7.1 Discusión sobre caracterización geográfica y puntos de interés

Se observa que las variables asociadas a la distancia al centro de la ciudad (Plaza de armas) y también a uno de los grandes centros comerciales como es el costanera center, son variables estadísticamente significativas (Con p-valores menores a $2e-16$ en modelo logit). Las que además resultan ser variables relevantes en la predicción tanto para el modelo de Random Forest como SVM.

El modelo logit señala que al alejarse del centro de Santiago (Plaza de armas) aumenta la probabilidad de robo, esto debido a que el coeficiente es positivo. Posibles explicaciones a lo anterior pueden ser una mayor concentración de automóviles en la lejanías de la plaza de armas y por una mayor cantidad de estacionamientos a medida que aumenta la distancia al centro, esto se apoya en que el centro de Santiago tiene menos estacionamientos que las inmediaciones.

No ocurre lo mismo con la distancia al Costanera Center, donde el coeficiente tiene signo negativo. El efecto de acercarse al Costanera Center aumenta la probabilidad de robo. Esto puede explicarse por una mayor presencia de vehículos estacionados en el sector, mayor actividad económica en este sector y mayor presencia de espacios para estacionarse.

Varios puntos de interés son señalados como variables estadísticamente significativas en el robo de vehículos, especialmente se destacan los puntos de interés relacionados a instituciones u organizaciones de educación (p-valor menor a 10^{-3} en *academias y cursos y educativos* y 0.007 variable *educativos* en los tramos D1 y D2 respectivamente), diferentes servicios de belleza (p-valor menor a 10^{-3} variable para verse bien), locales de comida (p-valor menor a 0.043 en la variable de comida chilena, 0.022 en la variable de cafeterías y picadas, 0.002 en la variable de helados). Algunas otras variables aparecieron como relevantes en otras iteraciones, seleccionando otros conjuntos aleatorios para entrenamiento y test. Se destaca el caso de las variables de *hospitales, clínicas y centros de salud, otros comercios, alimentos y Reciclaje y chatarra*, las últimas dos categorías que contienen los supermercados.

Los puntos de interés anteriores respecto al modelo logit tienen un efecto que aumenta la probabilidad de robo. Una explicación posible a lo anterior es que en estos lugares suele haber concentración de vehículos, tanto por el servicio que brindan o también por eventos extraordinarios (reuniones de apoderados, actividades, entre otras) lo que aumenta en el número de vehículos. Esto se debe a que la gente suele ir a aquellos lugares en vehículo, aumentando la cantidad de autos estacionados y eso podría atraer una mayor cantidad de ladrones de vehículos.

Lo anterior, permite validar la hipótesis de que hay puntos de interés que tienen mayor importancia para predecir el robo de vehículos, esto debido a que solo algunas de las variables son estadísticamente significativas y los valores de los coeficientes entre uno y otro punto de interés son diferentes, por lo tanto su influencia es variable. Además, es posible predecir parte de los robos usando estas variables.

Otra de las explicaciones puede ser que en estos lugares existe una vulnerabilidad mayor, porque los estacionamientos son de acceso libre a la gente, aumenta la presencia de vehículos en la vía pública o en estacionamientos públicos. En contraste con lo que ocurre en los sectores más residenciales, los vehículos se estacionan en casas o cercanos a sus dueños, donde las condiciones de seguridad son mayores, la sanción por irrumpir en la morada es mayor en el caso de vehículos estacionados al interior de las casas. Por lo mismo, la extracción del vehículo podría tener mayores complicaciones. Lo que podría explicar también por qué hay mayor presencia de robos en lugares con mayor actividad.

Hay otros puntos de interés, que el modelo logit indica un efecto de disminución en la probabilidad de robo, como es el caso de los servicios financieros (p-valor menor a 10^{-3}) variable que se compone de bancos, Servipag, multi caja y otros. Algunas posibles explicaciones a este fenómeno, puede ser que en Santiago, estos puntos de interés social quedan en lugares donde existe mayor flujo de gente. Son lugares donde hay mayor nivel de seguridad o porque en general la ubicación de lugares asociados a servicios financieros tiene un menor acceso a estacionamiento vehicular.

La variable de Transantiago en otras iteraciones si fue estadísticamente significativa, de haber una posible explicación a este fenómeno, puede ser la mayor presencia de personas en los paraderos y a su vez una menor cantidad de autos estacionados cerca de los mismos.

Finalmente, se puede concluir que es posible predecir parte de los robos de vehículos por medio de la caracterización de lugares en Santiago con sus puntos de interés social distancia al centro de la ciudad y al Costanera Center por su desempeño cercano al 66%.

7.2 Discusión sobre variables temporales y de huida

En primer lugar, se observa que las variables temporales son relevantes para caracterizar el fenómeno de robo de vehículos, especialmente en la segunda simulación, en la cual, si se comparan los resultados de los coeficientes con el *Base Line*, el efecto del tráfico disminuye la probabilidad de robo, esto implica que, a medida que incrementa el tráfico disminuye la probabilidad de robo del vehículo.

Una de las posibles explicaciones del punto anterior es que hay una disminución de vehículos que antes estaban estacionados, dado que ahora están en movimiento, lo anterior tiene como efecto reducir la cantidad de autos disponibles para robar. Otra posibilidad es que en las horas de mayor congestión, también hay mayor flujo de personas, lo que podría eventualmente influir en la decisión de robo.

Otro hallazgo es que al anochecer hay una tendencia un poco mayor al robo que en horas de madrugada, según la segunda simulación de datos donde los coeficientes del base line (Variable de intervalo 00:00 y 2:00) tienen valores positivos en los horarios comprendidos entre las 20:00 a las 24:00 (Con coeficientes de 0.17 y 0.26 en orden) y valores negativos en los intervalos que comprenden los horarios entre 2:00 a las 8:00 de la mañana (Con coeficientes de -0.55, -0.87, -1.12 en orden) En este caso todas las variables son estadísticamente significativas con p-valores menores a 10^{-3} . Esto podría ser explicado por dos situaciones: (1) en horas de madrugada hay menos autos en la vía pública, estos a su vez están resguardados en lugares más seguros que en otros momentos del día, pues en Santiago la gente suele dejar los vehículos dentro de sus hogares, lo que podría significar una mayor dificultad para robar. (2) Podría ocurrir que los ladrones de vehículos prefieran realizar este tipo de delitos en otros horarios. Sin duda, también es una posibilidad que (2) sea una consecuencia de (1) o que ambos fenómenos influyen simultáneamente.

Respecto a la variable de capacidad de huida, definida como la velocidad promedio de un lugar, los resultados muestran que no es estadísticamente significativa por el modelo logit (Con p-valores de 0.263 y 0.218 eliminadas en el proceso de *Backward*). Tiene también pesos muy pequeños en el modelo SVM. Por lo tanto, la variable utilizada para caracterizar la capacidad de huida, definida como la velocidad promedio de desplazamiento de un lugar no es significativa en la decisión de robo como se había planteado inicialmente en las hipótesis.

Lo que pareciera ser concluyente, es que, sí existe un efecto horario en el robo y que el efecto del tráfico en el robo pareciera afectar más por la cantidad de vehículos disponibles para el robo que un efecto asociado a la dificultad de huir de un lugar. Finalmente, la caracterización del robo por ventanas de tiempo y tráfico si permite predecir en parte cuando ocurre un robo, por su desempeño cercano al 60%.

7.3 Discusión sobre predicción usando imágenes

Es posible demostrar que las imágenes permiten predecir parte del fenómeno de robo de vehículos (*Accuracy: 59.8%, precision: 60%, recall: 60%* y *F1: 59%* o ver *Tabla 18* para más detalle). Uno de los hallazgos encontrados, es que al menos en este caso de clasificación binaria (lugar de robo y no robo)

no existen grandes diferencias en el desempeño usando diferentes redes CNN (Ver Ilustración 36 y *Tabla 18*) adicionalmente las redes BGM que son menos profundas tienen algunas ventajas en el tiempo de entrenamiento, pues permiten realizar entrenamiento con tamaños de *batch* mayores.

Se mencionó en la sección de predicción basada en imágenes (5.4.7.4) que, al aumentar los datos, se balancearon las clases de robo y no robo por medio de la generación de imágenes con diferentes variaciones de color, saturación y otros. Pero, contrario a la recomendación vista en [Z5] los resultados de predicción no mejoraron. Una de las razones que pueden explicar esto es que, aunque los datos hayan sido aumentados, para poder balancear las clases se generan muchas imágenes con la misma imagen, por lo tanto, aunque existan variaciones, las redes se sobre ajustan y que para este tipo de problema, el aumento de datos por medio de la variación de las imágenes no aporta mayor nivel de aprendizaje a las redes.

