

Predicción de ineficiencias en la contratación pública de Bogotá

Santiago Rodríguez Arévalo

Director: Jorge A. Gallego

Tesis para optar por el título de
Magister en Economía de las Políticas Públicas

Facultad de Economía
Universidad del Rosario
Bogotá
2020

Predicción de ineficiencias en la contratación pública de Bogotá

Santiago Rodríguez Arévalo

Maestría en Economía de las Políticas Públicas, Universidad del Rosario

Abstract

Este trabajo propone una metodología basada en Inteligencia Artificial para mejorar la capacidad que tienen los entes de control de detectar anomalías en la contratación pública de Bogotá. A partir del uso la información pública consolidada en la plataforma SECOP II y la aplicación de herramientas de aprendizaje automático, es posible predecir con una precisión superior al 90 % qué contratos, entre los suscritos por la Administración Distrital de Bogotá, pueden presentar prórrogas o sobrecostos en su ejecución. El algoritmo permite además cuantificar el peso de las variables incluidas en la predicción y su análisis en función de su pertenencia a cada etapa del ciclo contractual. El valor de los contratos, la diversidad en la contratación de las entidades, la relación de la adjudicación de contratos con el ciclo fiscal y el uso inadecuado de modalidades de contratación son identificadas como las variables de mayor importancia. Esta aplicación además es un ejemplo del aprovechamiento de las nuevas fuentes de información disponibles con la apertura de datos del Estado y de cómo la transparencia en el acceso a la información puede traducirse en herramientas prácticas que mejoren la gestión de los gobiernos locales.

Keywords: Contratación pública, eficiencia, machine learning, transparencia, gestión pública local.

1. Introducción

Durante 2019, el Presupuesto General de Gastos de la Administración Distrital de Bogotá fue de 33,1 billones de pesos, una cifra récord en la ciudad equivalente al 12% de su Producto Interno Bruto y superior al Producto Interno Bruto de 25 de los 33 departamentos del país. La complejidad y magnitud de la contratación pública en la ciudad así como los recursos escasos de las entidades de control encargadas de vigilar su ejecución, obligan a buscar soluciones innovadoras que mejoren su capacidad de detectar de manera temprana ineficiencias y permitan generar alertas tempranas para su prevención.

Si bien el presupuesto público incluye rubros como transferencias, gastos generales y servicios personales, en buena medida es usado para la contratación y compra de bienes y servicios a través de los cuales se materializan las políticas públicas (Melo & Ramos, 2017). En este sentido, las entidades que forman parte del Distrito deben invertir una gran cantidad de recursos para asegurar resultados satisfactorios en la ejecución presupuestal en términos de eficiencia, eficacia, economía y publicidad.

El desarrollo tecnológico y nuevas herramientas de gestión basadas en datos como las plataformas de contratación pública *e-procurement* ponen a disposición de la ciudadanía información valiosa sobre el manejo de los recursos del Estado. En el caso colombiano, la Agencia Nacional de Contratación Pública - Colombia Compra Eficiente (CCE) es la agencia gubernamental encargada de monitorear la contratación pública en el país. La agencia registra la información de los procesos de contratación pública ejecutados en Colombia a través del Sistema Electrónico de Compras Públicas (SECOP), esta información a su vez está disponible al público a través del Portal de Datos Abiertos de Colombia para su consulta.

Las estrategias *e-procurement* han mostrado ser efectivas para mejorar la eficiencia en el gasto público de gobiernos subnacionales, por ejemplo, han impactado positivamente la calidad de la infraestructura en India y los tiempos de entrega de obras en Indonesia (Lewis-Faupel et al., 2016). También han promovido la transparencia en el acceso a la información; gobiernos co-

mo el de Chile¹ y Ucrania² han creado plataformas de acceso público para facilitar el seguimiento a la ejecución de contratos públicos.

Este trabajo propone una herramienta basada en Inteligencia Artificial para el control preventivo sobre la contratación pública en la ciudad de Bogotá. Mediante el uso de herramientas innovadoras de gestión como el aprovechamiento de la información pública sobre procesos contractuales y la implementación de modelos de aprendizaje automático (*machine learning*), se obtiene un algoritmo capaz de predecir qué procesos contractuales del Distrito son más propensos a presentar ineficiencias en su ejecución con un nivel de precisión superior al 90 % y un costo de implementación bajo.

La identificación temprana de riesgos asociados a la ineficiencia en la contratación pública permite reducir la carga en la investigación punitiva y el costo asociado a la sanción social sobre la gobernanza. Asimismo, en la medida en que mejore la capacidad de monitoreo y seguimiento sobre la ejecución de contratos públicos, se reducen los incentivos a la entrada al mercado de agentes corruptos o poco competitivos.

En casos como el del modelo presentado en este trabajo, la capacidad de generar recomendaciones basadas en evidencia a partir de información pública parte del conocimiento de técnicas especializadas de análisis cuya aplicación en el diseño y evaluación de políticas públicas es aun incipiente. De acuerdo con Kleinberg y coautores (2015), el análisis cuantitativo de políticas públicas hasta ahora se ha centrado principalmente en la búsqueda de evidencia causal, sin embargo, la evaluación retrospectiva de las acciones del Estado y su relación con otros actores sociales no es un marco de análisis aplicable a todos los problemas públicos.

La implementación de técnicas de *machine learning* a partir de la información pública permite entrenar modelos que identifiquen de manera temprana la propensión de nuevos contratos a presentar ineficiencias con base en la información disponible sobre los contratos ya terminados. Este trabajo se nutre de una literatura creciente en la aplicación de técnicas de aprendizaje automático para la detección de ineficiencias y riesgos de corrupción en

¹<https://comprasmunicipales.observatoriofiscal.cl/>

²<https://prozorro.gov.ua/en>

contratación pública, a nivel nacional y municipal (Gallego et al., 2020), (Colonnelli et al., 2019) y (Lopez-Iturriaga y Sanz, 2018) o en la contratación de proyectos de desarrollo internacional (Grace et al., 2016).

En el caso del presente modelo, la detección de ineficiencias en la contratación pública es estimada a partir de la existencia de sobrecostos o prorrogas en los contratos. Esto se justifica en la medida en que existe literatura que ha documentado la asociación de este tipo de anomalías a mayores riesgos de corrupción (Dal Bo y Rossi, 2007) y en que estas además representan en sí mismas un costo de oportunidad en el acceso oportuno a bienes y servicios para la ciudadanía.

Se construyeron 42 variables asociadas a riesgos de ineficiencia en la contratación pública durante las tres etapas del ciclo contractual (etapa pre contractual, etapa de adjudicación y etapa de ejecución); con esta información se entrenaron 5 algoritmos de diferente naturaleza (basados en árboles de decisión, basados en regresiones y basados en prototipos) populares en la resolución de problemas de clasificación binaria. Como resultado de la competencia entre modelos, se obtuvo que CatBoost (Prokhorenkova et al. 2019) tuvo el mejor desempeño con un nivel de precisión en la predicción de 92%.

Un análisis complementario del peso de cada variable incluida en el modelo sobre la existencia de ineficiencias mostró que entre los predictores más importantes están: (i) variables asociadas al diseño y la naturaleza de los contratos (etapa pre contractual) como la modalidad de contratación, la categoría del bien o servicio y la diversidad en los bienes y servicios que contratan las entidades, (ii) variables asociadas a la temporalidad en la adjudicación de los contratos, relacionadas con la etapa de adjudicación y con el periodo fiscal en la ciudad, y (iii) el valor de la compra, identificada como la variable de mayor peso, cuya relación directamente proporcional con la aparición de sobrecostos y prórrogas puede estar asociada a la complejidad de los bienes y servicios contratados, que reduce la capacidad de ejercer control por parte de las entidades encargadas y de prever contingencias por parte de los contratistas.

Los resultados encontrados son robustos al entrenamiento de los modelos considerando el desbalance de clases provocado por el menor número de contratos con adiciones dentro del total de la contratación pública y a diferentes

métodos de ponderación de la importancia de las variables en la predicción. Como producto de este trabajo se espera consolidar la metodología de análisis como un insumo en la toma de decisiones sobre el control a la eficiencia del gasto y la contratación pública en Bogotá, con el fin de mejorar el proceso de control preventivo y aumentar los costos de transacción de conductas que atenten contra el uso adecuado de los recursos públicos.

Este trabajo está dividido en cinco secciones que comienzan con la presente introducción. A continuación se discute la relevancia del trabajo desde la política pública y en particular, para la gestión pública local eficiente y basada en evidencia. Luego, se presenta en detalle la metodología, las fuentes de información y la naturaleza de los modelos entrenados. En cuarto lugar se discuten los resultados encontrados y finalmente se presentan las conclusiones del estudio.

2. Discusión de política pública

2.1. Definición de ineficiencia

La manera en la que se gastan los recursos públicos puede llegar a ser incluso más importante que el monto total de fondos que se gastan; en la contratación pública, mayores niveles de eficiencia se reflejan un mayor ahorro de recursos, particularmente tiempo y dinero. La eficiencia económica está asociada de manera general al manejo productivo de recursos, haciendo uso de los insumos disponibles para entregar la mayor cantidad de productos posible, con el fin de obtener el máximo valor social por cada unidad monetaria invertida.³ En consecuencia, la contratación pública eficiente está asociada a la adquisición de bienes y servicios en el plazo correcto y al precio correcto para soportar las acciones del Estado (Shindu & Rotich, 2014).

