



CIES
consorcio de investigación
económica y social

Construyendo conocimiento para mejores políticas



Universidad Nacional Mayor de
SAN MARCOS
Universidad del Perú. Decana de América.

XVI Concurso
Anual de
Investigación
CIES 2019

¿Focalizar para mejorar? Un análisis de las políticas y esquemas de incentivos de atracción docente en el Perú

Antonio Campos ●

Jesús Gutierrez ●

Con el apoyo de



PERÚ

Ministerio
de Economía y Finanzas

Índice

1. Introducción	4
2. Revisión de literatura	7
3. Ley de la Reforma Magisterial	10
4. Datos	18
4.1. Indicadores y fuentes de información.....	19
4.2. Estadísticos descriptivos.....	23
5. Metodología	25
5.1. Métodos predictivos	26
5.1.1. <i>Modelo base</i>	27
5.1.2. <i>Least Absolute Shrinkage and Selection Operator</i>	28
5.1.3. <i>Random Forests</i>	29
5.1.4. <i>Light Gradient Boosting</i>	30
5.2. Implementación de los métodos predictivos	32
5.3. Métodos de conglomerados	34
6. Estimaciones de los modelos predictivos	35
6.1. Calidad predictiva de los métodos implementados	35
6.2. Principales predictores.....	40
6.3. Predicción de los modelos	43
6.4. Análisis de conglomerados.....	45
7. Análisis y recomendaciones de las políticas enfocadas en la atracción docente	51
7.1. Políticas en el contexto internacional	52
7.1.1. <i>Incentivos Monetarios</i>	53
7.1.2. <i>Incentivos no monetarios y estrategias informativas</i>	55

7.2. Políticas en el contexto nacional	56
7.2.1. <i>Políticas de corto plazo</i>	56
7.2.2. <i>Políticas de largo plazo</i>	70
7.2.3. <i>Focalización de incentivos: La gradiente de ruralidad</i>	74
8. Comentarios finales	75
Bibliografía.....	81

Introducción

La calidad docente es uno de los principales determinantes de la calidad educativa y, a través de esta, de la mejora de los resultados educativos (Chetty et al., 2014; Hanushek 2002, 2010). Siguiendo esta idea, el Ministerio de Educación (MINEDU) viene promoviendo, desde el año 2012, la Carrera Pública Magisterial (CPM) en el marco de la Ley de Reforma Magisterial (LRM); con ello busca, específicamente, impulsar la Política Integral de Desarrollo Docente como uno de sus ejes prioritarios de política.

Así, en el marco de la LRM, existen concursos de nombramiento pensados para que los docentes tengan la posibilidad de acceder a plazas de escuelas públicas de manera permanente con todos los beneficios propios de la CPM. Si bien existe una alta valoración respecto a la posibilidad de acceder a la CPM¹, si analizamos los concursos de nombramiento entre los años 2015-201 nos encontramos con que existen plazas desiertas (no ganadoras) de manera recurrente entre concursos.

Para tener una idea de la magnitud de esta problemática, en los últimos tres concursos solo dos regiones lograron ocupar más del 50% de las plazas que ofertaron en cada concurso. Pero la cifra se hace más dramática si se analizan regiones específicas como Loreto, donde ni siquiera el 7% de las plazas ofertadas son otorgadas en cada concurso (ver Anexo 1)². Incluso si analizamos regiones como Lima Metropolitana, el histórico del otorgamiento de plazas está por debajo del 65%, lo que sugiere que existen factores inherentes a la escuela más allá de las características regionales analizados en estudios previos (Bertoni et al., 2019, Jaramillo, 2013).

Esto nos lleva a cuestionar la existencia de una política de oferta de plazas y, más aún, si existen adecuados esquemas de incentivos para atraer y retener docentes a la CPM. El

¹ En una encuesta realizada en el Concurso de Nombramiento 2015, las 2 principales razones por las cuales postulan a la CPM fueron: la estabilidad laboral (50.9% de docentes) y el acceso a posibilidades de ascenso, capacitación y mayores oportunidades (59% de docentes).

² Asimismo, si se analizan a nivel de plazas existen 4,153 escuelas cuyas plazas han sido ofertadas en todos los concursos desde el año 2015.

presente trabajo se plantea la siguiente pregunta: ¿Se pueden (re)plantear los esfuerzos de atracción docente atendiendo las necesidades y heterogeneidades de las escuelas a partir de una adecuada focalización? A partir de esta pregunta surgen otras dudas adicionales: ¿Cuáles son las principales características que ayudan a predecir que una plaza sea otorgada?; ¿cuáles son las escuelas que tienen menos capacidad de atracción docente en el territorio nacional?; ¿las actuales políticas de incentivos brindados por el MINEDU están alineadas a dichas características?; ¿existen otras políticas que sean más idóneas para dicha heterogeneidad?

Si bien existen estudios sobre la demanda de plazas a través de las preferencias de los docentes, no existen estudios que permitan analizar la dinámica generada a partir de la oferta y la demanda de plazas en el sistema educativo. Asimismo, tampoco existe una clasificación o tipología de plazas que permita generar políticas diferenciadas por la heterogeneidad ni focalizar esfuerzos por en poblaciones específicas. Es por ello que las principales acciones implementadas por el MINEDU son homogéneas y nacionales, motivo por el cual les resulta difícil alcanzar los objetivos planteados.

De esta manera, por ejemplo, una de las principales políticas para la atracción de los docentes es el Bono de Atracción Docente (BAD). Dicho bono ofrece 18,000 soles en tres años para los docentes que ingresen en el tercio superior de cada Concurso de Nombramiento. No obstante, el mismo diseño conlleva a que los docentes ganadores del BAD se centren en zonas urbanas con alta demanda y de baja rotación, lo que lo hace sub-óptimo para responder a la problemática existente³.