Es posible demostrar a partir del modelo de zonas, versus el modelo de lugares que la capacidad predictiva cambia en función del tamaño de celda utilizado en el conteo de robos en un área. Algunas explicaciones al mejor desempeño del modelo de zonas pueden ser que entrenar una red para clasificar lugares de robo es más complejo que zonas, otra explicación tiene que ver que la disposición geográfica de las zonas de riesgo se encuentra mayoritariamente concentrada en zonas de alta concentración comercial (Ver Ilustración 20), zonas que a su vez, tienen una infraestructura diferente a aquellos lugares más residenciales, lo que favorece el aprendizaje del clasificador.

Respecto al modelo basado en imágenes panorámicas, los resultados obtenidos no son diferentes al modelo que utiliza imágenes por separado. Posibles explicaciones a este fenómeno tienen que ver con que el aporte de información que se tiene al entrenar la red con imágenes panorámicas no aporta una gran cantidad de información adicional, lo que puede verse reflejado en que el desempeño de los modelos sea similar al de los modelos con imágenes por separado. Otra posible explicación, es que la red empleada no es capaz de captar los efectos combinados de usar imágenes panorámicas.

7.4 Discusión sobre modelo de fusión de datos

En el caso del modelo de fusión de datos, aunque pareciera haber una mejora al usar los conjuntos de datos integrados, la mejora no es notoria y podría no ser estadísticamente significativa. Alguna de las razones que pueden explicar esto es que, al entrenar la red, el modelo no es capaz de establecer relaciones significativas entre los conjuntos de datos, por lo tanto, el nivel de predicción no aumenta como se esperaba.

Efectivamente los resultados demuestran que es posible clasificar con un desempeño regular el robo de vehículos asegurados en Santiago, esto a través

de la caracterización de un lugar de robo usando imágenes y puntos de interés, tanto por sí solo como en conjunto, pues los resultados indican un desempeño del 66% versus un 50% en un caso aleatorio de clasificación.

Por lo tanto, se valida parte de la hipótesis de que las técnicas de *machine learning* y *deep learning* sirven para abordar el problema del robo de vehículos. Algunas explicaciones que justifican por qué los resultados no sean excelentes son las diferentes modalidades de robo, la omisión de variables y datos que aportan un menor nivel de información de un lugar. Se procede explicar las razones de cada posible justificación en los siguientes párrafos.

El robo de vehículos tiene diferentes modalidades, como “portonazos”, robo de vehículos en movimiento, robos de vehículos estacionados y otros. Lo relevante de cada modalidad es que tienen patrones de comportamiento diferentes. Por ejemplo, los dos primeros mencionados tienen comportamientos más aleatorios que el resto de los robos, según carabineros de Chile, existen bandas que para este tipo de vehículos los delincuentes tienen a buscar determinados modelos en las calles mientras van conduciendo y una vez que dan con el modelo buscado lo persiguen hasta realizar el atraco. Considerando el punto anterior, es posible que en las fuentes de dato utilizadas no sean las más adecuadas para caracterizar el delito, lo que sin duda disminuye la performance de los modelos propuestos.

Algo similar ocurre con los vehículos de lujo o deportivos, pues carabineros indica que, en este caso, estos vehículos al estar concentrados mayormente en el sector oriente de la ciudad, provoca que los delincuentes se desplacen hasta sectores donde hay una mayor presencia de este tipo de vehículos. Lo anterior permite indicar que en este caso la información de puntos de interés es menos significativa.

La violencia en el robo, muestra que el robo de vehículos puede tener patrones diferentes, por lo tanto, no sería extraño pensar que las variables que afectan a cada tipo de robo pueden llegar a ser diferentes, lo que impacta en el desempeño de las predicciones. Incluso, pudiese ocurrir que hay tipos de robo donde el contexto puede ser menos relevante.

Existen variables que no se abordaron en este estudio que podrían otorgar un mejor nivel de predicción al modelo como es el caso de la información asociadas al vehículo, como el valor, la marca, el tipo de vehículo y otras. Las anteriores son variables que no son de contexto, las cuales sin duda afectan la decisión de robo, esto porque hay evidencia en la literatura que podría justificarlo y además porque carabineros también menciona que hay preferencias, por ejemplo, en el caso de vehículos de trabajo

Los datos que aportan un menor nivel de información hacen referencia a imágenes sobre las cuales no es posible deducir mucha información de contexto, especialmente en casos de imágenes de pasajes muy pequeños donde no se ve más que murallas, árboles o vegetación.

7.5 Limitaciones actuales y Propuestas de continuidad de trabajo

Existe evidencia que el tamaño y resolución de la imagen [G2] influyen en el desempeño de la predicción. Esto, se debe a que la información que aporta una imagen más grande y de mejor calidad es mayor, sin embargo, el tamaño de la imagen afecta directamente al tiempo de entrenamiento de las redes CNNs.

Las imágenes utilizadas en la memoria tienen un tamaño original de 640x640 píxeles en color, pero para el entrenamiento de los modelos se redimensionaron a 224x224, por lo tanto, es probable que exista una brecha de mejora en los resultados.

En la memoria se define la capacidad de huída de un lugar como la velocidad promedio que tiene un vehículo en recorrer una distancia entre el punto de robo y un punto de destino aleatorio. Esto, se debe a que no se cuenta con la velocidad de un punto de Santiago, por lo tanto, calcular el promedio en un tramo pequeño entrega una noción del tráfico de la zona.

Para determinar el punto de destino, se utiliza un punto cercano al punto de robo, considerando cercando una distancia entre 2 y 3 kilómetros. Sin embargo, cómo se desconoce el punto de destino real, tener información sobre como es el tráfico desplazándose al norte, sur, este y oeste permitiría tener mayor detalle sobre la huída de un lugar.

Lo anterior está motivado en que la literatura señala que existe una relación entre los lugares donde se roba y donde viven los delincuentes, donde la probabilidad de que un delincuente seleccione un lugar de robo es inversamente proporcional a la distancia que él o ella debe viajar para alcanzarlo (Snook, 2004; Wiles and Costello, 2000). Adicionalmente, carabineros señala que los vehículos que son encontrados en Santiago, también tienden a concentrarse en algunas comunas de Santiago, por lo tanto, el tráfico y lo que al delincuente le toma desplazarse, considerando un panorama más global de información eventualmente podría dar mejores resultados.

Es importante destacar que la forma de perpetrar un robo de vehículo, al tener una conducta diferente, puede generar formas diferentes de intervenir un lugar o generar un mecanismo de prevención, por lo que la segmentación puede ser a su vez visto como una forma de utilizar recursos o generar estrategias que combatan la delincuencia más eficientemente.

La forma de poder segmentar y abordar el problema de las distintas modalidades de robo (con o sin violencia, u otro) es aplicar técnicas de *machine learning* y minería de texto sobre los relatos de los afectados en la base de datos de la aseguradora, esto debe a que por medio de esta información se puede identificar el tipo de siniestro. De esta manera, se pueden etiquetar los registros en función de las categorías delictuales y entrenar los modelos propuestos en esta memoria para ver cuáles son los lugares más o menos riesgosos de robo según la forma de llevar a cabo el siniestros, donde se esperaría ver una mejora en los resultados de predicción.

Una de las limitaciones existentes es que de desarrollar estrategias de prevención basados en los aprendizajes de esta memoria, podría provocar que los delincuentes cambian su *modus operandi*, siendo necesario desarrollar nuevos modelos o re entrenar los modelos actuales para identificar los nuevos patrones de robo.

Otros datos, pueden contribuir a mejorar los resultados. Por ejemplo, el instituto nacional de estadística de Chile (INE) que cuenta con información sobre ingresos y gastos, información económica, social, demográfica y de censos, que pueden ser utilizados para caracterizar en otras dimensiones un lugar, pues la literatura señala también que hay factores sociales que pueden influir en la delincuencia, lo que contribuiría a mejorar los desempeños y estudiar cuales de la magnitud y la incidencia de algunas variables en el robo de vehículos.

7.6 Otras áreas de investigación y posibles aplicaciones

Este trabajo ha desarrollado herramientas y una metodología que facilita la caracterización de un lugar a través de información del ambiente, como puntos de interés, imágenes *in situ* e información sobre el desplazamiento de un lugar.

La metodología de esta memoria puede ser utilizada para estudiar otro tipo de delitos como el narcotráfico, robos a casas, robos con violencia, asaltos u otro tipo de delitos y también otorga la posibilidad para estudiar fenómenos como accidentes vehiculares o peatonales, contaminación, venta ilícita, entre otro tipo de situaciones, estudiando la relevancia del contexto en la ocurrencia de estos fenómenos. Esta propuesta de uso está apoyada por la literatura, donde se explica que los delitos se manifiestan en función de un contexto demográfico, económico, social, cultural, espacial y temporal en el cual ocurren (Capítulos 4.1.1 y 4.1.2).