³De manera general, la ineficiencia en el gasto público se puede clasificar entre ineficiencia técnica, que corresponde a las ineficiencias en cada componente del gasto por factores como negligencia, corrupción, falta de capacidades o una combinación de estos factores y la ineficiencia asignativa, cuyo fin es priorizar entre partidas de gasto alternativas basándose en la evidencia y la asignación de los recursos públicos a intervenciones con tasas de retorno más altas (BID, 2018). En el caso de la contratación pública, las asignaciones del gasto ya están determinadas, por lo cual está asociada a la ocurrencia de ineficiencias técnicas.

La necesidad de detectar de manera temprana ineficiencias en la contratación pública se justifica en la medida que las fallas en las diferentes etapas del ciclo contractual desincentivan la competencia entre proveedores al aumentar las barreras de entrada al mercado público y pueden indicar niveles bajos de transparencia y solidez institucional, lo cual a su vez, siguiendo a Bosio et al. (2020) reduce los costos de incurrir en prácticas corruptas.

De acuerdo con Bandiera et al. (2009), la corrupción y las ineficiencias en la contratación son fenómenos diferentes pero que pueden estar estrechamente relacionados. Las prácticas corruptas (malgasto activo) implican un beneficio directo o indirecto para un funcionario público, mientras que las ineficiencias (malgasto pasivo) están relacionadas con falta de capacidad o incentivos en los funcionarios públicos para llevar a cabo sus funciones o a regulación excesiva⁴ (Kelman, 1990; 2005); factores que incrementan el precio promedio que paga el Estado por los bienes y servicios que adquiere, al no permitir que cada proceso de contratación se adapte a las necesidades específicas de cada mercado.

El alto volumen de transacciones, fallas de coordinación y asimetrías de información entre las partes que participan en las compras públicas aumentan los riesgos de corrupción e ineficiencias administrativas y presupuestales. Los efectos nocivos sobre el bienestar ocasionados por el mal gasto de recursos públicos, obliga a las entidades encargadas de ejercer el control sobre la contratación pública a buscar herramientas que hagan más eficientes los procesos de seguimiento y monitoreo a lo largo del ciclo de la contratación.

Con base en la información disponible de manera pública sobre procesos contractuales del Estado colombiano, la ineficiencia en la contratación pública es cuantificada a partir de las prórrogas o sobrecostos de los contratos. Si bien la existencia de adiciones no es una condición inherente a una mala gestión contractual, si genera costos adicionales a la administración pública, bien sea a través del requerimiento de recursos adicionales para la finalización de los contratos, tanto monetarios como humanos, o a través de cambios en la planeación administrativa y presupuestal de las entidades.

⁴En la literatura anglosajona este problema es conocido como *red tape*, término que hace referencia al exceso de burocracia asociado a la administración pública de la corona española en la época colonial (Fazekas, 2017).

El uso de recursos adicionales a los inicialmente previstos representa un costo de oportunidad para la ejecución de las demás labores que deben cumplir las entidades del Estado y puede generar incertidumbre en los contratistas, que luego se traduce en una menor competencia en el mercado al desincentivar su participación en los procesos de contratación pública.

2.2. Contexto en Bogotá

La ejecución presupuestal en Bogotá ha crecido 10 puntos porcentuales durante los últimos cuatro años. Como lo describe el Banco Interamericano de Desarrollo (2018) en su estudio sobre calidad del gasto en América Latina, esta tendencia es consistente con la ley de Wagner, según la cual en la medida en que aumenta el desarrollo económico del país, y de la ciudad, el gasto público tendrá también una tendencia al alza, tanto en un margen extensivo (demanda por nuevos bienes y servicios), como intensivo (ampliación de los bienes y servicios existentes).

Las crecientes demandas sociales, el cambio demográfico, la revolución tecnológica, así como el aumento en las cargas fiscales y la volatilidad en la economía internacional, han aumentado la presión sobre los gobiernos, tanto nacionales como locales, para buscar mecanismos que les permitan mejorar la eficiencia en el gasto público. En este sentido, el rol de la vigilancia en la ejecución presupuestal y la gestión contractual es cada vez más trascendental.

De acuerdo con la información reportada a SECOP II, el 48 % de los contratos firmados en 2019 relacionados con la compra y contratación de bienes y servicios, fueron firmados por entidades de la Administración Distrital de Bogotá, la ciudad es además el único gobierno subnacional con un número significativo de entidades que usan SECOP II (81 %). Si bien este registro no es aun censal, si permite tener una lectura global acertada sobre la contratación en la ciudad, fundamental para el propósito del estudio.

En relación a las características de los contratos, vale la pena resaltar que algunas entidades en Colombia están eximidas de los criterios establecidos en Estatuto General de Contratación y adelantan sus procesos contractuales

en lo que comúnmente se conoce como Régimen Especial.⁵ Esta es, de hecho, la modalidad de selección más usada de acuerdo con los registros, en 2019 representó el 81 % de los contratos firmados en la ciudad.

Los registros en la plataforma muestran además que, entre los contratos para la adquisición de bienes y servicios firmados en 2019 bajo el marco normativo del Estatuto General de Contratación, es decir, sin tener en cuenta el Régimen Especial, el 17 % se suscribieron a través de la modalidad de contratación directa, que a diferencia de las demás modalidades no es competitiva y de acuerdo con el marco legal colombiano debe ser excepcional. Adicionalmente, el 30 % de los contratos se suscribieron bajo la modalidad de mínima cuantía.

Lo anterior es relevante en la medida en que organizaciones internacionales con experiencia en la formulación de indicadores para detectar alertas tempranas de fraude en contratación pública como Open Contracting Partnership (2016) han identificado el uso excesivo de modalidades de selección no competitivas y la aplicación indebida de los criterios de mínima cuantía en la contratación pública como factores que aumentan el riesgo de fraude e ineficiencias. De hecho, en Bogotá la Veeduría Distrital (2017) evidenció que entre 2015 y 2016 el 75 % de los contratos suscritos a través de la modalidad de mínima cuantía fueron adicionados durante su ejecución por valores que oscilaban entre el 45 % y el 50 % del monto inicial, y en algunos casos excediendo el tope de mínima cuantía de cada entidad, muchos de ellos sin justificación técnica, jurídica o financiera.

El desfalco en la contratación de la tercera fase del sistema Transmilenio que recorre la Calle 26⁶ fue el origen de una ambiciosa reforma normativa, plasmada en la Ley 1474 de 2011, conocida como el Nuevo Estatuto Anticorrupción, a partir del cual se dictan normas orientadas a fortalecer los mecanismos de prevención, investigación y sanción de actos de corrupción

⁵Este régimen de contratación fue creado para entidades que si bien ejecutan recursos públicos, compiten en el mercado.

⁶La Contraloría General (2011) estimó que el detrimento al erario público de todas las irregularidades en los proyectos del Distrito fue cercano a los 175.000 millones de pesos de ese entonces, además, la troncal de la Calle 26 entró en operación cerca de tres años después de lo inicialmente estipulado.

y la efectividad del control de la gestión pública. A partir de estas nuevas herramientas normativas, el reto recae en la capacidad operativa de los entes encargados de asegurar su cumplimiento.

Los recursos con los que cuentan los organismos de control en la ciudad para vigilar el uso adecuado del dinero público a nivel territorial son escasos en relación con el volumen y la complejidad de información generada diariamente a partir de los procesos de contratación estatal. Una primera versión de este trabajo es la base de un proyecto que desarrolla la Veeduría Distrital de Bogotá (2019) con el apoyo del Banco de Desarrollo para América Latina (CAF) a través del cual la entidad busca ejercer sus funciones de control preventivo mediante el uso de herramientas de análisis que permitan mejorar su capacidad de generar alertas tempranas.

Por lo anterior, el presente análisis se centra en la aplicación del modelo predictivo a la contratación pública de Bogotá como un primer ejemplo práctico de su efectividad, si bien la técnica es extrapolable a otro tipo de jurisdicciones territoriales u otras variables objetivo como sanciones fiscales, penales o disciplinarias asociadas a contratos estatales.

La Veeduría Distrital es una entidad única en su tipo en Colombia por dos razones: la primera, por ser un ente de control en el orden subnacional, perteneciente a la Administración Distrital de Bogotá pero independiente en sus decisiones y la segunda, por su misionalidad enfocada en el control preventivo, es decir, en la detección temprana de riesgos de corrupción o ineficiencias administrativas y presupuestales para evitar o mitigar sus efectos nocivos sobre el bienestar de la ciudadanía.⁷

La Veeduría Distrital es una de las entidades de menor tamaño en la Administración; su presupuesto anual asignado equivale al 0,1 % del presupuesto total de la ciudad, por lo cual la institucionalización de nuevas herramientas analíticas puede impactar de manera significativa la eficiencia en su procesos.

⁷La Veeduría Distrital es un ente de control que, de acuerdo con el artículo 17 del Acuerdo Distrital 24 de 1993, tiene entre sus funciones “*velar por la salvaguarda del patrimonio del Distrito, y por la correcta utilización del mismo*” y según el artículo 8 del mismo acuerdo debe además “*promover la ejecución pronta y oportuna de las políticas, planes, programas y proyectos trazados por la Administración en cumplimiento del Plan de Desarrollo y de los compromisos adquiridos con la comunidad*”.