Otras políticas que buscan mejorar la atracción y retención docente son las Asignaciones Temporales (por ruralidad, bilingüe, entre otros). Sin embargo, estas no incentivan la atracción

³ Como se describirá más adelante, los Concursos de Nombramiento Docente son centralizados, por lo que los docentes que ocupen los primeros puestos suelen ubicarse en escuelas con mejores condiciones y predominantemente urbanas.

de los docentes nombrados toda vez que la importancia relativa de la asignación temporal decrece a medida que se incrementa la remuneración del docente nombrado.

Por ello, el objetivo del presente estudio es generar una tipología de plazas de modo que, a partir de esta, se pueda proponer recomendaciones que permitan rediseñar políticas y esquemas de incentivos de atracción docente. En consecuencia, los objetivos específicos propuestos son los siguientes:

(i) Análisis de la dinámica de oferta y demanda de plazas entre los concursos de nombramiento en la CPM. Esta permitirá conocer las principales características de las instituciones educativas (IIEE) con plazas adjudicadas en los concursos de nombramiento. Asimismo, la tipología de plazas estará alineada a su demanda real en cada uno de los concursos.

(ii) Análisis del diseño de las políticas y esquemas de incentivos de atracción docente implementadas por el MINEDU en base a la tipología de plazas propuesta por el estudio.

(iii) Mapeo y revisión de aquellas políticas o esquemas de incentivos para atraer y retener docentes que hayan sido planteadas por la literatura nacional e internacional y que, a su vez, respondan a la tipología planteada y las principales características del análisis de oferta y demanda de plazas.

La hipótesis de la cual se parte es que no existe un esquema de incentivos adecuado que genere que las plazas ofertadas por el MINEDU sean atractivas de manera homogénea. Ello conduce a que existan plazas que no hayan podido ser ocupadas a pesar de ser ofertadas en los cuatro últimos concursos. Para ello, elaboramos una tipología de plazas a través de métodos de analítica avanzada que capturen la heterogeneidad de las mismas tanto interna como externamente. Además, esta tipología podrá generar un espacio para el diseño de políticas

enfocadas a la variación de algunas características que hagan que una plaza sea más atractiva para un docente.

La información que se utiliza para alimentar tales metodologías proviene de diversas fuentes. Entre ellas están los Concursos de Nombramiento, el Censo Escolar, el sistema de plazas docentes Nexus, el Censo de Población y Vivienda 2017, entre otras. De este modo, se capturan características intrínsecas de las plazas, así como del entorno que las rodean. Gracias a la variedad de fuentes de información, el presente estudio tendrá diversas contribuciones, siendo la principal, las recomendaciones de rediseño de políticas o esquemas de incentivos que puedan responder a la heterogeneidad de las plazas ofertadas a nivel nacional.

El resto del documento se organiza de la siguiente manera. La sección 2 muestra una breve revisión de literatura acerca de los determinantes para escoger una plaza por parte de los docentes. La sección 3 describe la ley de la reforma magisterial, el proceso de los concursos de nombramiento y muestra algunos estadísticos descriptivos de los últimos resultados de dichos concursos. La sección 4 presenta las fuentes de información, así como los principales indicadores mientras que la sección 5 describe los modelos de analítica avanzada que serán utilizados. La sección 6 muestra los principales resultados por modelo, además de una breve comparación entre los mismos. La sección 7 provee los análisis y recomendaciones de las políticas enfocadas en la atracción docente. Finalmente, la sección 8 cierra con los comentarios finales.

1. Revisión de Literatura

La LRM es una de las políticas más importantes y ambiciosas que se hayan implementadas en los últimos años por el Estado Peruano y, en particular, por el MINEDU. A pesar de su importancia política y presupuestal⁴, en los últimos concursos de nombramiento no

⁴ Para tener una idea de la relevancia presupuestal, el presupuesto de remuneraciones en el año 2020 estuvo en aproximadamente 5 mil millones de soles que, en términos reales, equivale al presupuesto anual asignado al Ministerio de Desarrollo e Inclusión Social.

se logra adjudicar ni siquiera el 30% de las plazas ofertadas a nivel nacional, lo que conlleva a que las plazas vacantes tengan que ser ocupadas por docentes contratados, quienes en su mayoría no han alcanzado el puntaje mínimo en la Prueba Única Nacional (PUN) o tampoco han rendido dicho examen (Bertini et al., 2019).

Este fenómeno en la CPM tiene efectos negativos directos sobre la calidad de la enseñanza en las aulas, pero también en las diferentes políticas que el MINEDU diseña e implementa. Tener docentes contratados en lugar de nombrados, conlleva a una alta rotación de docentes y, entre otros aspectos, no permite invertir de manera sostenible en ellos, siendo el caso más representativo las políticas de formación en servicio⁵. Asimismo, la literatura educativa reconoce que la presencia de docentes contratados ocupando el puesto de docentes nombrados tiene impactos negativos en los aprendizajes de los estudiantes (Ayala y Sánchez, 2017⁶; Marotta, 2019).

Si bien el presente estudio busca modelar la probabilidad de que una determinada plaza sea elegida, tanto la literatura nacional como internacional es muy limitada al respecto. Sin embargo, existen estudios que explican las preferencias de los docentes y qué variables juegan un rol clave al momento de decidir en dónde trabajar.

Por ejemplo, Loeb, Kalogrides y Béteille (2012) utilizaron métodos de valor agregado (*value-added*) para evaluar la relación entre la efectividad escolar y el reclutamiento y retención de docentes en Estados Unidos. Así, ellos encuentran que las escuelas con mayor efectividad (definido como logros de aprendizaje) son más atractivas y, por ende, contratan a los mejores docentes. Asimismo, un estudio reciente muestra que el acceso a seguros de salud subsidiados

⁵ La literatura en educación indica que los programas de formación en servicio tales como los Acompañamiento Pedagógico requieren un periodo de exposición para ser efectivos, pero ante la alta rotación de docentes contratados, la intervención no se implementa adecuadamente.