Por otro lado, la metodología de esta memoria puede ser extendida y utilizada para abordar problemas relacionados a la toma de decisiones en el comercio o la industria del *retail*. Lo anterior se da a través del mercado inmobiliario

donde se hace énfasis en la venta al ambiente que rodea la vivienda, es decir, si hay colegios cerca, centros comerciales, centros de salud, parques o plazas. Si bien, en el mercado inmobiliario existe conciencia de que estos factores afectan la decisión de compra, se desconoce el impacto que tiene cada uno de estos elementos en la decisión de los compradores, lo que podría ser tema de estudio. Conocer el atractivo de un lugar y el impacto que tiene este en la venta, permite elaborar una mejor estrategia comercial y de venta.

Otro ejemplo, es el atractivo o potencial económico que tiene un lugar en función de la actividad económica en la inmediaciones, es decir, cuanto afecta para un local la existencia de oficinas, edificios, restaurantes, pubs, bancos, una estación de metro u otro tipo de puntos de interés. Tener conocimiento de lo anterior podría aportar en la evaluación de compra e instalación de ciertos servicios o comercios y las estimaciones de venta futura.

En ambos casos, por medio de la metodología utilizada y los archivos entregables hay ahora una forma que permite abordar estos temas, complementando la caracterización única de un fenómeno por las variables del cliente o las personas, aportando variables ambientales o externas que puedan influir.

El trabajo realizado, genera nuevas oportunidades para desarrollar herramientas tecnológicas en la prevención del robo como la utilización de aplicaciones en teléfonos móviles que indiquen al conductor del vehículo sobre el riesgo de robo que tiene un lugar o también, incorporar este servicio como una aplicación que venga instalada en los vehículos que cuenten con algún sistema de navegación por GPS. Esto es factible, en parte porque los vehículos actualmente están incorporando sistemas operativos como Android.

En ambos casos, basta con desarrollar una aplicación que incorpore modelos de probabilidad de robo de vehículos ya entrenados e incorporarlos al sistema de navegación de los vehículos, así los conductores podrán tener información de los siniestros y el riesgo. La propuesta anterior, puede ser de interés para actores del mundo privado o públicos, con el fin de evitar, prevenir y proteger a las personas de los siniestros.

Otra de las aplicaciones posibles y oportunidades que genera este trabajo es permitir a las aseguradoras entender mejor el fenómeno de robo de vehículos. El riesgo de siniestro de un vehículo, no depende únicamente de variables asociadas al vehículo y el conductor. También, es relevante las zonas donde el vehículo se desplaza, se estaciona y sus horarios de uso. Estas variables pueden ser agregadas a los modelos de riesgo de las aseguradoras, pues se demuestra en este trabajo que afectan el puntaje de riesgo de siniestros, lo

que permitiría mejorar el desempeño de los modelos de riesgo y una mejor segmentaciones de los niveles de riesgo de los clientes, otorgando la posibilidad de generar precios diferenciados.

Además, se puede mejorar la estrategia de prevención de siniestros, otorgando incentivos y recomendaciones a los clientes para que tomen mayores precauciones cuando estén en puntos riesgosos de Santiago.

Desde una perspectiva pública, este trabajo permite determinar cuáles son los lugares más riesgosos. Esto, otorga la posibilidad de generar un ranking de los lugares más riesgosos de Santiago y otorga la posibilidad de dirigir inversiones en seguridad de forma más efectiva. Algunas de las posibilidades son aumentar la vigilancia de un lugar, aumentando la flota de seguridad, rediseñar las rutas de los vehículos de seguridad de vehículos de seguridad de las municipalidades o carabineros, instalación de cámaras de seguridad, entre otros.

También permite hacer recomendaciones en los entornos sobre el riesgo de la zona, informando a las personas que estacionan o se movilizan por sectores más riesgosos, implementando campañas de comunicación que aumenten el nivel de conciencia de los factores y riesgos de un lugar, de tal forma, que los conductores tomen más resguardos y medidas de seguridad para evitar siniestros.

Capítulo VIII. Conclusiones

Esta memoria ha permitido conocer de forma más profunda y exacta cuáles son los efectos ambientales que pueden condicionar el robo de vehículos en Santiago. Este conocimiento puede ser entregado de diversas formas para contribuir a mejorar la seguridad y la prevención del robo de vehículos.

En primer lugar, ahora existe conocimiento sobre cuáles son los puntos de interés que tienen una alta correlación con el robo de vehículos. A partir de los modelos implementados para los datos de puntos de interés, se puede recomendar a los conductores que tomen medidas adicionales de seguridad cuando estacionen cerca de instituciones educativas, centros de belleza, gimnasios, inmobiliarias, centros o clubes sociales, plazas y parques, grandes centros comerciales y supermercados, ya que estos lugares tienen mayor propensión al robo.

Los modelos de puntos de interés revelan también que los conductores deben tener precaución cuando estacionan en lugares cercanos al costanera center o el centro económico de Providencia, especialmente en aquellos lugares donde hay estacionamientos en la vía pública o donde hay una gran cantidad de vehículos. Efecto similar en las lejanías del centro de Santiago, donde los modelos indican que aumenta la probabilidad de robo.

Existe un efecto temporal, por lo que de preferencia los conductores deben tener cuidado cuando se estacionan en horarios de menor congestión y al anochecer, especialmente entre las 19:00 y las 24:00 horas.

Llevar a cabo estas recomendaciones es una tarea de la cual deben encargarse los actores que están especialmente ligados a combatir el robo de vehículos y adicionalmente aquellas que sufren impactos, pudiendo ser desde organismos del estado u organismos privados como las aseguradoras.

Otra de las posibilidades que se plantean tienen relación directa con cómo se realizan los patrullajes en Santiago tanto para las municipalidades como carabineros. Conocer el ambiente, los horarios, los factores del tráfico, permite también diseñar a futuro rutas de patrullaje más efectivas con el fin de disminuir este tipo de delitos.

Capítulo IX. Bibliografía

[A1] (2016) Observatorio Digital de Delincuencia en Chile: Un sistema inteligente de apoyo a la industria automotriz chilena, en el robo de vehículos y accesorios. Programa IDeA, III concurso IDeA en dos etapas 2016.

[A2] Jaris Mujica, Nicolás Zevallos, Noam López y Bertha Prado. (2015). El impacto del robo y el hurto en la economía doméstica: un estudio exploratorio sobre los datos de Lima Metropolitana. *Debates en Sociología*, 40, 127-147.

[A3] Carbonell M, Carmen Gloria, & Carvajal A, César. (2004). El trastorno por estrés postraumático: una consecuencia de los asaltos. *Revista médica de Chile*, 132(7), 832-838.

[A4]. Breslau N, Davis G, Andreski P, Peterson E. (1991) Traumatic events and posttraumatic stress disorder in an urban population of young adults. *Arch Gen Psychiatry*, 48, 216-22.

[A5] The FBI Uniform Crime Report 2014. Sitio web:
<https://www.fbi.gov/about-us/cjis/ucr/crime-in-the-u.s/2014/crime-in-the-u.s.-2014/offenses-known-to-law-enforcement/motor-vehicle-theft>
(Consultado el 20 de abril de 2018).

[A6] Nelson, A. L., Bromley, R. D., & Thomas, C. J. (2001). Identifying micro-spatial and temporal patterns of violent crime and disorder in the British city centre. *Applied Geography*, 21(3), 249-274.

[A7] Yan, Y. Y. (2000). Weather and homicide in Hong Kong. *Perceptual and Motor Skills*, 90(2), 451-452.

[A8] Wilson, J. Q., & Kelling, G. L. (1982). Broken windows. *Atlantic monthly*, 249(3), 29-38.

[A9] Cusimano, M., Marshall, S., Rinner, C., Jiang, D., & Chipman, M. (2010). Patterns of urban violent injury: a spatio-temporal analysis. *PLoS One*, 5(1), e8669.

[A10] Bernasco, W., & Nieuwbeerta, P. (2004). How do residential burglars select target areas? A new approach to the analysis of criminal location choice. *British Journal of Criminology*, 45(3), 296-315.

[A11] Townsley, M., Birks, D., Ruiter, S., Bernasco, W., & White, G. (2016). Target selection models with preference variation between offenders. *Journal of quantitative criminology*, 32(2), 283-304.

[A12] Bernasco, W., & Kooistra, T. (2010). Effects of residential history on commercial robbers' crime location choices. *European Journal of Criminology*, 7(4), 251-265.

[A13] Frith, M. J., Johnson, S. D., & Fry, H. M. (2017). ROLE OF THE STREET NETWORK IN BURGLARS'SPATIAL DECISION-MAKING. *Criminology*, 55(2), 344-376.

[A14] Bennett, T., & Wright, R. (1984). *Burglars on burglary: Prevention and the offender*. Aldershot: Gower.

[A15] Hochstetler, A. (2001). Opportunities and decisions: Interactional dynamics in robbery and burglary groups. *Criminology*, 39(3), 737-764.