En este sentido, el proyecto es un esfuerzo en la generación de capacidades en la gestión pública local a través del uso estratégico de datos abiertos y metodologías de análisis innovadoras basadas en Inteligencia Artificial.

El fortalecimiento institucional desde el orden subnacional puede además generar externalidades positivas, en la medida en que una mayor confianza en las instituciones es una condición necesaria para el desarrollo (Worthington, 1999) (Kaufmann, Kraay, y Mastruzzi, 1999) (Rodrick, Subramanian, y Trebbi, 2004), de hecho, autores como Clausen et al. (2011) han identificado la existencia de una relación negativa entre hechos probados de corrupción y la confianza de la ciudadanía en las instituciones.

2.3. Marco de análisis

Fenómenos como la ineficiencia en la contratación pública y la corrupción están asociados a una baja capacidad del Estado para vigilar el uso adecuado de los recursos públicos (Besley, 2006). Los contratos públicos son por definición incompletos en la medida en que existe información privada que condiciona la relación entre el principal (en este caso las entidades estatales) y los agentes (oferentes en procesos contractuales) (Tirole & Laffont, 1993), lo cual imposibilita que se contemplen todas las posibles contingencias durante su ejecución.

Estas asimetrías de información entre las entidades públicas del Estado y los oferentes en los procesos de contratación pública⁸ aumentan el riesgo de la provisión ineficiente de recursos públicos en un escenario en el que tanto los plazos de ejecución como el precio están fijados y existe incertidumbre sobre los costos asociados a la ejecución de los objetos contractuales (Baron & Besanko, 1987).

En este sentido, desde una perspectiva económica, es recomendable garantizar la competencia, para que sean las fuerzas del mercado las encargadas de regular las transacciones y asegurar eficiencia (Saussier & Tirole, 2015). La

⁸Los oferentes tienen mayor conocimiento acerca de los costos asociados a los servicios prestados y las condiciones del mercado que los gobiernos, a la vez que están sujetos a la incertidumbre provocada por regulación excesiva o conocimientos específicos sobre el funcionamiento de la administración pública.

Organización para la Cooperación y el Desarrollo Económicos (2016) identificó los principales riesgos a la integridad de los procesos contractuales en cada una de sus etapas, como es presentado en la figura 1.

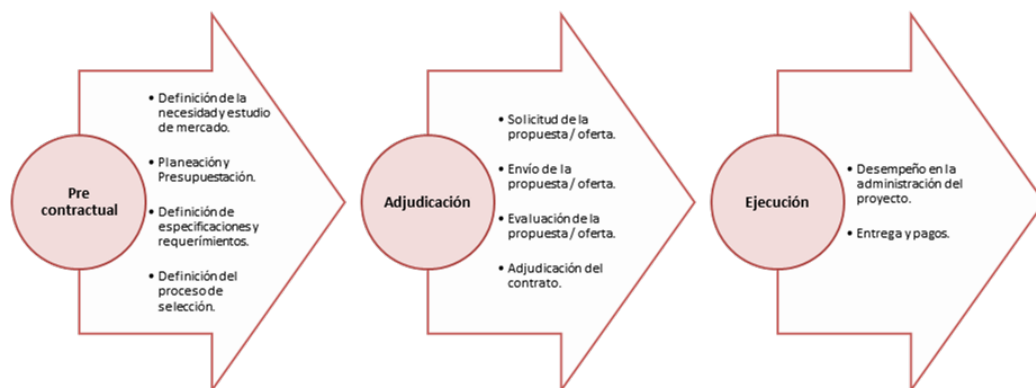


Figura 1: Riesgos de integridad en procesos contractuales

En primera instancia, la etapa pre contractual, se refiere al diseño del proceso de contratación y la definición de los productos que requiere la entidad estatal. En esta fase las fallas que pueden llevar a ineficiencia en la ejecución de los contratos están relacionadas con una mala definición de la necesidad, la asignación de recursos insuficientes para la provisión del servicio, requerimientos que no se ajustan a las capacidades de los proveedores o una mala elección del proceso de selección, así variables relacionadas con la cuantía de los contratos, el plazo y el periodo de ejecución y las modalidades de contratación a través de las cuales estos se suscriben pueden resultar ser relevantes en la aparición de ineficiencias.

En segunda instancia, en la etapa de adjudicación se concentra el proceso de solicitud, envío y evaluación de las propuestas. Esta elección de oferentes suele estar determinada tanto por los parámetros establecidos en las especificaciones de los procesos contractuales, como por otros factores subjetivos que influyen en la toma de decisiones de los evaluadores. Si estos factores de elección subjetiva limitan además la competencia en el mercado, la elección de los contratistas ganadores no responde a un criterio de eficiencia, razón por la cual su desempeño en la etapa de ejecución puede no ser el deseado.

Es así como en la última etapa, que corresponde a la ejecución del contrato, se materializan los riesgos previamente expuestos. Si bien durante el

diseño de los procesos contractuales se define una matriz de riesgos que recopila una serie de eventos previsible y asigna responsabilidades a las partes, es frecuente que se materialicen fallas que no pudieron ser tenidas en cuenta inicialmente y se traducen en ineficiencias que obligan a realizar adiciones al tiempo o al costo del bien o servicio. Al tratarse en este caso de un problema de información asimétrica entre los agentes y de incompatibilidad de incentivos, estas posibles fallas o riesgos no previsible no son observables.

En función de lo anterior, se toman como referencia para el entrenamiento del modelo las características observables de los contratos definidas en cada etapa del ciclo contractual conforme a la información disponible en la plataforma SECOP II, al tratarse de información estandarizada, confiable y disponible para todos los contratos analizados. De esta forma, el algoritmo es también capaz de establecer la importancia de las principales características relacionadas con el diseño y desarrollo de los contratos sobre la materialización de los riesgos de ineficiencia, que se manifiestan a través de la existencia de prórrogas o sobrecostos durante la etapa de ejecución.

3. Metodología

Este trabajo se enmarca en una literatura creciente sobre el uso de la ciencia de datos para el bienestar social. La disponibilidad de nuevas fuentes de datos y la mejora en la capacidad predictiva a través de la implementación de algoritmos de *machine learning* puede tener efectos importantes en la implementación de políticas públicas (Kleinberg et al. 2015); este tipo de técnicas se han probado efectivas en campos como la predicción del nivel socio económico de hogares en zonas de difícil acceso a través de su uso de teléfonos móviles (Blumenstock, Cadamuro, & On, 2015), la predicción de crimen en entornos urbanos (Bogomolov et al., 2014), riesgos de violencia en zonas de conflicto (Blair, Blattman, & Hartman, 2017), y la provisión de educación (Kotsiantis, 2012), salud (Kleinberg et al., 2015) y justicia (Kleinberg et al., 2018), entre otros.

De acuerdo con Géron (2017), el aprendizaje automático es la ciencia, o el arte, de programar computadoras de tal manera que estas puedan aprender

de los datos.⁹ De manera más general, es el campo de estudio que otorga a los computadores la habilidad de aprender sin ser explícitamente programados (Samuel, 1959).

Si bien los modelos estadísticos y el diseño de sistemas computacionales que dan origen a este campo de las ciencias de la computación se han desarrollado de manera continua desde mediados del siglo XX, han ganado popularidad de forma progresiva en los últimos años en la solución de problemas complejos en diferentes áreas tanto de la administración pública como del sector privado por dos razones fundamentales: de una parte, la mayor cantidad y calidad de datos disponibles, así como la mejora en la capacidad para su almacenamiento, y de otra parte, la mayor potencia de los sistemas informáticos modernos, que permite procesar dichos datos y convertirlos en información valiosa a través de la aplicación de estos algoritmos a un costo computacional relativamente bajo.

Siguiendo a Gallego et al. (2020), la aplicación efectiva de estas técnicas depende principalmente de dos factores: una fuente de información confiable, amplia y escalable y el uso adecuado de herramientas estadísticas que capturen patrones complejos en los datos. Aunque son pocos los antecedentes relacionados, el presente trabajo se enmarca en la literatura sobre el uso estratégico de datos de contratación pública y la implementación de modelos de Inteligencia Artificial para la detección temprana de ineficiencias y riesgos de corrupción. En el primer caso, se destaca el trabajo de Fazekas et al. (2020), que encuentran una relación causal negativa entre niveles altos de transparencia en la contratación pública, a través del uso de plataformas de *e-procurement*, y riesgos de corrupción.

En el segundo caso, se destacan trabajos que mediante el uso de algoritmos de *machine learning* detectan y analizan riesgos de corrupción e ineficiencia estatal a nivel municipal en Colombia (Gallego et al., 2020), Brasil (Colonnelli et al., 2020) y España (López – Iturriaga & Pastor Sanz, 2017), además del trabajo de Grace et al. (2016) que estudia casos de corrupción, fraude

⁹A continuación otra definición, más orientada a ingeniería, propuesta por (Mitchell, 1997): Se dice que un programa estadístico aprende de la experiencia E con respecto a alguna tarea T y una medida de desempeño P (en inglés, performance), si su desempeño en T, medido por P, mejora con la experiencia E.

y colusión en proyectos de desarrollo a nivel internacional ejecutados con recursos del Banco Mundial.

Este trabajo se diferencia de la literatura citada en la medida en que, en primer lugar, centra el análisis predictivo en la identificación temprana de riesgos de ineficiencias (o malgasto pasivo de recursos públicos), en segundo lugar, sustenta la implementación de este tipo de herramientas en un organismo de control encargado de auditar la contratación pública a nivel subnacional y en tercer lugar, el procesamiento de los datos, la construcción de variables de interés y el entrenamiento de los modelos se centran en el análisis de procesos cuyo objeto es la contratación y compra de bienes y servicios.