⁶ Ayala y Sánchez (2017) encuentran que un aumento en una desviación estándar en la proporción de docentes provisionales en secundaria en el establecimiento educativo disminuye en 0.26 desviaciones estándar el puntaje promedio en Saber 11.

y pagos en función del desempeño también serían claves al momento de reclutar y retener docentes (Johnston, 2020).

Por su parte, Bonhomme, Jolivet y Leuven (2016) exploran características de las escuelas que pueden afectar la utilidad de los docentes en los Países Bajos. Estos autores encuentran que la proporción de alumnos en condición de vulnerabilidad, la ratio de alumnos por docente, la jornada laboral y el personal de apoyo pedagógico determinan la elección del lugar donde el docente decide enseñar. Asimismo, Rosa (2019) presenta evidencia de que las elecciones de los docentes guardan relación con la ubicación de las escuelas, el nivel socioeconómico y la presencia de esquemas de atracción como la entrega de incentivos monetarios.

En Perú existen tres estudios que abordan la problemática descrita, y lo hacen también desde la perspectiva de la demanda (preferencias de los docentes). Por un lado, Jaramillo (2013) analiza los mercados laborales docentes para identificar las características que determinan su primer trabajo, y encuentra que la distancia al lugar de nacimiento y el haberse graduado de una institución de la misma región son las de mayor consideración. Por otro lado, Bertoni et al. (2019) analizan las preferencias en la elección de plazas docentes en el marco de los concursos de nombramiento docente 2015, encontrando resultados muy similares pero que permiten discriminar por atributos de los docentes: la proximidad a la institución de estudio es más relevante para mujeres, mientras que localidades urbanas son más relevantes para docentes de mayor desempeño y de mayor edad.

Recientemente, Ajzenman et al. (2020) evaluaron de manera experimental dos programas gubernamentales enfocados en los docentes. La idea detrás era motivar a los docentes, ya sea de manera intrínseca (altruismo) o extrínseca (incentivo monetario), para que elijan enseñar en una escuela en situación de vulnerabilidad. Los autores muestran que ambos

canales incrementan la probabilidad de que se postulen a dichas escuelas y de llegar a la etapa final en la selección de dichas plazas.

Si bien es interesante abordar los aspectos de la demanda a través de las preferencias de los docentes, poco o nada se ha estudiado la oferta como tal. Peor aún, actualmente, no existe un estudio que analice la dinámica de la oferta y demanda a partir de las características de las plazas ofertadas y que brinde mayor oportunidad de generar políticas educativas en el margen de maniobra del MINEDU. Es así que, desde un análisis de demanda, no es posible explicar la falta de adjudicación de plazas que tiene Lima Metropolitana o el Callao (en el último concurso, entre 45% y 33%, respectivamente).

Por ello, el presente estudio plantea proponer recomendaciones de política enfocadas a grupos de plazas específicos. De este modo, se podría rediseñar las políticas de atracción y asignación de docentes a las escuelas donde más se les necesita, respondiendo así a la heterogeneidad de plazas.

2. Ley de la Reforma Magisterial

En el 2007, se aprobó la Ley de la Carrera Pública Magisterial, que luego, en 2012, se convirtió en la Ley de la Reforma Magisterial (Ley N° 29944). Esta legislación promueve el desarrollo profesional de los docentes, estableciendo criterios de selección y promoción en la carrera pública basados en el desempeño y la evaluación permanente. De este modo, se coloca como eje fundamental del servicio educativo el mérito y desempeño del docente para avanzar en su carrera (Ñopo y Díaz, 2016). A través de estrategias de atracción, reconocimiento y retención de los mejores docentes en el sistema educativo público, el MINEDU busca mejorar la calidad del servicio educativo con la finalidad de mejorar los resultados de aprendizajes de los estudiantes.

En el marco de la LRM, tanto el ingreso como la permanencia en la CPM se rige a través de distintas evaluaciones que rinden los docentes. En primera instancia, se tiene el concurso de

nombramiento, el cual sirve para el ingreso a la carrera. A la fecha, se han desarrollado cuatro concursos en los años 2015, 2017, 2018 y 2019. En la siguiente sección se detallará más al respecto de esta evaluación. La segunda evaluación es el concurso de ascenso. Esta evaluación sirve para que los docentes puedan escalar en la carrera. De este modo, cuando un docente ingresa en la carrera, automáticamente está en la primera escala, teniendo que rendir evaluaciones para poder subir en ella.

La tercera evaluación es la de acceso a cargos directivos, el cual está dirigido a docentes nombrados en tercera escala o escalas superiores que busquen ocupar un cargo directivo. Actualmente, se cuenta con alrededor de 26 mil directivos a nivel nacional, la mayoría en las escalas 3 y 4. Finalmente, se tiene la evaluación de desempeño docente. Esta evaluación está dirigida a todos los docentes que formen parte de la CPM y busca contribuir con su formación. La idea es identificar espacios de mejora en la labor docente y proponer estrategias que los ayuden a mejorarlos.

Las cuatro evaluaciones cumplen un rol muy importante dentro de la CPM. No solo se busca que ingresen los mejores docentes, sino también que estos se capaciten durante su permanencia en la carrera y sean recompensados por ello. Sin embargo, una característica del cuerpo docente en el sistema educativo público es que está compuesto por una gran proporción de docentes contratados. Para el 2019, el 39% de docentes eran contratados (140 mil aproximadamente).