[B1] van Gelder, J. L., Nee, C., Otte, M., Demetriou, A., van Sintemaartensdijk, I., & van Prooijen, J. W. (2017). Virtual burglary: Exploring the potential of virtual reality to study burglary in action. *Journal of Research in Crime and Delinquency*, 54(1), 29-62.

[B2] Vandeviver, C. (2014). Applying google maps and google street view in criminological research. *Crime Science*, 3(1), 13.

[B3] Less, E. L., McKee, P., Toomey, T., Nelson, T., Erickson, D., Xiong, S., & Jones-Webb, R. (2015). Matching study areas using Google Street View: A new application for an emerging technology. *Evaluation and program planning*, 53, 72-79.

[B4] Khosla, A., An An, B., Lim, J. J., & Torralba, A. (2014). Looking beyond the visible scene. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 3710-3717).

[B5] Hershey, D., & Wulfe, B. *Recognizing Cities from Street View Images*. Stanford University, 2016.

Sitio Web: http://cs231n.stanford.edu/reports/2016/pdfs/422_Report.pdf

[ERV1] Walsh, J. A., & Taylor, R. B. (2007). Community structural predictors of spatially aggregated motorvehicle theft rates: Do they replicate? *Journal of Criminal Justice*, 35(3), 297-311

[ERV2] Levy, M. P., & Tartaro, C. (2009). Repeat Victimization: A Study of Auto Theft in Atlantic City Using the WALLS Variables to Measure Environmental Indicators. *Criminal Justice Policy Review*, 21(3), 1-23.

- [ERV3] Roberts, A. (2012). Motor Vehicle Recovery: A Multilevel Event History Analysis of NIBRS Data. *Journal of Research in Crime and Delinquency*, 49(3), 444-467.
- [ERV4] Zulkifli, M., Ismail, N., & Razali, A. M. (2013). Analysis of vehicle theft: A case study in Malaysia using functional forms of negative binomial regression models. *Appl. Math*, 7(2L), 389-395.
- [ERV5] Suresh, G., & Tewksbury, R. (2012). Locations of Motor Vehicle Theft and Recovery. *Am J Crim Just*, 38, 200-215.
- [F1] Krizhevsky, A., & Hinton, G. (2010). Convolutional deep belief networks on cifar-10. Unpublished manuscript, 40, 7. Sitio web: <https://www.cs.toronto.edu/~kriz/conv-cifar10-aug2010.pdf>
- [F2] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- [F3] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. In: Advances in neural information processing systems (pp. 91-99).
- [F4] Tang, Y. (2013). Deep learning using linear support vector machines.
- [F5] Roh, M. C., & Lee, J. Y. (2017, May). Refining faster-RCNN for accurate object detection. In: Machine Vision Applications (MVA), 2017 Fifteenth IAPR International Conference on (pp. 514-517). IEEE.
- [F6] Sakla, W., Konjevod, G., & Mundhenk, T. N. (2017, March). Deep Multi-modal Vehicle Detection in Aerial ISR Imagery. In: Applications of Computer Vision (WACV), 2017 IEEE Winter Conference on (pp. 916-923). IEEE.
- [F7] Azadi, S., Feng, J., & Darrell, T. (2017, July). Learning detection with diverse proposals. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 7369-7377). IEEE.
- [F8] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In: Advances in neural information processing systems (pp. 1097-1105).
- [F9] Canziani, A., Paszke, A., & Culurciello, E. (2016). An analysis of deep neural network models for practical applications.

- [F10] Información sobre el conjunto de datos de ImageNet. Sitio Web: <http://image-net.org/about-stats> (Consultado el 20 de abril de 2018)
- [F11] Zhou, B., Lapedriza, A., Xiao, J., Torralba, A., & Oliva, A. (2014). Learning deep features for scene recognition using places database. In: *Advances in neural information processing systems* (pp. 487-495).
- [F12] A. Krizhevsky. Learning multiple layers of features from tiny images. Master's thesis, Department of Computer Science, University of Toronto, 2009. Sitio Web: <https://www.cs.toronto.edu/~kriz/learning-features-2009-TR.pdf>
- [F13] Lin, M., Chen, Q., & Yan, S. (2013). Network in network.
- [F14] Bursac, Z., Gauss, C. H., Williams, D. K., & Hosmer, D. W. (2008). Purposeful selection of variables in logistic regression. *Source code for biology and medicine*, 3(1), 17.
- [F15] Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- [F16] Louppe, Gilles, et al. Understanding variable importances in forests of randomized trees. *Advances in neural information processing systems*. 2013.
- [F17] Archer, K. J., & Kimes, R. V. (2008). Empirical characterization of random forest variable importance measures. *Computational Statistics & Data Analysis*, 52(4), 2249-2260.
- [F18] Kursu, M. B., & Rudnicki, W. R. (2010). Feature selection with the Boruta package. *J Stat Softw*, 36(11), 1-13.
- [F19] Huang, G., Liu, Z., Weinberger, K. Q., & van der Maaten, L. (2017, July). Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition* (Vol. 1, No. 2, p. 3).
- [F20] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In: *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- [F20+] Stutz, D. (2014). Understanding convolutional neural networks. In: *Seminar Report, Fakultät für Mathematik, Informatik und Naturwissenschaften Lehr-und Forschungsgebiet Informatik VIII Computer Vision*.
- [F21] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks

from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958.

[G1*] Kang, H. W., & Kang, H. B. (2017). Prediction of crime occurrence from multi-modal data using deep learning. *PloS one*, 12(4), e0176244.

[G1] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition.

[G2] Zheng, L., Zhao, Y., Wang, S., Wang, J., & Tian, Q. (2016). Good practice in CNN feature transfer.

[Z1] Coruse: Convolutional Neural Networks for Visual Recognition, Stanford University. Sitio Web: <http://cs231n.github.io/classification/> (Consultado 10 Marzo 2018)

[Z2] Di Lu, Yaru Zhang, Nealan Vettivelu 311201105. (2017). A Comparison of Classifiers on the CIFAR-10 Dataset. 05 Septiembre 2018, de Nealan's Webpage Sitio web: <http://nealan.vettivelu.com/wp-content/uploads/2017/07/Report-1.pdf>

[Z4] Conjunto de datos de Cifar-10 y Cifar-100, Toronto University. Sitio Web: <https://www.cs.toronto.edu/~kriz/cifar.html> (Consultado 09 Septiembre 2018)

[Z5] Buduma, N., & Locascio, N. (2017). *Fundamentals of deep learning: Designing next-generation machine intelligence algorithms*. " O'Reilly Media, Inc."

[Z6] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2016). Grad-cam: Visual explanations from deep networks via gradient-based localization. v3, 7(8).

[Z7] Wiles, Paul, and Andrew Costello. 2000. Road to Nowhere: The Evidence for Travelling Criminals. *Home Office Research Study No. 207*. London, U.K.: Home Office.

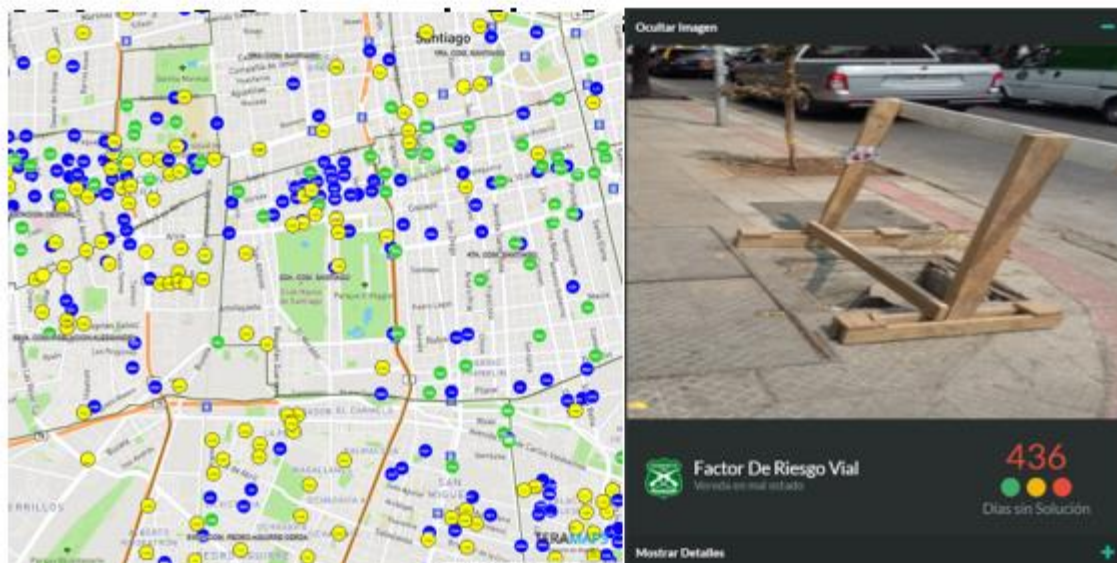
[Z8] Snook, Brent. 2004. Individual differences in distance travelled by serial burglars. *Journal of Investigative Psychology and Offender Profiling* 1:53-66.