En el caso particular de la detección de ineficiencia en la contratación pública, la aplicación de estas herramientas es útil por dos razones principales: en primer lugar, por su capacidad de estimar el riesgo de que se generen prórrogas o sobrecostos a nivel de cada contrato con un alto grado de precisión, y en segundo lugar, por la posibilidad que ofrecen varios algoritmos de identificar patrones en los datos que permitan sustentar reformas institucionales a partir de la estimación del peso de cada variable disponible sobre la predicción de la condición de interés, en este caso, la existencia de adiciones en tiempo o en dinero sobre las condiciones inicialmente fijadas en los contratos.

El modelo entrenado se basa en un problema de clasificación binario, en el cual la variable objetivo es dicotómica, toma el valor de 1 en caso de que el contrato presente sobrecostos o prórrogas, y 0 en caso contrario. En la literatura de aprendizaje automático este tipo de problemas se clasifican en la categoría de aprendizaje supervisado, pues se basan en el uso de datos estructurados para estimar el valor de una variable conocida ([Conway & White, 2012](#)).

El flujo del proceso comienza con la recolección de información y la depuración de registros inconsistentes o irrelevantes, luego se llevó a cabo una selección inicial de los modelos que finalmente fueron entrenados. Los modelos elegidos son de diferente naturaleza: basados en árboles de decisión (Catboost, LightGBM, XGBoost y Gradient Boosting Machine), basados en regresiones (Ridge) y basados en métodos de prototipado (KNN) ([Hastie et](#)

al.).

La implementación de los modelos se dividió en tres pasos: En primer lugar, la información sobre los contratos se separó en dos grupos, el 70 % de los registros fueron utilizados para el entrenamiento de los algoritmos y el 30 % restante para probar su capacidad predictiva. En segundo lugar, se entrenaron los modelos a través de un proceso de validación cruzada con cinco iteraciones.¹⁰ En tercer lugar, los modelos fueron optimizados a partir del ajuste de sus hiperparámetros¹¹ para comparar su capacidad predictiva.

La competencia entre modelos arrojó que Catboost (Prokhorenkova et al., 2019) es el algoritmo más preciso en la identificación de contratos con potencial riesgo de presentar ineficiencias. Todo el proceso se desarrolló en Python, un lenguaje de programación interpretado, multiparadigma y de código abierto. Basar la infraestructura del modelo en Python, al tener una licencia de código abierto, reduce los costos de su puesta en producción por parte de la Veeduría Distrital u otras entidades del Sector Público o la academia.¹²

3.1. Datos

La información utilizada para alimentar los modelos y realizar la predicción proviene de la plataforma transaccional SECOP II,¹³ esta información es oficial y actualizada periódicamente por Colombia Compra Eficiente, agencia gubernamental encargada de monitorear la contratación pública en el país.

El Sistema Electrónico para la Contratación Pública (SECOP) fue creado por la Ley 1150 de 2007, como medio para canalizar el flujo de información sobre la contratación estatal en el país, tanto en el orden nacional como subnacional. SECOP está compuesto por tres plataformas; la primera fue

¹⁰*5-fold Cross Validation*. Es una técnica estadística que consiste en dividir aleatoriamente el conjunto de datos y realizar la evaluación para garantizar que el resultado es independiente de la partición de la base en datos entre entrenamiento y prueba.

¹¹Los hiperparámetros son parámetros ajustables que se definen antes del proceso de entrenamiento para generalizar patrones en los datos (Conway & White, 2012).

¹²El código en Python con el desarrollo del proyecto está disponible de manera pública en [Github](#).

¹³La información es publicada en el Portal de Datos Abiertos de Colombia datos.gov.co

SECOP I, una plataforma de información en la que las entidades consultan y registran información contractual, luego, con el Decreto 1082 de 2015 se creó SECOP II, plataforma transaccional en línea a la que se busca migrar la información contractual y la Tienda Virtual del Estado Colombiano, en la que se registran los procesos contractuales relacionados con mecanismos de agregación de demanda.

La plataforma SECOP I fue la primera diseñada por el Estado colombiano para promover la transparencia en la contratación pública, sin embargo, el reporte de la información era responsabilidad directa de cada una de las entidades del Estado; como solución a estas limitaciones y de la mano de la implementación de la estrategia *e-procurement*, se crea SECOP II en 2015, una versión actualizada que permite el cargue y diligenciamiento de la información en línea. El uso de este tipo de herramientas mejora la calidad y el volumen en el registro de los procesos, lo que a su vez reduce riesgos de corrupción (Fazekas, 2017). Si bien la incorporación de herramientas tecnológicas ha mejorado la calidad de la información disponible, la plataforma aun es propensa a contener errores de diligenciamiento, intencionales o no, que podrían afectar los resultados.

De otra parte, hay diferencias en las variables disponibles en las bases de datos publicadas en el Portal de Datos Abiertos de los procesos contractuales registrados en la plataforma SECOP I, procesos que tuvieron lugar entre 2011 y 2018, y la plataforma SECOP II, a la cual ha migrado la información reportada por las diferentes entidades de la Administración Distrital sobre nuevos procesos contractuales de manera progresiva. La calidad y disponibilidad de variables de análisis es una limitación a la capacidad predictiva del modelo.

En este caso, el modelo ha sido entrenado con base en la información reportada en la plataforma SECOP II por dos razones: en primer lugar, tiene un mayor número de variables de interés disponibles y menor cantidad de errores de diligenciamiento, que además son depurados de manera periódica, y en segundo lugar, si bien el volumen de información para el entrenamiento del modelo es en principio menor que la información disponible en SECOP I, es en esta plataforma en la que serán cargados los futuros contratos públicos a nivel nacional, lo cual mejora la viabilidad de su implementación en un escenario real.

De acuerdo con el interés del análisis y la información disponible en SECOP II, sólo se incluyen en el algoritmo los procesos contractuales correspondientes a la compra y contratación de bienes y servicios.¹⁴ En total, se cuenta con información sobre 8.635 contratos firmados por entidades de la Administración Distrital de Bogotá entre el 1 de enero de 2016 y el 6 de noviembre de 2020 con un valor total agregado de COP \$4.442 billones. Para cada contrato se dispuso de 42 variables que estaban disponibles de manera directa en la base de datos original o fueron construidas a partir de la información disponible, de estas, 27 son variables categóricas incluyendo la variable de resultado, 10 son variables numéricas y 5 son fechas; la descripción detallada de estas variables se presenta en el Anexo 1.

En relación a la variable de clasificación, existe un desbalance entre el número de contratos con adiciones y el número de contratos sin adiciones. Como se muestra en la tabla 1, del total de contratos el 23 % presentó algún tipo de prórroga o sobrecosto. Un factor relevante sobre la construcción de la variable objetivo es que, dado que las prórrogas o sobrecostos son eventos observados y documentados durante el proceso de ejecución de los contratos, no hay sesgos que se transmiten al modelo por una clasificación subjetiva, contrario por ejemplo a la medición de riesgo de corrupción, que depende especialmente del criterio y la capacidad de detección de los auditores.

Clasificación	Número de contratos	Porcentaje
Contratos sin adiciones	6.619	77 %
Contratos con adiciones	2.016	23 %
Total	8.635	100 %

Finalmente, vale la pena resaltar que las variables obtenidas para el entrenamiento del modelo cuentan con información de cada una de las etapas de los procesos contractuales expuestas en el marco de análisis, lo cual permite además identificar posibles cuellos de botella en cada una de estas con el fin de generar alertas tempranas y enfocar de manera más eficiente la acción de los organismos de control.

¹⁴Se excluyen los contratos relacionados con la contratación de Ordenes de Prestación de Servicios, pues corresponde al pago por servicios personales (capital humano) y no a la compra y contratación de bienes y servicios.

3.2. Selección de modelos y ajuste de métricas de desempeño

Existe una dicotomía entre el poder predictivo de los algoritmos de aprendizaje automático¹⁵ y su interpretabilidad (Hastie et al. 2001). Para obtener la mejor predicción posible sobre existencia de ineficiencias en la contratación pública de Bogotá, se compararon 5 modelos de clasificación evaluando su desempeño en las métricas de AUC, exactitud, precisión y sensibilidad, además del tiempo de entrenamiento, la definición formal de las métricas de desempeño se describe en el Anexo 2. El resumen de los resultados de la competencia entre modelos se describe en la sección 4 y se detalla en el Anexo 3.

Pese a las ventajas que traen consigo los modelos de aprendizaje automático, estos no están exentos de presentar retos en su aplicación, en este caso particular se destacan dos: por un lado, la calidad de la información disponible y por otro lado, el costo de oportunidad que existe entre maximizar la precisión del modelo (minimizar falsos positivos) y maximizar su sensibilidad (minimizar falsos negativos).¹⁶

La disyuntiva entre maximizar el grado de precisión que tiene el algoritmo para predecir correctamente los casos en los que se presenten adiciones, o reducir su sensibilidad a identificar como verdaderos casos en los que no se presentarán anomalías es un problema estadístico inherente a todas las aplicaciones de modelos de aprendizaje automático, y la elección entre cuál de los dos errores debe ser priorizado en su tratamiento depende del escenario sobre el cual se aplica el algoritmo.