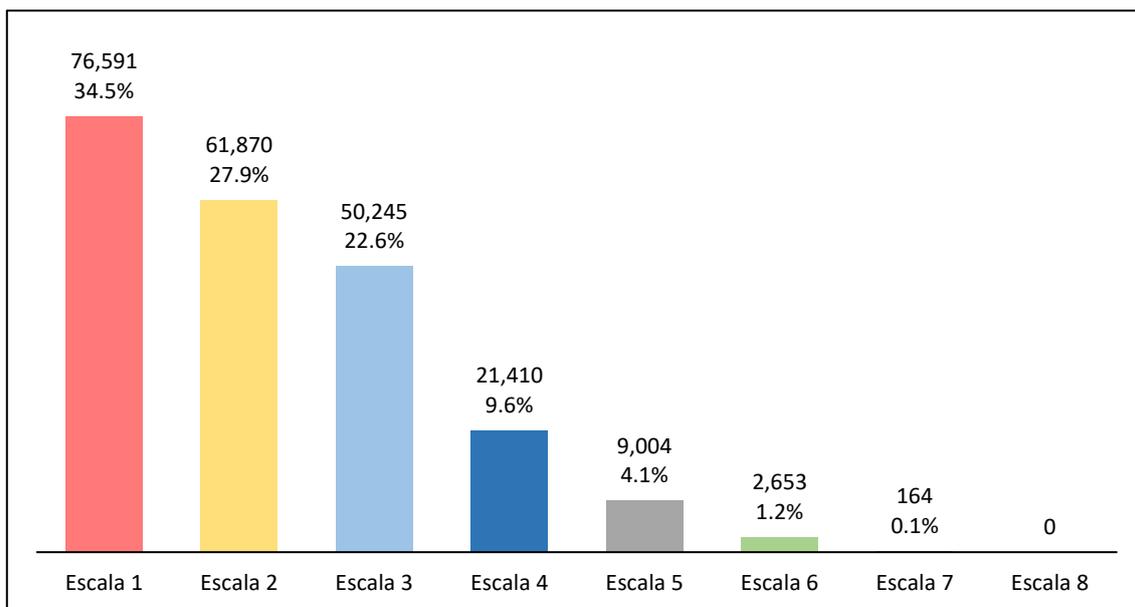
Si bien el ingreso a la CPM es bastante difícil, el ascenso durante la misma también lo es. En el Gráfico 1 se muestra la distribución de plazas nombradas según la escala remunerativa de los docentes. Como se observa, hacia el 2019 el 85% de los docentes se concentraba en las tres primeras escalas; mientras que, en la escala más alta, todavía no se tenía docentes⁷.

⁷ Esto se debe, principalmente, debido a la estructura y los requerimientos mínimos para ascender entre escalas. Por ejemplo, para llegar a la escala más alta, en promedio, un docente debe tener acumulados más de 15 años de experiencia.

Claramente, tener un sistema bastante exigente requiere de altos incentivos para que los docentes permanezcan motivados. No obstante, como se verá en la siguiente sección, no se observa mayor incentivo por parte de los docentes, incluso, por ingresar a la CPM.

Gráfico 1

Distribución de Plazas Nombradas según Escala Remunerativa



Fuente: Nexus 2019

2.1. Concurso de Nombramiento

El concurso de Ingreso a la Carrera Pública Magisterial (Concurso de Nombramiento) se desarrolla en el marco de la Ley de Reforma Magisterial. Este concurso está dirigido a los profesionales de la educación que aún no estaban en la Carrera Pública Magisterial y que deseaban desarrollar la función docente en alguna de las IIEE de Educación Básica del sector público con plazas vacantes disponibles para nombramiento.

El proceso único de evaluación, que englobó este concurso y el de Contratación Docente, se desarrolló en dos etapas: (i) la etapa nacional y (ii) la etapa descentralizada. La primera etapa está a cargo del MINEDU. En ella se acreditan las competencias del docente a través de la PUN y de una evaluación psicológica. Aquellos que superan los puntajes mínimos

requeridos para esta prueba quedan habilitados para pasar a la etapa descentralizada, siempre que haya plazas disponibles para su grupo de inscripción. Además, todos los postulantes que rindieron la prueba, independientemente de su puntaje, quedan habilitados para ingresar al cuadro de méritos del proceso de contratación docente.

La segunda etapa involucra solo a los postulantes de Educación Básica Regular que superan los puntajes mínimos requeridos de la PUN y que desean ser nombrados en alguna de las plazas disponibles para su grupo de inscripción. Esta etapa evalúa la capacidad didáctica del docente, así como su conocimiento de la cultura y lengua materna.

Luego de ambas etapas, se estima el puntaje final del docente mediante la suma simple de los puntajes obtenidos en cada etapa de evaluación. En caso de empate, la norma establece que se proceda de la siguiente manera:

- a. Mayor puntaje en la PUN.
- b. Mayor puntaje en la Observación en Aula.
- c. Mayor puntaje en el rubro de Formación de la Trayectoria Profesional.
- d. Mayor puntaje en el rubro de Experiencia de la Trayectoria Profesional.
- e. Mayor puntaje en el rubro Méritos de la Trayectoria Profesional.

Finalmente, los ingresantes a la CPM tienen también la opción de acceder al Bono de Atracción Docente. Dicho bono fue creado en el marco de la revalorización docente, que impulsa el MINEDU con la finalidad de reconocer a los docentes que ingresen a la CPM en el tercio superior del concurso de nombramiento. Este incentivo económico asciende a 18,000 nuevos soles por persona, y se entrega anualmente en partes iguales durante los tres primeros años de servicio dentro de la Carrera Pública Magisterial.