Capítulo X. Apéndices

10.1 Apéndice A: Imágenes de Google Street View

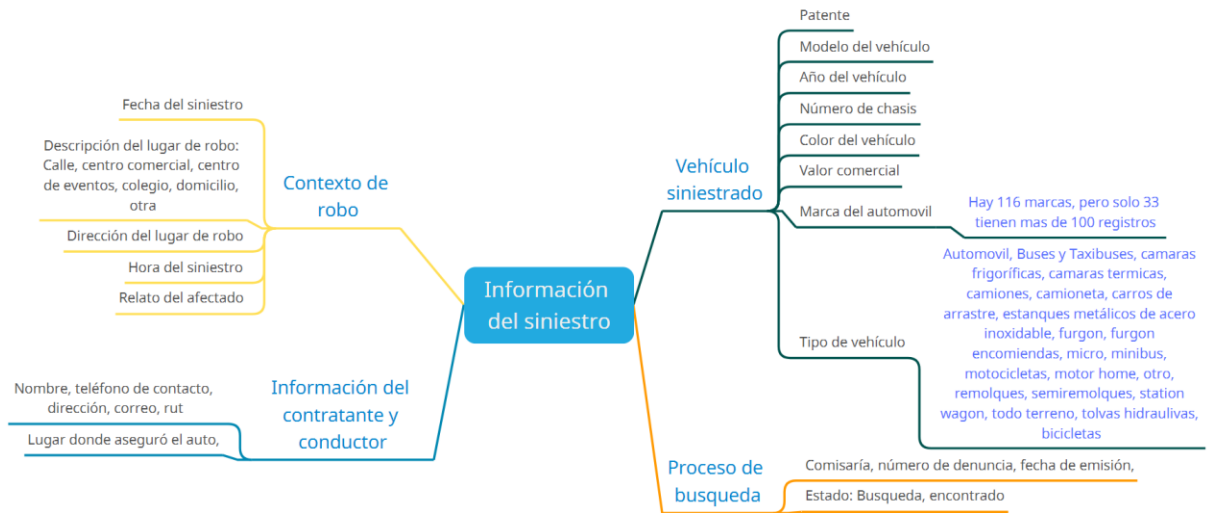


10.2 Apéndice B: Imágenes de Plan Cuadrante





10.3 Apéndice C: Información contenida en Base de AACH



10.4 Apéndice D: Modelo Descriptivo

Ambiente	Categoría	Subcategoría	Variable de medición
Privado - Público	Edificación	casa	Tamaño de la casa (Normal, Grande), Cantidad de casas
Privado - Público	Edificación	Edificio	Tamaño (Normal, Grande), Cantidad de edificios (Posible categorización edificio comercial o habitacional)
Privado - Público	Terreno	Estacionamiento	Presencia (B)
Vereda	Terreno	Vacío	Tamaño
Vereda	Calle	Vereda	Presencia (B), Amplia-Estrecha (B)
Calzada	Calle	Señales pista (Encima del asfalto)	No tapar el cruce, ceda al paso, línea de detención, Lento, Lomo de toro, Sentido de calles, Solo Buses, etc.
Calzada	Calle	Línea Amarilla (Estacionamiento)	Presencia (B)
Vereda	Calle	Alumbrado Público	Presencia (B)
Vereda	Calle	Arbol	Cantidad de arboles, Tamaño de arboles (Para entramiento considerar arboles sin hojas), (Cercanía de arbol)
Calzada	Calle	Tunel	Presencia (B)
Calzada	Calle	Interseccion	Presencia (B)
Vereda	Calle	Poste	Presencia (B), Cantidad
Vereda	Calle	Sitio libre (entre calle y t. priv)	Jardin (B), terreno vacío de tierra (B), cemento (B)
Calzada	Calle	Autos - Acción - Existencia	Acción: Estacionado (B), Movimiento (B) - Existencia: Cantidad de autos
Calzada	Calle	Micros	Presencia (B), Presencia-Troncales(B), Presencia-Inter comuna(B)
Calzada	Calle	Pista de buses	Pista en la misma vía (B), Presencia de bandejon central (B)
Vereda	Calle	Estacionamiento	Laterales (entre calle y terreno privado)
Vereda	Calle	Paradero	Presencia (B)
Vereda	Calle	Asfalto	Una vía única, dos vías, vías distintos sentidos, tres vías, cuatro vías etc (B)
Vereda	Calle	Letrero	Publicidad (B)
Calzada	Calle	Ciclovia	Presencia (B)
Calzada	Calle	Visibilidad Metro	Presencia (B)
Otro	Calle	Semáforo	Presencia (B), Cercano (B)
Vereda	Calle	Personas - Acción - Visualización	Acción: Por vereda cruzando, etc - Visualización: Presencia (B), Cantidad (B)
Vereda	Calle	Proteccion (para prohibir el paso a la calle)	Presencia (B)
Calzada	Calle	Tipo calle	(Pasaje, avenida, calle normal, sin salida, etc) (B)
Vereda	Delimitacion calle-terreno	Porton	Presencia (B)
Vereda	Delimitacion calle-terreno	Muralla	Presencia (B)
Vereda	Delimitacion calle-terreno	Reja Libre (Con visión interior)	Presencia (B)
Vereda	Delimitacion calle-terreno	Arbusto (Usualmente los que estan en las rejas)	Presencia (B)
Vereda	Delimitacion calle-terreno	Reja Tapada (Sin visión interior)	Presencia (B)
Privado - Público	Terreno	Parque	Parque entre calle (como pocuro), parque (como lnes de suarez)
Calzada	Calle	Estacionamiento vereda	Presencia (B)
Calzada	Señaléticas	Ceda el Paso, no virar, no estacionar, etc	Presencia (B) por tipo

10.5 Apéndice E: Categorías secundarias de puntos de interés

Entretención: cine, cultura, deporte, juegos, parques y plazas, vida social.

Comercio: agrícola, alimentos, aseo y limpieza, climatización y aire acondicionado, comercios especializados, concesionarios y automotoras, construcción, cordonerías, cumpleaños y cotillón, deco-hogar, electrodomésticos, kioscos, lotería, otros comercios, plásticos, prenderías y casas de empeño, reciclaje y chatarra, tiendas electrónicas.

Salud: hospitales clínicas centros de salud, médicos y especialistas, previsión de salud, rescate médico, terapias naturales.

Servicios: academias y cursos, agencias de empleo, comunicaciones, deportivos, educativos, empresas y oficinas, financieros, mantenimiento de maquinaria, mascotas, otros servicios, para el auto y moto, para el hogar, servicio técnico, servicios especializados, servicios personales, servicios contables, vivienda.

La ciudad: comisarías y carabineros, compañías de bomberos, embajadas, entidades oficiales y ministerios, fundaciones, iglesias, municipalidades, ONG, oficinas y dirección pública, otros organismos ciudad, seminarios.

Trafico y transporte: centros bip, ciclovías, estacionamientos, metro, Santiago en bici, Transantiago, urbano.

Turismo: aeropuertos, agencias de turismo, hospedaje, puntos de información, puntos de interés, terminal de transporte.

Belleza y bienestar: barberías y barber shop, centros de pilates y yoga, maquilladores, para deportistas, para verse bien, spa.

Compras: centros comerciales y mall, compras personales, hogar, joyas y accesorios, otras compras, para vestirse, para niños y bebes, regalos, tecnología, tetarías, tiendas de música y disquería, uniformes, venta de entradas, zapatería.

Restaurante:, cafés y cafeterías, chilena, comidas rápidas, delivery a domicilios, fruterías y verdulerías, helados y postres, internacional, otros restaurantes, parrilladas, pescados y mariscos, picadas, vegetariano y naturista.

10.6 Apéndice F: Descripción de variables de puntos de interés

Academias y cursos: capacitación: (356), academia (101), escuela (99), capacitaciones (92), instituto (77), conductores (66), centro (65), otec (58), servicios (39), danza (29).

Aeropuertos: aeropuerto (3), club (2), lan (1), parque (1), arauco (1), base (1), aerea (1), bosque (1), planeadores (1), vitacura (1).

Agencias de empleo: agencia (17), empleos (7), empleo (5), grupo (4), servicios (3), addecco (3), externos (2), cia. (2), cygnus (2), providencia (2).

Agencias de turismo: turismo (113), viajes (93), travel (69), agencia (53), tour (36), tours (17), cocha (16), falabella (14), providencia (12), servicios (12).

Agrícola: agrícola (167), comercial (66), agrícolas (47), vivero (45), inversiones (44), soc (37), servicios (36), jardín (35), comercializadora (31), santa (24).