Por un lado, un sistema de clasificación agresivo identificará un mayor número de contratos como potencialmente ineficientes, aumentando el número de falsos positivos (contratos clasificados como ineficientes, aunque no lo sean). Por otro lado, un sistema de clasificación más conservador detectará

¹⁵El poder predictivo aumenta por lo general en la medida en que los algoritmos son capaces de identificar patrones no lineales entre los predictores y las variables de interés.

¹⁶Estadísticamente, la precisión o especificidad del modelo es entendida como $VP / (VP + FP)$ y la sensibilidad como $VP / (VP + FN)$, donde TP es el número de verdaderos positivos, FP es el número de falsos positivos y FN es el número de falsos negativos; cabe destacar que como se evidencia en la definición matemática, se hace imposible reducir los dos problemas a la vez.

un menor número de contratos aumentando así el número de falsos negativos (contratos que presentarán ineficiencias, pero no son identificados por el modelo). Teniendo en cuenta que las entidades de control cuentan con recursos presupuestales y humanos escasos, se prioriza en este caso minimizar el número de falsos positivos con un clasificador conservador que identifique como potencialmente ineficientes un menor número de contratos, pero con un mayor grado de precisión.¹⁷

En el caso particular de la detección de casos de ineficiencia en la contratación pública con base en la existencia de sobrecostos o prórrogas, existe un reto adicional para la predicción dado por el desbalance del número de observaciones en los dos resultados posibles de la variable de interés, pues el número de contratos sin ineficiencias supera ampliamente en número a aquellos en los que estas se presentan. Así, un modelo con un alto grado de exactitud, esto es, con un alto nivel de acierto en el valor real de la variable de interés, puede tener un nivel de precisión bajo al clasificar de manera correcta principalmente a los contratos que no tienen adiciones.

Para medir la robustez de los algoritmos al efecto del desbalance entre clases, la predicción se optimizó mediante el uso de SMOTE ([Chawla et al., 2002](#)) una técnica que consiste en aumentar la representación de la clase subrepresentada, que en la mayoría de los casos, entre los que se incluye este trabajo, es la clase más relevante. Adicionalmente, los hiperparámetros del modelo fueron calibrados teniendo como función objetivo maximizar la precisión de la predicción, o lo que es igual, minimizar el número de falsos positivos.

¹⁷En el caso particular sobre el cual se aplica el modelo expuesto, la auditoría a la contratación pública es costosa debido a una limitada capacidad operativa frente a un alto volumen de procesos contractuales. En otros casos, en los cuales se cuenta institucionalmente con mecanismos costo-efectivos de disuasión, la minimización de falsos negativos puede ser un enfoque preferible.

4. Resultados

4.1. Ajuste del modelo

Siguiendo el procedimiento descrito en la sección 3, se entrenaron 5 modelos utilizados comúnmente en problemas de clasificación con aprendizaje supervisado (Hastie et al. 2001), tras la competencia se obtuvo como resultado que CatBoost (Prokhorenkova et al., 2019) tuvo el mejor desempeño en términos de precisión, la métrica de mayor interés en este caso al estimar la relevancia de la medición sobre la clase positiva, es decir, sobre la existencia de adiciones.

CatBoost se ha consolidado en los últimos años como uno de los modelos más populares y eficientes en la solución de problemas de aprendizaje automático con datos estructurados. El modelo está construido a partir de un ensamblaje de árboles de decisión basado en máquinas potenciadoras de gradiente (GBM),¹⁸ que a diferencia de otros modelos que parten de la misma lógica en su concepción como AdaBoost (Freund & Schapire, 1997), XGBoost (Chen & Guestrin, 2016) y LightGBM (Ke et al., 2017), es más eficiente en la predicción de problemas de clasificación binaria cuando la mayor parte de las covariables son categóricas y requiere configurar pocos hiperparámetros, reduciendo la posibilidad de que exista sobreajuste.

Los modelos basados en GBM son ampliamente utilizados tanto en la industria como en la academia; el ensamblaje de los predictores *débiles*¹⁹ para la construcción de CatBoost se realiza a través de la aplicación de una técnica conocida como boosting, la cual consiste en entrenar secuencialmente el modelo y tras cada iteración aumentar el peso de las predicciones incorrectas, lo cual obliga a cada clasificador adicional a minimizar el error esperado.

¹⁸Los modelos GBM utilizan como técnica de aprendizaje automático la minimización de la función de costo, es decir, de la diferencia entre el valor estimado y el valor real de una función, a lo cual se le conoce como método de gradiente descendente, estos están además respaldados por evidencia teórica que muestra como predictores poderosos pueden construirse a través de la combinación de predictores *débiles* (Hastie et al. 2001).

¹⁹Los predictores *débiles* son entendidos en este contexto como predictores con bajo nivel de exactitud en su capacidad predictiva, el ensamblaje parte del supuesto de que a menor exactitud hay menor correlación entre los resultados, por lo cual su combinación debe traducirse en una mejor predicción.

Una ventaja adicional de estos algoritmos, es que permiten identificar relaciones no lineales entre variables que no son observables en modelos más parsimoniosos como las regresiones Lasso o Ridge. Si bien esto hace que la capacidad de interpretación de los resultados obtenidos en la predicción sea más compleja, existen técnicas de análisis como SHAP (Lundberg & Lee, 2017) que permiten tener una aproximación al peso de cada una de las variables incorporadas en modelos construidos a partir de datos estructurados.

La tabla 2 compara en detalle el desempeño de los modelos. La precisión de los modelos es el parámetro de mayor relevancia en la predicción; los algoritmos fueron optimizados para clasificar de manera correcta contratos que presentarán sobrecostos o prórrogas buscando minimizar el coste de la revisión por parte de las entidades de control con recursos escasos.²⁰

Una revisión del desempeño general de los modelos luego de la optimización de los hiperparámetros evidencia un grado de precisión superior al 89 % en todos los modelos basados en árboles de decisión. Así mismo, los modelos basados en árboles de decisión también tienen un desempeño destacado en AUC (por encima del 85 %), esta métrica es importante en modelos de clasificación binaria en la medida que permite medir de forma agregada el desempeño del modelo sobre todos los posibles umbrales de clasificación.

Modelo	Exactitud	AUC	Precisión	Exhaustividad
CatBoost	0,820	0,874	0,922	0,252
LightGBM	0,856	0,911	0,917	0,421
GBM	0,813	0,865	0,895	0,226
Ridge	0,846	0,699	0,834	0,424
KNN	0,768	0,736	0,512	0,214

A través de la construcción de los algoritmos se obtuvo un grado de precisión en la predicción usando CatBoost (Prokhorenkova et al., 2019) de 0,92, un AUC de 0,87 y un nivel de exactitud de 0,82. Esto quiere decir que de cada 100 contratos analizados por el modelo, 82 son clasificados correctamente, y que de cada 100 contratos analizados que en un futuro tendrán algún tipo de

²⁰Para una definición detallada de los hiperparámetros del modelo elegido, ver (Prokhorenkova et al. 2019)

prorroga o sobre costo, 92 son clasificados correctamente y entregados como insumo para la revisión de profesionales expertos en la generación de alertas preventivas.

CatBoost comparte con LightGBM y la Máquina Potenciadora de Gradiente tradicional (GBM) ser un modelo basado en el ensamblaje de predictores *débiles*, en el caso de estos modelos, árboles de decisión, y se diferencia de estos en la medida en que prioriza la clasificación de variables categóricas, y está diseñado para reducir el riesgo de sobre estimación, lo cual hace menos probable que el entrenamiento del modelo sesgue sus resultados y reduzca su desempeño al ser implementado en datos desconocidos.

Para testear la robustez de los resultados principales, se utilizó SMOTE (Chawla et al., 2002) con el fin de controlar el posible efecto del desbalance entre clases. Los resultados muestran que el desempeño entre modelos no está mediado por la diferencia entre el número de contratos con y sin adiciones en la muestra,²¹ como se muestra en la tabla 3.

Modelo	Exactitud	AUC	Precisión	Exhaustividad
CatBoost	0,863	0,908	0,769	0,586
LightGBM	0,860	0,904	0,795	0,534
GBC	0,864	0,903	0,783	0,571
Ridge	0,841	0,796	0,642	0,712
KNN	0,684	0,730	0,379	0,571

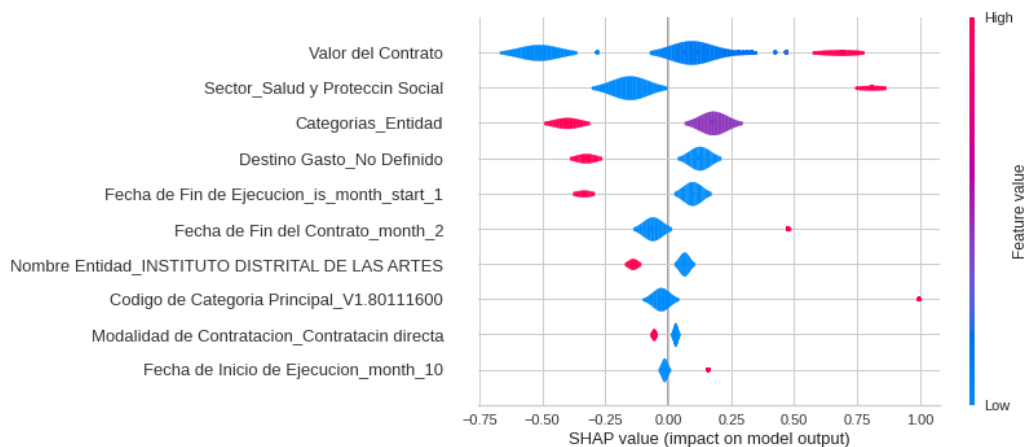
4.2. Importancia de variables

Las máquinas potenciadoras de gradiente (GBM) no son fácilmente interpretables al ser modelos no paramétricos. Sin embargo, es posible tener una aproximación al peso de cada una de las variables incorporadas en los modelos a través de la aplicación de algoritmos como SHAP (Lundberg Lee, 2017), que se ha consolidado como el método más confiable para hacer interpretaciones de modelos complejos con datos estructurados.