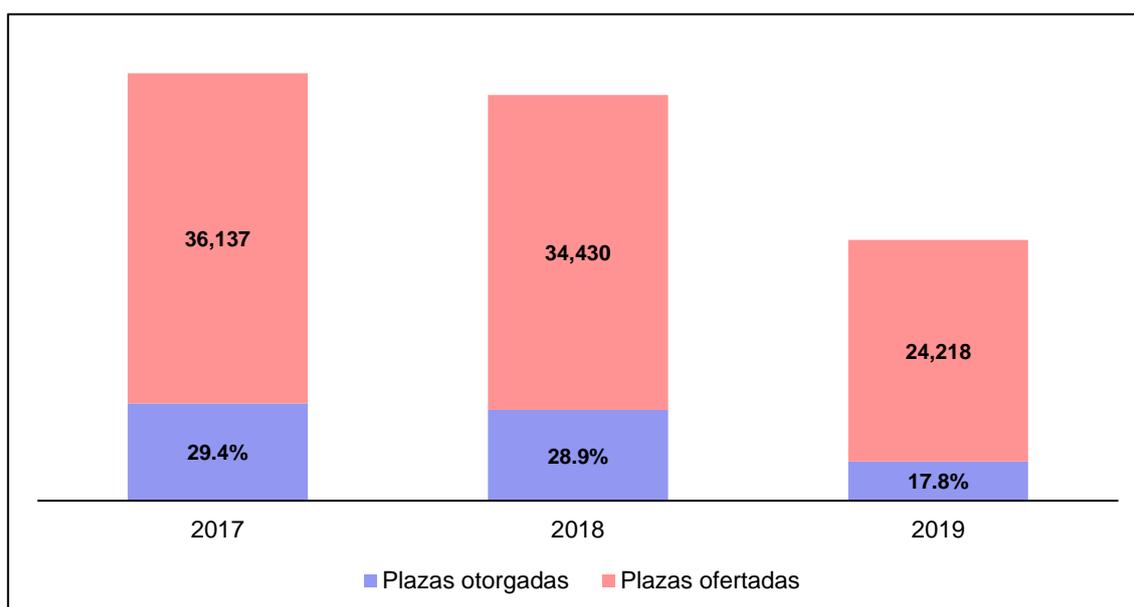
2.2. Descriptivos de los Concursos de Nombramiento

Entre 2017 y 2019 se llevaron a cabo tres concursos de nombramiento. De este modo, se ofertó 36,137 plazas en 2017; 34,430 plazas en 2018; y 24,218 plazas en 2019. Sin embargo,

en promedio, solo el 26% de estas plazas fueron ocupadas por un docente. La proporción de plazas otorgadas por concurso se aprecia en el Gráfico 2. Se observa que, del total de plazas ofertadas en 2017, apenas un escaso 29.4% fueron otorgadas. Algo similar sucedería el siguiente año. El caso más serio se refleja en el último concurso. Si bien se ofertaron menos plazas que en concursos anteriores, los resultados mostraron que la ratio de ocupación también fue mucho menor en comparación a los concursos previos (17.8%).

Gráfico 2

Proporción de Plazas Otorgadas por Concurso (2017 – 2019)



Fuente: Dirección General de Desarrollo Docente (MINEDU).
Elaboración propia.

Un análisis más desagregado se puede generar a nivel de macro región. Una macro región es un conjunto de regiones que poseen en común alguna característica. En función a la ubicación, se definieron cinco macro regiones.

La primera es la macro región Norte, la cual está compuesta por las regiones de Ancash, Cajamarca, La Libertad, Lambayeque, Piura y Tumbes. La segunda es la macro región Sur, que está compuesta por las regiones de Arequipa, Cusco, Madre de Dios, Moquegua, Puno y Tacna. La tercera es la macro región Lima, que está compuesta por Lima

Metropolitana, Lima Provincias y la Provincia Constitucional del Callao. La cuarta es la macro región Oriente, que está compuesta por las regiones de Amazonas, Loreto, San Martín y Ucayali. La quinta es la macro región Centro, que está compuesta por las regiones de Apurímac, Ayacucho, Huancavelica, Huánuco, Junín, Pasco e Ica.

En la Tabla 1 se puede apreciar que la macro región más favorecida en términos de llenar sus plazas ofertadas es Lima (52.1%), mientras que la menos favorecida es Oriente (8.8%). Al parecer, el problema más grave se encuentra en la selva, donde solo dos de cada veinte plazas ofertadas pueden ser llenadas. En cuanto a las macro regiones Norte y Sur, al parecer tienen resultados muy similares con 30.9% y 30.7% respectivamente. Por su parte, en la macro región Centro, una de cada cinco plazas ofertadas es ocupada por un docente.

Tabla 1

Plazas Otorgadas y Ofertadas por Macro Región (2017 – 2019)

	Plazas otorgadas	Plazas ofertadas	%
Macro región Norte	7,100	22,962	30.9%
Macro región Sur	4,630	15,091	30.7%
Macro región Lima	6,285	12,073	52.1%
Macro región Oriente	1,826	20,698	8.8%
Macro región Centro	5,029	23,961	21.0%

Fuente: Dirección General de Desarrollo Docente (MINEDU) (2019).

Elaboración propia.

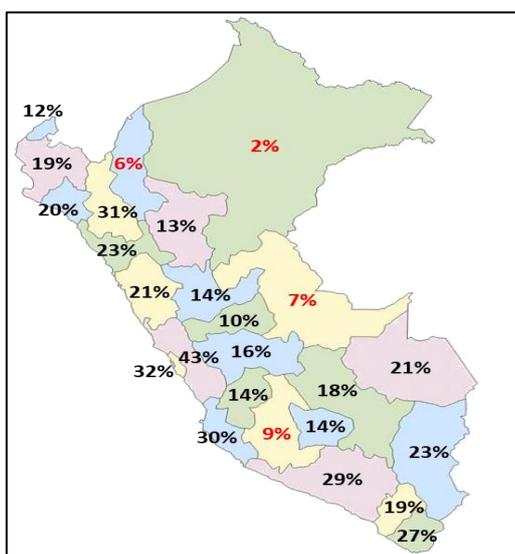
El panorama se hace mucho más complicado si se revisan cifras a nivel regional. El Anexo 1 muestra la distribución de plazas ofertadas a nivel regional, así como la proporción de plazas que fueron otorgadas. En los últimos tres concursos, en promedio, apenas dos regiones ocuparon más del 50% de sus plazas ofertadas. Asimismo, los casos más severos están en Loreto, Ucayali y Amazonas, las cuales no llegan a ocupar ni siquiera el 15% de sus plazas.