Alimentos: almacén (2180), botillería (905), minimarket (719), supermercado (499), panadería (355), santa (320), pastelería (308), market (241), bazar (214), don (194).

Aseo y limpieza: aseo (63), distribuidora (25), comercial (24), clean (23), limpieza (20), servicios (18), artículos (17), industrial (16), comercializadora (14), service (11).

Barberías y barber shop: barbería (5), barber (2), inda's (1), freres (1), barbiers (1), lotus (1), nice (1), quality (1), armando (1), chileombianos (1).

Bares y discotheque: bar (317), club (101), pub (88), restobar (68), restaurante (48), restaurant (29), providencia (27), discotheque (25), café (19), the (17).

Cafés y cafeterías: café (542), cafetería (250), mall (69), coffee (64), plaza (58), starbucks (45), donuts (35), central (26), providencia (26), casa (26).

Centros bip: centro (44), bip! (44), santa (6), pedro (4), Errazuriz (3), central (3), José (3), francisco (3), Valdivia (2), Irarrázaval (2).

Centros comerciales y mall: comercial (43), mall (42), centro (39), galería (35), plaza (19), paseo (19), portal (11), espacio (8), Arauco (7), Maipú (7).

Centros de pilates y yoga: yoga (51), pilates (21), centro (19), studio (5), escuela (4), yogaluka (3), bikram (3), academia (3), integral (3), sala (3).

Chilena: restaurante (143): restaurant (49), pescadería (22), mar (18), plaza (15), mall (14), rincón (13), don (11), ostras (11), casa (10).

Ciclovías: ciclovía (2), Antonio (1), varas (1), presidente (1), Riesco (1).

Cine: cine (31), Hoyts (14), mall (12), plaza (8), Cinemark (7), Cineplanet (6), paseo (5), video (5), Arauco (3), Bernardo (3).

Climatización y aire acondicionado: ingeniería (1), servicios (1), inse (1) .

Comercios especializados: agua (42), dental (36), médicos (27), medical (21), comercial (20), clínica (19), ortopedia (17), química (15), medica (15), centro (14).

Comida rápida: sushi (537), pizza (227), mall (132), restaurante (132), plaza (129), fuente (105), Telepizza (78), soda (78), pizzería (72), McDonald's (64).

Comisarías y carabineros: comisaria (11), tenencia (4), Ñuñoa (2), subcomisaria (2), carrascal (1), juan (1), Antonio (1), ríos (1), 45a (1), cerro (1).

Compañías de bomberos: bomberos (22), compañía (19), Santiago (8), cuerpo (5), quinta (4), normal (4), metropolitano (3), sur (3), 7 (1), Conchalí (1).

Compras personales: farmacia (1042), farmacias (837), mall (434), cruz (410), verde (403), ahumada (364), salcobrand (277), plaza (248), óptica (237), ópticas (203).

Comunicaciones: diseño (220), claro (213), publicidad (190), Entel (141), mall (124), movistar (97), plaza (97), editorial (92), producciones (84), servicios (79).

Concesionarios y automotoras: automotora (196), mall (192), plaza (189), automotriz (47), condes (44), Vespuccio (43), oeste (40), sur (40), Vitacura (36), av. (34).

Construcción: construcciones (372), construcción (187), constructora (144), ingeniería (133), arquitectos (73), servicios (65), arquitectura (61), comercial (60), contratista (59), aguas (48).

Conventos: inversiones (1), convento (1) .

Cordonerías: cordonería (34), importadora (7), textil (4), paquetería (3), scarlett (3), comercial (2), casa (2), tienda (2), artículos (2), ceremonias (2).

Cultura: teatro (70), galería (69), centro (60), cultural (52), arte (52), museo (50), casa (25), espacio (20), producciones (19), Santiago (17).

Cumpleaños y cotillón: cotillón (24), fiesta (9), cumpleaños (8), express (7), carnaval (7), regalos (5), mundo (3), puente (3), alto (3), artículos (3).

Deco hogar: muebles (419), mall (106), comercial (97), antigüedades (87), cerrajería (76), importadora (60), telas (57), tienda (55), pinturas (53), alfombras (52).

Delivery a domicilios: sushi (21), delivery (6), Telepizza (3), pizza (3), domino (2), Tobalaba (2), bar (2), botillería (2), Vitacura (2), plaza (1).

Deporte: estadio (29), municipal (22), piscina (20), piscinas (11), centro (5), club (4), parque (4), Conchalí (3), universidad (3), O'Higgins (3).

Deportivos: sport (4), club (4), escuela (4), deportes (4), mall (3), plaza (3), Vespucio (3), estación (3), central (3), centro (2).

Educativos: jardín (1877), infantil (1846), escuela (838), colegio (591), especial (281), instituto (173), centro (165), universidad (164), liceo (158), lenguaje (156).

Electrodomésticos: ABCDIN (36), importadora (28), comercializadora (16), comercial (16), Luis (14), mall (12), cia. (12), maría (12), González (12), electrodomésticos (12).

Embajadas: embajada (118), republica (21), consulado (8), indonesia (4), reino (4), malasia (3), canada (3), arabe (3), egipto (3), libano (3).

Empresas y oficinas: grúas (141), seguridad (67), transportes (49), servicios (34), comercial (32), security (18), consultores (17), comercializadora (16), asociados (16), transporte (15).

Entidades oficiales y ministerios: centro (27), mujer (23), ministerio (17), registro (6), civil (6), identificación (6), servicio (5), nacional (5), Santiago (4), puente (3).

Estacionamientos: estacionamiento (40), estacionamientos (27), estación (13), parking (11), Santiago (11), park (9), central (5), system (5), plaza (5), saba (5)..

Financieros: banco (2821), cajero (1540), automático (1514), supercaja (1011), Santander (880), redelcom (593), Banefe (557), Santiago (514), multicaja (464), Servipag (391).

Fruterías y verdulerías: verdulería (20), almacén (10), frutas (6), verduras (5), comercial (5), frutería (4), don (3), veguita (3), Luis (3), Felipe (3).

Fundaciones: fundación (62), casa (8), desarrollo (6), educacional (6), instituto (5), joven (5), beneficencia (5), social (4), familia (4), cerro (4).

Helados y postres: pastelería (204), mall (123), plaza (122), heladería (63), Savory (55), bravísimo (33), Arauco (33), yogen (33), helados (31), center (29).

Hogar: outlet (190), mall (89), plaza (44), growshop (44), Santiago (26), Maipú (24), centro (23), parís (22), importadora (22), Falabella (21).

Hospedaje: hotel (362), motel (193), Santiago (90), hostel (67), apart (51), hostel (48), providencia (34), suites (28), casa (24), residencial (24).

Hospitales clínicas y centros de salud: dental (558), centro (541), clínica (497), salud (248), dr (236), servicios (196), medico (186), dr. (154), odontológica (153), consulta (152).

Iglesias: parroquia (34), iglesia (31), santa (13), maría (11), señora (9), cristo (6), capilla (6), templo (5), evangélica (5), pentecostal (5).

Internacional: restaurant (595), restaurante (510), sushi (127), china (116), mall (70), comida (70), plaza (53), Perú (48), casa (41), fu (36).

Joyas y accesorios: joyas (239), joyería (213), mall (121), plaza (89), comercial (41), importadora (35), perfumería (31), portal (31), perfúmame (30), Arauco (30).

Juegos: teletrak (74), plaza (29), mall (29), pool (19), happyland (16), juegos (15), salón (14), eventos (9), center (8), sur (7).

Kioscos: kiosko (22), kiosco (19), almacén (10), bazar (4), Irarrázaval (4), Ana (3), luisa (3), Carmen (3), Eduardo (3), don (3).

Lotería: agencia (2), polla (2), lotería (2), pentágono- (1), independencia (1), luisa (1), almacén (1), Inés (1), bazar, (1), carrascal (1).

Mantenimiento de maquinaria: maquinarias (6), group (2), industrial (2), soluciones (2), Ricardo (2), ingeniería (2), alva (1), Frost (1), ángel (1), nogales (1).

Maquilladores: mall (2), maquillo (1), maquilladora (1), Carmen (1), cortes (1), l.t.d.a (1), dorado (1), salones (1), belleza (1), domicilio (1).

Mascotas: veterinaria (438), clínica (280), pet (141), mascotas (83), veterinario (71), peluquería (47), canina (44), centro (44), animal (43), shop (37).

Médicos y especialistas: laboratorio (106), clínico (65), centro (26), kinesiología (24), salud (19), kinesióloga (17), vida (14), medico (13), clínica (13), kinesiólogo (12).

Metro: estación (108), metro (106), plaza (4), santa (4), universidad (3), escuela (2), militar (2), Magallanes (2), parque (2), José (2).

Municipalidades: municipalidad (38), estación (2), central (2), pedro (2), Bernardo (2), municipal (2), Maipú (2), recoleta (2), Peñalolén (2), condes (2).