²¹Los resultados con el balance de muestra presentan una mejora en términos de exhaustividad frente al modelo original, sin embargo, como fue explicado con anterioridad, en este caso se busca optimizar la precisión en la predicción.

En la figura 2, se presenta la interpretación de las variables más importantes en la predicción de CatBoost a partir del peso de cada una de las observaciones sobre la variable objetivo. En el eje horizontal se representa la magnitud del impacto promedio de cada variable sobre la variable objetivo, así, más observaciones cercanas a 1 denotan un mayor peso de la variable en cuestión sobre la existencia de ineficiencias. Los puntos rojos representan contratos con los valores más altos en cada una de las variables, mientras que los puntos azules representan los contratos con los valores más bajos; en el eje vertical se presentan las variables de mayor importancia en la predicción en orden jerárquico.

Figura 2: Importancia de las variables en la predicción de CatBoost



El modelo identifica el valor de los contratos como la variable de mayor importancia en la predicción de ineficiencias; la relación es directamente proporcional en la medida en que los contratos de mayor valor tienen mayor probabilidad de presentar sobrecostos o prórrogas. Los contratos de mayor valor, en general, corresponden a la contratación de servicios u obras de alta complejidad que requieren además de mayor tiempo de ejecución, lo cual aumenta el riesgo de que se presenten imprevistos y justifica la importancia de contar con mecanismos de vigilancia e interventoría diferenciales.

La segunda variable de mayor importancia en la predicción son los contratos del Sector Salud y Protección Social. Los registros del sector en SECOP II corresponden principalmente a contratos de las Subredes Integradas de Salud, entidades que luego de la reforma al sistema de salud en la ciudad

administran la red de hospitales públicos y que por su naturaleza no están obligadas a cumplir con el Estatuto General de Contratación, por lo cual aplican a sus procesos de compra normas comerciales bajo el amparo del Régimen Especial.

Un caso similar al de las entidades del Sector Salud, es el del Instituto Distrital de las Artes, que hace uso de la figura del Régimen Especial para la contratación de servicios culturales, en la mayoría de los casos, convenios de asociación con organizaciones del sector privado. Como soporte de este resultado, se ha evidenciado que el uso del Régimen Especial de contratación en Colombia está asociado a restricciones a la competencia (Zuleta et al., 2019).

En tercer lugar se encuentra el número de categorías diferentes contratadas por cada entidad de acuerdo con el Código Estándar de Productos y Servicios de Naciones Unidas. Así, las entidades con mayor variedad en los bienes y servicios contratados presentan menor probabilidad de registrar adiciones, mientras que aquellas que concentran su contratación en características más homogéneas suelen ser más ineficientes. La variedad en las categorías de contratación puede estar relacionada con el tamaño de las entidades (entidades más pequeñas contratan servicios de menor complejidad y más homogéneos) o la naturaleza de su misionalidad (entidades ejecutoras de políticas públicas o cabezas de sector tienen una contratación más compleja y dinámica).

En cuarto lugar se encuentra una relación negativa entre los contratos cuyo destino de gasto no está definido y las adiciones. El gasto público puede clasificarse en gastos de funcionamiento y gastos de inversión, sin embargo, el 28% de los contratos registrados en SECOP usados en el modelo no tenían un destino de gasto definido, lo cual es un indicador de la calidad de la información y está asociada principalmente al subregistro existente en la información de los procesos contractuales.

En el quinto, sexto y décimo lugar se encuentran variables relacionadas con la periodicidad de la contratación pública. La ejecución del gasto en Bogotá está sujeta a las vigencias presupuestales, esto implica que el presupuesto en la ciudad comienza a ejecutarse en enero y debe estar comprometido en su totalidad en diciembre, producto de esto, el último trimestre de cada año suele ser más dinámico en términos de ejecución presupuestal y en ocasiones

la contratación de bienes y servicios excede el criterio de la anualidad. Por lo anterior, los contratos finalizados en enero y febrero, o iniciados en octubre tienen un peso importante sobre la predicción; en este caso, las ineficiencias pueden estar relacionadas con una mala planeación presupuestal que no prevee los tiempos necesarios para la correcta ejecución de los contratos debido a la presión que existe por ejecutar la totalidad del presupuesto anual.

En el octavo lugar se encuentran los contratos registrados en la categoría 801116 de las Naciones Unidas, que corresponde al suministro de personal temporal y trabajadores en misión, utilizada para la contratación de servicios especializados durante periodos específicos. Si bien esta categoría está tipificada como la adquisición de un servicio, está asociada a la contratación de personal y su efecto sobre las ineficiencias puede estar asociado a un uso indebido de la figura de contratación.

Finalmente, la contratación directa tiene también un peso importante sobre la predicción, si bien esta es una modalidad de contratación no competitiva y ha estado asociada a casos de ineficiencias por su uso inadecuado, como categoría general está asociada a la compra de bienes y servicios de baja complejidad y en la mayoría de los casos, de entrega inmediata, por lo cual su relación con la existencia de prórrogas o sobrecostos es negativa.

Las anomalías documentadas en otras investigaciones asociadas al uso inadecuado de modalidades de contratación no competitivas pueden estar relacionadas con características relacionadas con la temporalidad o naturaleza del bien contratado, y de acuerdo con los resultados presentados, no son necesariamente generalizables a todos los contratos de este tipo. Esto es relevante en la medida en que la identificación temprana de ineficiencias a nivel contractual y patrones más específicos en su ocurrencia permite focalizar mejor los recursos de vigilancia y control.

En síntesis, de acuerdo con el diagnóstico del modelo, el peso de las variables sobre las adiciones no es exclusivo de una sola etapa del ciclo contractual y las ineficiencias pueden estar asociadas a fallas en la etapa de ejecución por contingencias relacionadas con la complejidad de los bienes o servicios contratados, asociadas al valor de los contratos, o a fallas de planeación, como la definición inadecuada del tiempo de ejecución, el uso indebido de modalidades de contratación o falta de competencia en el mercado.

Los resultados en la predicción de la importancia de variables son robustos a otras métricas comunes como el peso ponderado de cada variable y son consistentes al comparar los modelos basados en árboles de decisión, como queda evidenciado en el Anexo 3.

5. Conclusiones

Bandiera et al. (2009) sugieren que la mayor parte del malgasto de recursos públicos puede deberse a ineficiencias en la contratación pública, no a corrupción. La capacidad de vigilancia los recursos públicos es una condición necesaria para garantizar su ejecución eficiente; de acuerdo con Becker y Stigler (1974), la propensión a actuar indebidamente para los agentes aumenta con el monto en juego, la falta de controles y disminuye con el mayor castigo.

Si bien el presente análisis se centra en la detección de ineficiencias, en las cuales no hay un claro beneficiario (gasto pasivo) los resultados sugieren que fallas de coordinación o mala gestión pueden explicar al menos parcialmente la existencia de sobrecostos o prorrogas, que se traducen en un costo de oportunidad para la ciudadanía.

A nivel metodológico, la capacidad predictiva de los modelos es alta, si bien existen errores de clasificación, estos están dentro de los niveles normales de la aplicación de este tipo de algoritmos. Los modelos basados en árboles de decisión entrenados presentan un mejor desempeño que otro tipo de modelos, en particular CatBoost permite predecir de manera correcta la existencia de adiciones en 92 de cada 100 casos.

Los algoritmos son capaces además de encontrar patrones comunes entre las variables con mayor peso en la predicción de ineficiencias, que a su vez están distribuidas en todas las etapas del ciclo de contratación. En la etapa pre contractual, el uso indebido de la contratación mediante Régimen Especial es un factor relevante, particularmente en casos como el del Sector Salud y el Instituto Distrital de las Artes. Asimismo, la cantidad y naturaleza de las categorías de bienes y servicios que contratan las entidades también es relevante, una menor variedad de bienes y servicios contratados está asociada a mayor riesgo de ineficiencias, asimismo la contratación específica de servicios profesionales especializados está asociada a un mal uso de la figura que

deriva en sobrecostos y prórrogas.

En relación a la etapa de adjudicación, los algoritmos identifican mayor riesgo cuando esta tiene lugar en los últimos meses del año y puede estar asociada a fallas en la planeación de los procesos derivadas de la necesidad de ejecutar el presupuesto en su totalidad durante la vigencia.

Finalmente, el valor de los contratos tiene una relación directa con la existencia de ineficiencias lo cual puede estar mediado por la complejidad de los procesos, la poca capacidad de vigilancia sobre los mismos y la existencia de contingencias no previsibles.