Durante el último concurso, los datos demuestran que ninguna región pudo ocupar más del 50% de sus plazas ofertadas. Mientras que en el ámbito urbano el 28% de las plazas

ofertadas obtuvieron un ganador; en el ámbito rural más cercano⁸ el resultado fue de 24%, mientras que en el más lejano⁹ apenas el 11% de las plazas ofertadas fueron otorgadas. El Gráfico 3 revela que el mayor porcentaje de plazas ocupadas lo obtuvo Lima (Metropolitana y Provincias) (43%), seguida por Callao (32%), Ica (30%) y Arequipa (29%). Mientras tanto, en el otro extremo se tiene a las regiones de Loreto (2%), Amazonas (6%), Ucayali (7%) y Ayacucho (9%).

Gráfico 3

Porcentaje de Plazas Otorgadas con Respecto a las Ofertadas (2019)



Fuente: Dirección General de Desarrollo Docente (MINEDU) (2019). Elaboración propia.

Sin embargo, parte del problema de cobertura de plazas se debería a la calidad de los docentes. El Gráfico 4 muestra la cantidad de postulantes por etapa del concurso de nombramiento. En él se puede observar que durante los últimos tres concursos se tuvo una cantidad muy similar de postulantes evaluados. Sin embargo, el porcentaje de docentes que clasifican a la segunda etapa (aprueban la PUN) no supera del 12%. Esto genera que, al final

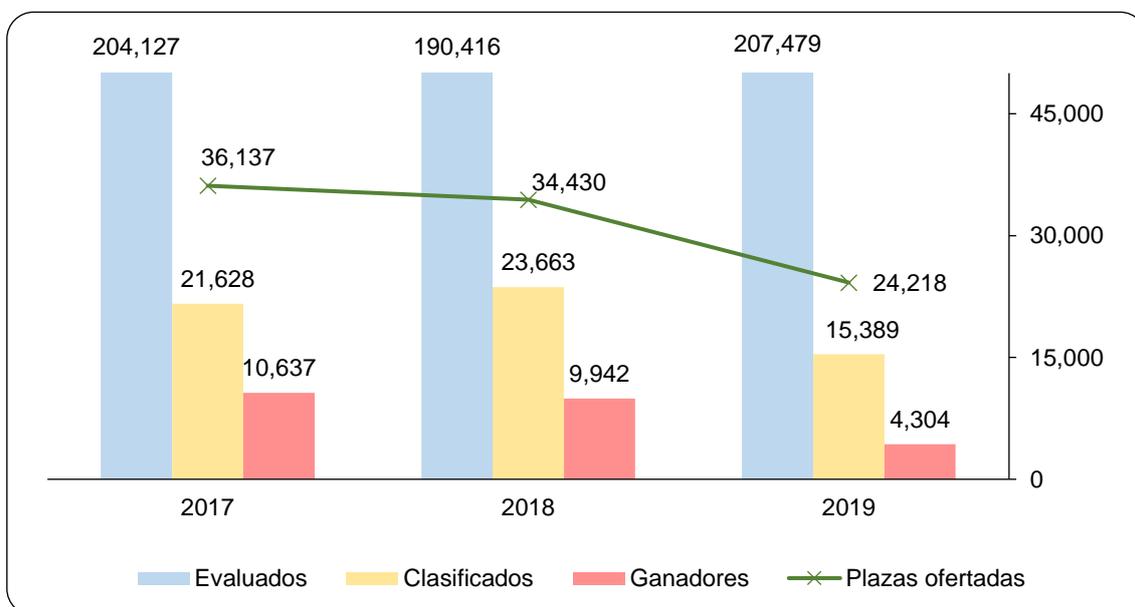
⁸ IIEE ubicadas en centros poblados rurales que cuenten con más de 500 habitantes y que puedan acceder a la capital provincial más cercana en un tiempo no mayor a las dos horas; o todas las IEE ubicadas en centros poblados rurales que cuenten con menos de 500 habitantes y que puedan acceder a la capital provincial más cercana en un tiempo no mayor a los 30 minutos

⁹ IIEE ubicadas en centros poblados con más de 500 habitantes y que pueden acceder a la capital provincial más cercana en un tiempo mayor a 2 horas; o que contando con un máximo de 500 habitantes el tiempo de acceso a la capital provincial más cercana es mayor a 30 minutos

del concurso, apenas un 5% del total de postulantes gane una plaza (2% en el caso de 2019). Así, no solo se debería volver más atractiva la oferta de plazas, sino también se debería reforzar la calidad educativa que reciben los docentes a fin de que tengan una formación que responda a la exigencia planteada por los concursos de nombramiento (Cueto et al., 2017; Guadalupe et al., 2017).

Dentro de esta discusión también se debe considerar la proporción de docentes que ganan una plaza con respecto al total de clasificados en la primera etapa del concurso. Menos del 50% de los docentes que clasifican terminan ganando una plaza. Esto puede suceder por al menos dos motivos. Primero, podría suceder que muchos de los docentes clasificados no cumplen con los requisitos mínimos para ganar una plaza. Segundo, también podría suceder que, luego de clasificar, los docentes escogen plazas que son altamente demandadas¹⁰. Esto hace que muchos no puedan acceder a estas y las que se les ofrece sean poco atractivas. De este modo, prefieren abstenerse y no formar parte de la carrera.

Gráfico 4
Postulantes por Etapa de Concurso de Nombramiento



Fuente: MINEDU (2020)
Elaboración propia.

¹⁰ Esta hipótesis es analizada por Bertoni et al (2019) para el concurso de nombramiento 2015, quienes muestran la concentración de plazas seleccionadas en zonas urbanas y, en contraposición, la alta concentración de plazas no seleccionadas, principalmente en áreas de la Selva peruana.