Nan: n (105), junta (16), vecinos (16), escuela (13), o'higgins (11), bernardo (11), conductores (10), jose (9), farmacias (9), belen (9).

Oficinas y dirección publica: vecinos (101), junta (98), registro (50), civil (50), identificación (49), centro (45), social (21), desarrollo (15), villa (15), instituto (14).

ONG: ONG (18), desarrollo (16), fundación (8), centro (4), social (4), casa (2), acogida (2), corporación (2), educación (2), quijote (2).

Otras compras: gas (80), Lipigas (63), importadora (57), comercial (37), distribuidora (25), mall (24), plaza (21), casa (20), ii (17), alto (15).

Otros comercios: inversiones (510), comercial (419), importadora (407), compañía (197), inmobiliaria (189), exportadora (162), comercializadora (134), ingeniería (116), servicios (102), gas (97).

Otros organismos ciudad: iglesia (410), evangélica (119), bomberos (102), compañía (97), pentecostal (82), parroquia (78), comisaria (74), Santiago (54), bautista (50), Jesucristo (39)..

Otros restaurantes: restaurant (247), restaurante (143), pollo (37), rincón (26), casino (25), fuente (22), don (22), café (19), bar (17), resobar (17)

Otros servicios: centro (1036), club (647), social (530), adulto (458), mayor (457), desarrollo (425), madres (280), comité (249), cultural (247), capacitación (235).

Para deportistas: club (102), deportivo (91), mall (33), plaza (23), social (21), centro (18), cultural (17), unión (14), condes (13), alto (12).

Para el auto y moto: servicio (435), estación (381), repuestos (215), Copec (212), Shell (200), automotriz (178), Petrobras (153), av. (132), comercial (123), taller (98).

Para el hogar: gasfitería (238), vidriería (129), vidrios (89), aluminios (74), fumigaciones (51), piscinas (45), gasfiter (38), servicios (34), jardines (34), comercial (26).

Para niños y bebés: mall (144), plaza (108), baby (48), juguetería (45), importadora (41), center (36), Arauco (31), comercial (29), juguetes (28), infantil (26)..

Para verse bien: peluquería (1247), salón (592), belleza (377), gimnasio (191), centro (175), unisex (145), estética (133), fitness (104), pacifico (89), podología (67).

Para vestirse: mall (464), plaza (324), Arauco (142), center (130), costanera (119), tienda (96), importadora (89), parque (88), ropa (87), alto (86).

Parques y plazas: plaza (2935), publica (706), feria (339), libre (318), santa (124), n (108), parque (104), sur (89), José (78), rio (75).

Parrilladas: restaurante (33), parrilladas (28), restaurant (17), pollos (11), pollo (10), beff (10), mall (9), buffalo (8), plaza (6), asados (5).

Pescados y mariscos: restaurante (14), mar (11), pesquera (10), restaurant (9), comercial (7), marisquería (5), ostras (5), productos (5), pesca (4), inversiones (4).

Picadas: restaurante (24), restaurant (11), pica (8), picada (5), comida (4), rincón (3), pollo (3), pollos (3), asados (3), don (2).

Plásticos: plásticos (129), comercial (22), comercializadora (13), envases (12), bolsas (9), importadora (9), industrial (9), maría (7), fabricación (6), ingeniería (5).

Prenderías y casas de empeño: dirección (2), general (2), crédito (2), prendario (2), orocash (2), julio (1), Marticorena (1), Golden (1), chile-los (1), toros (1).

Previsión de salud: Isapre (78), masvida (21), cruzblanca (21), consalud (19), colmena (17), banmedica (16), vida (14), av. (14), tres (11), clinica (9).

Puntos de información: info (1), tour (1), bellavista (1), punto (1), limpio (1), Barnechea (1), macroscope (1), sucursal (1), movistar (1), servicios (1).

Puntos de interés: Santiago (7), palacio (5), ex (3), santa (3), cerro (3), lucrecia (2), hospital (2), José (2), catedral (2), evangélica (2).

Reciclaje y chatarra: reciclaje (135), supermercado (73), punto (53), limpio (48), líder (42), parroquia (23), santa (18), Isabel (11), contenedor (11), publico (11).

Regalos: librería (417), florería (195), diseño (127), flores (104), bazar (84), mall (70), plaza (61), relojería (56), jardín (47), libros (45).

Rescate medico: ambulancias (6), santa (2), ambulancia (2), blanca (1), alo (1), aurora (1), alcántara (1), psiquiátricas (1), montano (1), ecar (1).

Santiago en bici: bicicletas (28), taller (22), biciestacionamiento (16), bike (13), mall (8), univ. (7), bikes (4), campus (4), Santiago (4), full (3).

Seminarios: seminario (14), providencia (2), menor (1), claretiano (1), 777 (1), kabbalah (1), centre (1), textil (1), serviautos (1), dercocenter (1).

Servicio técnico: servicio (134), técnico (133), bio (16), computación (12), computadores (12), notebook (11), electrónica (8), persa (8), service (7), mtek (7).

Servicios contables: contadores (33), contable (27), Carmen (23), estudio (21), asociados (18), asesorías (17), contabilidad (14), Muñoz (14), Andrea (14), María (13).

Servicios especializados: imprenta (129), impresores (57), grafica (52), eventos (43), banquetera (41), servicios (35), impresos (32), electricidad (31), conductores (30), escuela (26).

Servicios personales: inmobiliaria (473), propiedades (417), abogado (407), abogados (375), hogar (356), ancianos (273), lavaseco (175), funeraria (156), corredores (136), inversiones (129).

Spa: centro (55), casa (40), pichara (40), estética (39), mall (19), plaza (16), podología (14), condes (10), center (8), intersalon (8).

Tecnología: mall (109), plaza (75), computación (71), foto (48), servicios (35), comercial (31), center (30), pc (30), electrónica (28), bio (24).

Terapias naturales: centro (46), terapias (31), reiki (19), terapia (18), acupuntura (10), integral (9), medicina (8), natural (8), instituto (7), yerbearía (6).

Terminal de transporte: transportes (84), buses (9), terminal (8), transporte (7), mudanzas (6), cargo (6), bus (5), Pullman (5), jac (5), logística (5).

Teterias: tea (5), mall (3), café (3), tetaría (2), adagio (2), teas (2), inside (2), connection (2), cafetería (2), mo (2).

Tiendas de música y disquería: music (12), disquería (11), música (10), vinilos (5), mall (5), plaza (4), tienda (4), respect (3), discos (3), world (3).

Tiendas electrónicas: electrónica (47), mall (35), casa (18), plaza (17), pc (14), electricidad (14), importadora (13), Factory (12), eléctricos (10), store (9).

Transantiago: paradero (11192), Transantiago (11192), metro (8), estación (7), bip (3), ph407 (2), ph408 (2), centro (2), v (2), bio (2).

Uniformes: uniformes (43), confecciones (23), comercial (10), ropa (8), distribuidora (4), colegio (4), julin (4), serra (4), sport (4), trabajo (4).

Urbano: radio (207), taxi (199), transportes (135), buses (76), taxis (63), bus (44), transporte (26), radiotaxi (24), tur (23), Borja (19).

Vegetariano y naturista: restaurant (15), restaurante (9), natural (8), krishna (6), vegan (6), emporio (6), naturista (5), providencia (4), vegano (4), café (4).

Venta de entradas: punto (4), ticket (4), mall (4), plaza (4), Egaña (1), oeste (1), Vespucio (1), rockaxis (1), providencia (1), puntoticket-ripley (1)

Vida social: centro (174), club (120), madres (101), adulto (95), mayor (92), eventos (60), social (38), leones (33), cultural (30), organización (26).

Vivienda: constructora (137), construcciones (95), propiedades (84), inmobiliaria (80), construcción (41), Fuenzalida (31), inversiones (24), ingeniería (23), Luis (12), edificio (12).

Zapatería: mall (216), plaza (173), calzados (160), zapatería (141), center (50), Arauco (45), calzado (41), shoes (39), Vespucio (37), costanera (33).