El éxito en la aplicación del algoritmo en un escenario real depende en buena medida de la cantidad, calidad y oportunidad de la información para poder llevar a cabo un control preventivo efectivo sobre la contratación del distrito. El uso de software libre en el diseño y puesta en producción del algoritmo reduce los costos de su implementación, los entes de control cuentan con las herramientas computacionales necesarias para implementar este tipo de algoritmos, sin embargo, se hace necesario que la información a partir de la cual este sea implementado sea lo más completa posible.

Existen además otras dificultades operativas para generar capacidad dentro de las entidades públicas. En este caso particular, el proceso de legitimación del lenguaje científico en una comunidad esencialmente de abogados, expertos en la auditoría de procesos contractuales, puede incidir en su efectividad como insumo para la toma de decisiones. Es importante en este sentido que los algoritmos no sean vistos como cajas negras y se haga uso de las herramientas institucionales disponibles para impulsar una transformación cultural dentro de las entidades estatales que lleve a cambios generalizados.

Referencias

- Baron, D. P., & Besanko, D. (1987). Monitoring, Moral Hazard, Asymmetric Information and Risk Sharing in Procurement Contracting. *RAND Journal of Economics*, 18 (4), 509-532.
- Becker, G. S., & Stigler, G. J. (1974). Law Enforcement, Malfeasance, and Compensation of Enforcers. *Journal of Legal Studies* 3(1) enero, 1-18.
- BID. (2018). Mejor gasto para mejores vidas: Cómo América Latina y el Caribe puede hacer más con menos. Washington D.C.: Banco Interamericano de Desarrollo.
- Blair, R. A., Blattman, C., & Hartman, A. (2017). Predicting local violence: Evidence from a panel survey in Liberia. *Journal of Peace Research*, 54, 298-312.
- Blumenstock, J., Cadamuro, G., & On, R. (2015). Predicting Poverty and Wealth from Mobile Phone Metadata. *Science*, 350, 1073-1076.
- Bogomolov, A., Lepri, B., Staiano, J., Oliver, N., Pianesi, F., & Pentland, A. (2014). Once Upon a Crime: Towards Crime Prediction from Demographics and Mobile Data. *Proceedings of the 16th international conference on multimodal interaction*, 427-434.
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *arXiv:1603.02754*. doi:10.1145/2939672.2939785, 785-794.
- Contraloría General de la República. (2011). Informe de auditoría gubernamental con enfoque integral especial control excepcional a la fase III de Transmilenio. Bogotá.
- Conway, D., & White, J. M. (2012). *Machine Learning for Hackers*. O'Reilly.
- Fazekas, M. (2017). Assessing the Quality of Government at the Regional Level Using Public Procurement Data. WP 12/2017. Bruselas: European Commission, Directorate-General for Regional Policy.
- Fazekas, M. (2017). Red tape, bribery and government favouritism: evidence from Europe. *Crime, Law and Social Change*, (68)4.
- Freund, Y., & Schapire, R. (1997). A Decision - Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 119-139.
- Hastie, T., Tibshirani, R., & Friedman, J. (2001). *The Elements of Statistical Learning*, volume 1. New York: Springer series in statistics.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W. & Liu, T.-Y.

(2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. 31st Conference on Neural Information Processing Systems.

Melo, L. A., & Ramos, J. E. (2017). El gasto público en Colombia: Algunos aspectos sobre su tamaño, evolución y estructura. Borradores de Economía Banco de la República No.1003.

Open Contracting Partnership. (2016). Red Flags for Integrity: Giving the green light to open data solutions. Obtenido de <https://www.open-contracting.org/wp-content/uploads/2016/11/OCP2016-Red-flags-for-integrityshared-1.pdf>

Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2019). CatBoost: unbiased boosting with categorical features. 32nd Conference on Neural Information Processing Systems (NeurIPS 2018).

Tirole, J., & Laffont, J. J. (1993). A Theory of Incentives in Procurement and Regulation. Cambridge: MIT Press.

Veeduría Distrital. (2017). Análisis al régimen especial de contratación en el Distrito Capital.

6. Anexos

6.1. Anexo 1: Descripción de variables

Covariables			
<i>Variable</i>	<i>Etapa</i>	<i>Tipo</i>	<i>Descripción</i>
Nombre Entidad	Pre contractual	Categórica	Nombre de la entidad que publica el contrato
Sector	Pre contractual	Categórica	Sector entidad que publica el contrato
Rama	Pre contractual	Categórica	Rama del estado de la entidad que publica el contrato
Entidad Centralizada	Pre contractual	Categórica	Define si la entidad es descentralizada o centralizada
Código de Categoría Principal	Pre contractual	Categórica	Código UNSPSC de la categoría principal para el contrato
Tipo de Contrato	Pre contractual	Categórica	Tipo de contrato de acuerdo a su marco jurídico
Modalidad de Contratación	Pre contractual	Categórica	Modalidad de contratación de acuerdo al modelo de selección
Fecha de Inicio del Contrato	Pre contractual	Fecha	Fecha de inicio de las responsabilidades contractuales
Fecha de Fin del Contrato	Pre contractual	Fecha	Fecha de fin de las responsabilidades contractuales
Fecha de Inicio de Ejecución	Adjudicación	Fecha	Fecha de inicio de la ejecución de las actividades del contrato
Fecha de Fin de Ejecución	Ejecución	Fecha	Fecha de finalización de la ejecución de las actividades del contrato
Condiciones de Entrega	Pre contractual	Categórica	Fecha de fin de la ejecución de las actividades del contrato
Proveedor Adjudicado	Adjudicación	Categórica	Nombre del proveedor adjudicado
Es Grupo	Adjudicación	Categórica	Determina el proveedor es un grupo de entidades

Es Pyme	Adjudicación	Categorica	Determina si el proveedor se registro como pequeña empresa
Habilita Pago Adelantado	Pre contractual	Categorica	Determina si el contrato tiene habilitada la opción de pago de adelantos
Liquidación	Pre contractual	Categorica	Determina si el contrato ha sido liquidado
Obligación Ambiental	Pre contractual	Categorica	Determina si el contrato tiene compromisos de cumplimiento a obligaciones ambientales
Obligaciones Postconsumo	Pre contractual	Categorica	Determina si el contrato tiene compromisos de cumplimiento a obligaciones posteriores a la entrega del producto o prestación del servicios
Reversión	Pre contractual	Categorica	Determina si el contrato ha sido reversado
Valor del Contrato	Pre contractual	Numérica	Valor total del contrato
Destino Gasto	Pre contractual	Categorica	Destino del gasto, a nivel presupuestal
Origen de los Recursos	Pre contractual	Categorica	Origen de los Recursos, a nivel presupuestal
NIT	Adjudicación	Categorica	Numero de Identificación con el que figura el proveedor en SECOP II
Tipo Empresa	Adjudicación	Categorica	Tipo de Empresa que declara el proveedor al registrarse
Fecha Creación	Adjudicación	Fecha	Fecha en la que se hizo el primer registro del proveedor
País	Adjudicación	Categorica	País de origen del Proveedor
Departamento	Adjudicación	Categorica	En caso de Ser un proveedor colombiano, indica el departamento al que corresponde la ubicación principal del Proveedor

Municipio	Adjudicación	Categoría	En caso de Ser un proveedor colombiano, indica el Municipio al que corresponde la ubicación principal del Proveedor
Plazo Contrato	Pre contractual	Numérica	Tiempo transcurrido entre la fecha de firma del contrato y la fecha de finalización
Plazo Ejecución	Ejecución	Numérica	Tiempo transcurrido entre la fecha de inicio y la fecha de finalización de la ejecución
Tiempo Demora	Ejecución	Numérica	Diferencia entre la fecha de firma del contrato y la fecha de inicio de ejecución
Pendiente de ejecución	Ejecución	Numérica	Valor pendiente de ejecución a la fecha
Pendiente de amortización	Ejecución	Numérica	Valor pendiente de amortización a la fecha
Amortizado	Ejecución	Numérica	Valor amortizado a la fecha
Pagado	Ejecución	Numérica	Valor pagado a la fecha
Pendiente de pago	Ejecución	Numérica	Valor pendiente de pago a la fecha
Facturado	Ejecución	Numérica	Valor facturado a la fecha
Adelantado	Ejecución	Numérica	Valor del pago por adelantado
Categorías Entidad	Pre contractual	Numérica	Número de categorías diferentes de bienes y servicios contratadas por la entidad
Proveedores Entidad	Pre contractual	Numérica	Número de proveedores diferentes contratados por la entidad

6.2. Anexo 2: Métricas de desempeño

- **Exactitud:** Mide la proporción entre las predicciones correctas (Verdaderos Positivos (VP) y Verdaderos Negativos (VN)) y la suma de todas las predicciones hechas por el modelo: Falsos Positivos (FP), Falsos Negativos (FN), Verdaderos Positivos (VP) y Verdaderos Negativos (VN)

$$Exactitud = \frac{VP + VN}{VP + FP + VN + VP} \quad (1)$$

- **AUC (Area Under the Curve):** El área bajo la curva ROC (*Receiver Operating Characteristics Curve*) mide de manera agregada el desempeño del modelo sobre todos los umbrales de clasificación al comparar la tasa de verdaderos positivos con la tasa de falsos positivos. La escala de medición está entre 1 (cuando las predicciones son totalmente acertadas) y 0 (cuando las predicciones son totalmente erróneas)

$$Tasa\ de\ verdaderos\ positivos = \frac{VP}{VP + FN} \quad (2)$$

$$Tasa\ de\ falsos\ positivos = \frac{FP}{FP + VN}$$

- **Precisión:** Es una medida de relevancia popular en problemas de clasificación binaria. Mide la proporción de casos correctamente identificados como casos positivos (verdaderos positivos), con respecto al total de casos positivos identificados (verdaderos positivos y falsos positivos).