Esta discusión se aborda debido a que, una vez llegada a la etapa clasificatoria, los docentes tienen la opción de seleccionar una o más plazas. Al observar el Gráfico 4 se esperaría que, en el mejor de los casos, las más de 36 mil plazas ofertadas sean seleccionadas al menos una vez, pues cada uno de los más de 20 mil docentes pueden elegir entre una hasta cinco plazas. Sin embargo, como se muestra en la Tabla 4 del Anexo 4, entre 2017 y 2019, solo fueron seleccionadas 24,602 IIEE en total. Es decir, alrededor de 8,200 plazas seleccionadas, en promedio, por año. Por lo tanto, si bien en un inicio se tiene un problema de calidad docente, también se tiene un problema en la oferta, ya que apenas menos de la quinta parte de plazas (la tercera en caso de 2019) son seleccionadas.

3. Datos

Para cumplir con el objetivo y evaluar la hipótesis planteada, se utilizará como principal insumo los resultados de los concursos de nombramiento llevados a cabo entre 2017 y 2019. Dicha información será combinada con diversas fuentes de información correspondientes a los años 2016 – 2018. El hecho de tomar información rezagada al año anterior se debe a que los concursos de nombramiento empiezan a inicios del año escolar. Por ende, las características que el docente observa en una plaza antes de elegirla corresponden al corte del año anterior del concurso.

Por lo tanto, el presente estudio cuenta con 138 variables. Entre las fuentes de información elegidas destacan el Censo Educativo (CE); la Evaluación Censal de Estudiantes (ECE); el Sistema de plazas Nexus, el Censo de Población y Vivienda 2017¹¹; entre otros. A continuación, se resume cada fuente de información y se describe los principales indicadores a utilizar¹².

¹¹ Las tres primeras fuentes de información son de acceso público mientras que el resto de la información deberán ser solicitada al MINEDU e INEI mediante un documento formal.

¹² Un análisis más detallado se puede encontrar en el Anexo N° 2.

3.1. Indicadores y Fuentes de Información

a) Censo Educativo (CE). El CE es un proceso estadístico que se realiza anualmente por el MINEDU y que recoge información detallada de las IIEE públicas y privadas, y programas no escolarizados de todo el país¹³. De este modo, se puede saber de qué manera el sistema educativo está evolucionando en aspectos como número de estudiantes matriculados, niveles de atraso escolar, promoción, repetición, deserción, número de personal docente y administrativo, infraestructura educativa, entre otros.

Gracias a la información recogida por el CE, el MINEDU puede organizar acciones y distribuir recursos económicos y logísticos a las IIEE de todo el país. Además, sirve como plataforma de diferentes indicadores, lo cual es un incentivo para fomentar la investigación educativa en el país. Desde la plataforma de ESCALE, se cuenta con esta información desde 2004 en adelante. Además, puede ser cruzada con el Padrón Web para determinar su ubicación geo-referenciada y el grado de ruralidad de la institución educativa (IE).

b) Evaluación Censal de Estudiantes. La Evaluación Censal de Estudiantes (ECE) es una prueba a gran escala que cada año aplica el Ministerio de Educación para recoger información acerca de los logros de aprendizaje de los estudiantes. Esta prueba se realiza en todas las escuelas públicas y privadas del país. Si bien hasta el año 2015 la ECE estaba dirigida exclusivamente a estudiantes de segundo grado de primaria, a partir de ese mismo año se evaluó también a alumnos de cuarto de primaria y segundo de secundaria. Asimismo, en algunos departamentos del país, también se evalúa a los estudiantes de cuarto grado de primaria que tienen una lengua materna originaria distinta al castellano y asisten a una escuela de Educación Intercultural Bilingüe (EIB).

¹³ Según la Resolución Ministerial N° 627-2016-MINEDU, el CE es obligatorio y es el director de la IE el encargado de brindar la información.

Las competencias a evaluar son básicamente dos: Comprensión lectora y Matemáticas. Además, desde el 2016, también se evalúa a los estudiantes de segundo año de secundaria en las competencias de Historia, Geografía y Economía y Ciencia, Tecnología y Ambiente. Gracias a la ECE, el MINEDU puede establecer políticas educativas más efectivas, basadas en evidencia y orientadas a mejorar los aprendizajes. Esto debido a que los resultados de la evaluación forman parte de un indicador clave para medir el rendimiento académico de los estudiantes del país.

Por su parte, en 2015, la Oficina de Medición de la Calidad de los Aprendizajes (UMC) decidió incorporar cuestionarios adicionales con el fin de evaluar el nivel socioeconómico tanto de las IIEE como de los estudiantes que rendían la ECE. Estos cuestionarios iban dirigidos tanto para los directores como para los padres de familia de los alumnos que rendían la prueba. Mediante estos cuestionarios se generó un Índice Socioeconómico (ISE) de los estudiantes, indicador que también será considerado en el algoritmo.

c) Sistema de plazas Nexus. El sistema de plazas Nexus brinda información acerca de la situación de las plazas y del personal que la ocupa. Gracias a este sistema, se puede obtener características del personal docente y administrativo que labora en una IE. La base de datos tiene un nivel de desagregación a nivel de plaza. Bajo el actual sistema, cada docente ocupa una plaza. No obstante, antes de describir esta fuente de información, es necesario aclarar algunos conceptos:

Plaza: Para el presente estudio, una plaza se entiende como un espacio presupuestal asociado a un cargo establecido en la LRM. Esta podría estar o no ocupada por una persona que cumpla con los requisitos planteados para dicho cargo. Según el tipo de registro las plazas se pueden clasificar principalmente en orgánicas y eventuales.

Plaza orgánica: Son plazas que cuentan con financiamiento permanente. Solo plazas con este atributo pueden ser ofrecidas en concurso de nombramiento.

Plaza eventual: Son plazas que cuentan con una asignación presupuestal en forma anual. Al momento, no se pueden convertir en plazas orgánicas.