10.7 Apéndice F: Detalle resultados modelo logit Puntos de interés

Coefficients:	Estimate	Std. Error	z-value	Pr(> z)	s.e
(Intercept)	-0.139	0.114	-1.218	0.223	
academias y cursos D1	-0.037	0.009	-4.096	0.000	***
aeropuertos D1	0.557	0.201	2.776	0.005	**
agencias de turismo D1	-0.071	0.013	-5.482	0.000	***
aseo y limpieza D1	0.119	0.022	5.291	0.000	***
comercios especializados D1	0.032	0.019	1.657	0.098	.
construccion D1	0.013	0.009	1.430	0.153	
deco hogar D1	0.020	0.004	4.568	0.000	***
delivery a domicilios D1	-0.163	0.100	-1.629	0.103	
educativos D1	0.032	0.006	5.793	0.000	***
electrodomesticos D1	-0.065	0.037	-1.780	0.075	.
embajadas D1	-0.120	0.032	-3.698	0.000	***
estacionamientos D1	0.124	0.058	2.117	0.034	*
fruterias y verdulerias D1	-0.178	0.056	-3.193	0.001	**
fundaciones D1	-0.161	0.066	-2.452	0.014	*
helados y postres D1	0.072	0.023	3.129	0.002	**
hospedaje D1	0.018	0.010	1.801	0.072	.
iglesias D1	-0.106	0.063	-1.688	0.091	.
internacional D1	0.012	0.006	1.846	0.065	.
juegos D1	-0.165	0.046	-3.625	0.000	***
kioscos D1	-0.177	0.054	-3.280	0.001	**
ong D1	0.266	0.096	2.764	0.006	**
otras compras D1	0.025	0.016	1.513	0.130	
otros comercios D1	-0.008	0.002	-3.347	0.001	***
otros organismos ciudad D1	-0.024	0.017	-1.452	0.147	
para deportistas D1	-0.094	0.030	-3.158	0.002	**
para el hogar D1	-0.066	0.013	-5.216	0.000	***
para ninos y bebes D1	0.016	0.012	1.421	0.155	
parrilladas D1	-0.087	0.054	-1.609	0.108	
picadas D1	0.114	0.050	2.295	0.022	*
reciclaje y chatarra D1	0.059	0.035	1.674	0.094	.
santiago en bici D1	-0.093	0.056	-1.661	0.097	.
servicios personales D1	0.012	0.002	5.177	0.000	***
zapateria D1	-0.012	0.006	-2.146	0.032	*
aeropuertos D2	0.230	0.129	1.785	0.074	.
agencias de turismo D2	-0.023	0.009	-2.697	0.007	**
cafes y cafeterias D2	-0.014	0.006	-2.286	0.022	*

Ver el resto de las variables en la siguiente página

centros bip D2	-0.084	0.057	-1.492	0.136	
chilena D2	0.022	0.011	2.021	0.043	*
comercios especializados D2	0.028	0.013	2.176	0.030	*
comisarias y carabineros D2	-0.113	0.079	-1.428	0.153	
concesionarios y automotoras D2	0.011	0.006	1.664	0.096	.
cordonerias D2	-0.107	0.030	-3.585	0.000	***
deco hogar D2	0.008	0.003	2.844	0.004	**
delivery a domicilios D2	-0.095	0.060	-1.602	0.109	
educativos D2	0.008	0.003	2.704	0.007	**
financieros D2	-0.008	0.002	-3.762	0.000	***
fruterias y verdulerias D2	-0.056	0.033	-1.702	0.089	.
juegos D2	-0.040	0.027	-1.493	0.135	
maquilladores D2	-0.308	0.119	-2.581	0.010	**
medicos y especialistas D2	0.050	0.016	3.128	0.002	**
oficinas y direccion publica D2	0.043	0.017	2.442	0.015	*
ong D2	0.086	0.059	1.454	0.146	
otras compras D2	0.025	0.008	3.267	0.001	**
otros comercios D2	-0.003	0.001	-2.356	0.018	*
otros organismos ciudad D2	-0.022	0.010	-2.234	0.025	*
otros servicios D2	-0.003	0.002	-2.072	0.038	*
para el auto y moto D2	0.005	0.001	3.425	0.001	***
para el hogar D2	-0.044	0.008	-5.700	0.000	***
para verse bien D2	0.013	0.003	4.878	0.000	***
para vestirse D2	0.003	0.001	2.767	0.006	**
parques y plazas D2	0.006	0.003	2.228	0.026	*
picadas D2	0.062	0.035	1.805	0.071	.
prenderias y casas de empeno D2	-0.255	0.122	-2.094	0.036	*
reciclaje y chatarra D2	0.042	0.020	2.120	0.034	*
regalos D2	-0.007	0.005	-1.454	0.146	
seminarios D2	-0.316	0.205	-1.540	0.124	
servicio tecnico D2	0.038	0.016	2.428	0.015	*
servicios contables D2	-0.023	0.016	-1.505	0.132	
servicios especializados D2	0.021	0.007	2.967	0.003	**
servicios personales D2	0.006	0.002	4.188	0.000	***
tecnologia D2	-0.018	0.008	-2.440	0.015	*
transantiago D2	-0.003	0.002	-1.928	0.054	.
vegetariano y naturista D2	0.056	0.030	1.871	0.061	.
venta de entradas D2	0.361	0.247	1.462	0.144	
vida social D2	-0.009	0.005	-1.684	0.092	.
dist_plazarmas	0.000	0.000	8.269	<2.00E-16	***
dist_costanera	0.000	0.000	-10.640	<2.00E-16	***

**10.8 Apéndice G: Detalle modelo logit de Capacidad de huida
Modelo (1), generado con datos de primera simulación**

Coefficients:	Estimate	Std. Error	z-value	Pr(> z)	s.e
(Intercept)	0.968	0.037	26.067	<2.00E-16	***
trafico medio	-0.501	0.037	-13.397	<2.00E-16	***
trafico alto	-0.811	0.039	-20.869	<2.00E-16	***
trafico muy alto	-1.340	0.042	-31.807	<2.00E-16	***
0:00 a 2:00	-0.549	0.054	-10.127	<2.00E-16	***
2:00 a 4:00	-0.870	0.057	-15.155	<2.00E-16	***
4:00 a 6:00	-1.123	0.061	-18.256	<2.00E-16	***
6:00 a 8:00	-0.791	0.060	-13.237	<2.00E-16	***
8:00 a 10:00	-0.518	0.059	-8.730	<2.00E-16	***
10:00 a 12:00	-0.533	0.060	-8.893	<2.00E-16	***
12:00 a 14:00	-0.468	0.061	-7.711	1.25E-14	***
14:00 a 16:00	-0.759	0.064	-11.795	<2.00E-16	***
16:00 a 18:00	-0.495	0.063	-7.879	3.30E-15	***
18:00 a 20:00	0.172	0.061	2.814	0.00489	**
20:00 a 22:00	0.260	0.056	4.674	2.95E-06	***

Modelo (2), generado con datos de segunda simulación

Coefficients:	Estimate	Std. Error	z-value	Pr(> z)	s.e
(Intercept)	0.739	0.08553	8.642	<2.00E-16	***
0:00 a 2:00	-0.656	0.12864	-5.101	3.39E-07	***
2:00 a 4:00	-0.997	0.13748	-7.251	4.12E-13	***
4:00 a 6:00	-1.253	0.14522	-8.631	<2.00E-16	***
6:00 a 8:00	15.347	228.87215	0.067	0.947	
8:00 a 10:00	16.061	228.8722	0.07	0.944	
10:00 a 12:00	16.003	228.8722	0.07	0.944	
12:00 a 14:00	-15.840	238.57087	-0.066	0.947	
14:00 a 16:00	-15.982	238.57088	-0.067	0.947	
18:00 a 20:00	0.717	0.15313	4.683	2.83E-06	***
20:00 a 22:00	15.998	228.8722	0.07	0.944	
trafico.medio	-16.784	228.87216	-0.073	0.942	
trafico.alto	14.766	238.57086	0.062	0.951	
trafico.muy.alto	-1.385	0.14593	-9.493	<2.00E-16	***

Modelo (3), generado con datos de segunda simulación

Coefficients:	Estimate	Std. Error	z-value	Pr(> z)	s.e
(Intercept)	0.71703	0.162	4.426	9.59E-06	***
0:00 a 2:00	-0.62819	0.13135	-4.782	1.73E-06	***
2:00 a 4:00	-0.95786	0.14219	-6.736	1.62E-11	***
4:00 a 6:00	-1.20461	0.15178	-7.937	2.08E-15	***
6:00 a 8:00	15.81173	290.94433	0.054	0.957	
8:00 a 10:00	16.49319	290.94438	0.057	0.955	
10:00 a 12:00	16.4413	290.94438	0.057	0.955	
12:00 a 14:00	-0.47378	348.98028	-0.001	0.999	
14:00 a 16:00	-0.60094	348.98028	-0.002	0.999	
16:00 a 18:00	16.42739	535.03354	0.031	0.976	
18:00 a 20:00	17.10841	535.03356	0.032	0.974	
20:00 a 22:00	16.45154	290.94438	0.057	0.955	
trafico.medio	-17.27279	290.94435	-0.059	0.953	
trafico.alto	-0.65939	348.98025	-0.002	0.998	
trafico.muy.alto	-17.87096	535.03354	-0.033	0.973	
vel_avg_traffic	-0.06829	0.06105	-1.119	0.263	
vel_avg_nontraffic	0.07743	0.06288	1.232	0.218	

10.9 Apéndice H: Entrenamiento con imágenes