$$Precisión = \frac{VP}{VP + FP} \quad (3)$$

- **Sensibilidad:** Es una medida de relevancia popular en problemas de clasificación binaria. Mide la proporción de casos correctamente identificados como casos positivos (verdaderos positivos), con respecto al total de casos positivos reales (verdaderos positivos y falsos negativos).

$$\textit{Sensibilidad} = \frac{VP}{VP + FN} \quad (4)$$

6.3. Anexo 3: Gráficas adicionales

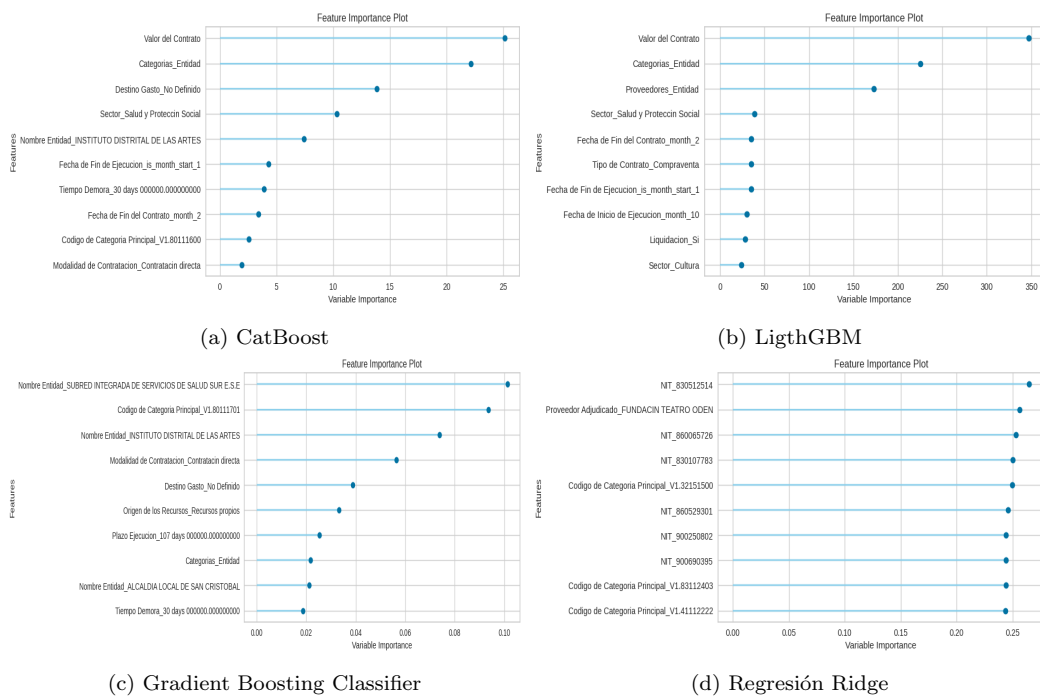


Figura 3: Importancia de variables

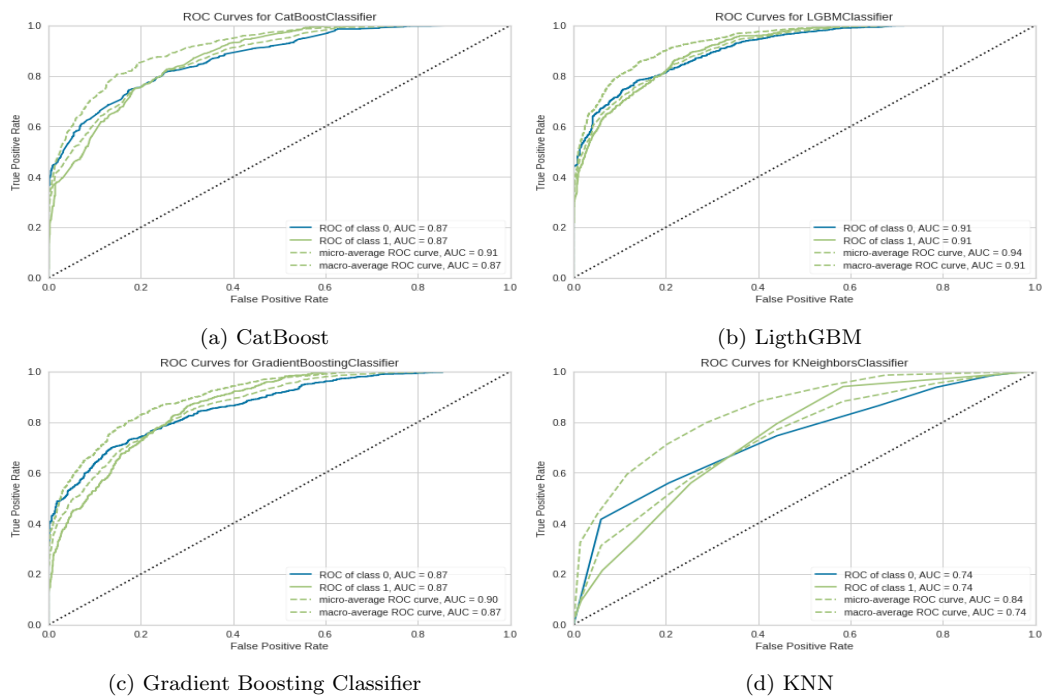


Figura 4: Área Bajo la Curva ROC - AUC

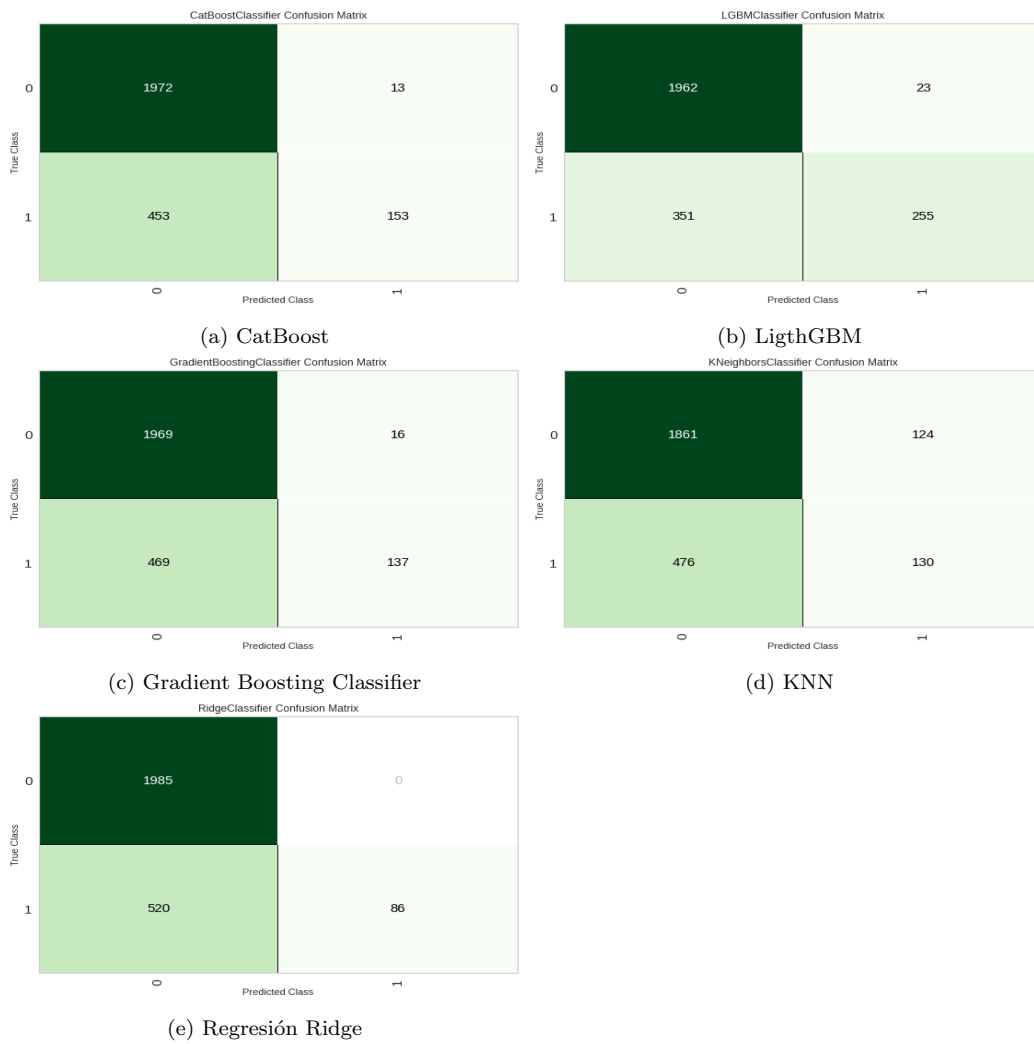





Figura 5: Matriz de confusión




(a) CatBoost




(b) LigthGBM



(c) Gradient Boosting Classifier




(d) KNN




(e) Regresión Ridge


Figura 6: Curva de Precisión - Sensibilidad




(a) Threshold



(b) Curva de calibración



(c) Curva de aprendizaje



(d) Curva de validación

Figura 7: Desempeño de CatBoost