De acuerdo a la situación laboral, los docentes pueden ser clasificados como nombrados y contratados:

Nombrado: Se denomina así a la plaza asignada a un docente a través de un concurso público de acceso a la CPM. Los ubicados en estas plazas son los únicos que pueden concursar por ascensos en la CPM o postular a cargos.

Contratado: Se denomina así a la plaza cuando un docente ingresa a esta después de ganar un concurso público de contratación docente. Los profesores contratados no forman parte de la CPM y su contrato es por tiempo definido, generalmente anual.

Vacante: Estas plazas no son ocupadas por un docente nombrado o contratado.

El sistema Nexus cuenta con información de las plazas financiadas por el MINEDU ya sean ocupadas o vacantes. Asimismo, el sistema contiene información de las plazas en los centros educativos. Si bien se sabe que la data más relevante es la de docentes, también es posible identificar a los directivos. Nexus provee información descriptiva de la plaza y la persona que lo ocupa.

Este sistema se actualiza de manera automática en tiempo real según contrataciones. Las bases de datos son reportes semanales y mensuales. El corte utilizado en el presente estudio es el correspondiente a los años 2016 – 2018, debido a que la base de datos a este periodo estaba sistematizada de modo tal que pueda fusionarse con otras bases a través de los datos personales de los docentes.

Algunos posibles indicadores que proporciona este sistema son: porcentaje de plazas nombradas, porcentaje de plazas vacantes, número de directivos, porcentaje de docentes

mujeres en la IE, número de directivo por docente en la IE, número de personal docente (directivos y profesores) en la IE, entre otros.

d) Censo de Población y Vivienda. El Censo de Población y Vivienda (CPV) realizado por el Instituto Nacional de Estadística e Informática en 2017 provee insumos sobre el entorno sociodemográfico de las IIEE. Esto permitirá describir el contexto al que se expondría un docente bajo una determinada plaza. En ese sentido, esta fuente de información permite caracterizar a las viviendas, los hogares y la población que rodea a cada IE.

En la base de vivienda se tiene información acerca del tipo de vivienda, si es un departamento, una casa, una choza, etc.; el material de construcción predominante en las paredes, pisos y techos. Además, se recogen variable de acceso a servicios básicos como agua potable, desagüe y electricidad, así como número de habitaciones y hogares por vivienda.

La base de hogares permite recoger indicadores de equipamiento como televisor, equipo de sonido, refrigeradora, etc. También se cuenta con indicadores de acceso a servicios como telefonía fija, celular, internet, cable, etc. Finalmente, la base de población permite caracterizar a las personas que habitan el entorno de la escuela a través de su edad, sexo, si están afiliados a algún seguro, lengua materna, nivel educativo, condición laboral, entre otros.

Si bien esta fuente de información solo está disponible para 2017, la mayoría de las variables que contiene se asumen constantes en el corto y mediano plazo. Por ende, dado que el análisis se genera a partir de la información de los años 2016 – 2018, las características sociodemográficas que rodean a la escuela se asumirán constantes en dicho periodo.

e) Padrones Adicionales. Si bien las fuentes mencionadas anteriormente proveen información diversa, el presente estudio utiliza, adicionalmente, otros padrones que contienen información tanto interna como externa de las IIEE. En este sentido, se tiene el registro de la plataforma SíSeVe, en la cual se registran las denuncias de los estudiantes por violencia escolar, ya sean físicas, psicológicas o sexuales. Esta información se contiene para los 3 años de análisis

a nivel de IE y proveen información tanto del número de denuncias, como de quién fue el agresor y el sexo del (de la) agredido(a).

Otra fuente relevante es el padrón de intervenciones del MINEDU. El Ministerio ha llevado a cabo diversas intervenciones, tales como el Acompañamiento Pedagógico, Soporte Pedagógico y la Jornada Escolar Completa. Estas intervenciones impactan de algún modo el rendimiento académico de los estudiantes, así como otras vinculadas a la IE y al docente (Chinen y Bonilla, 2017; Agüero 2016). En esta misma línea, se utiliza también el padrón de IIEE beneficiarias del Bono de Desempeño Escolar, el cual se entrega a aquellas IIEE con los mejores resultados en la ECE a nivel nacional. Este bono es un monto efectivo que se entrega al director de la escuela para ser distribuida tanto por su persona como para los docentes de la misma.

Finalmente, se agrega el padrón de ruralidad correspondiente a cada año en el periodo de análisis para considerar el área al que se expone el docente al trabajar en una determinada IE¹⁴. Esta información es relevante no solo porque brinda información más acertada sobre el área (desde más rural a menos rural), sino porque según dicha diferencia, el MINEDU otorga bonos a los docentes que van entre los S/ 500 soles (en caso trabaje en una IE con mayor ruralidad) y los S/ 50 soles (en caso trabaje en una IE con menor ruralidad)¹⁵.

3.1. Estadísticos Descriptivos

El presente trabajo se concentrará en el análisis de los concursos de nombramiento 2017, 2018 y 2019. Según las cifras del Censo Escolar, hacia 2017 se tenían 61,913 IIEE de educación básica regular, de las cuales, el 37.4% ofertaron al menos una plaza en su concurso de nombramiento. En 2018, un escaso el 29.6% de las 62,897 IIEE ofertaron plazas y en 2019 lo

¹⁴ Para el año 2017, 2018 y 2019 se parte de las Resoluciones Ministeriales N° 121-2017, N° 108-2018 y N° 093-2019 del MINEDU, respectivamente.

¹⁵ Decreto Supremo N° 014-2014-EF y su modificatoria Decreto Supremo N° 227-2015-EF.

hicieron solo el 21% de las 63,005 IIEE. La **Tabla N° 3** en el **Anexo N° 4** muestra los principales estadísticos descriptivos de las plazas ofertadas y no ofertadas.

Se observa que, por lo general, se ofertan plazas más alejadas de la UGEL o de la capital departamental, así como las que se ubican en zonas con mayor ruralidad. Asimismo, las plazas ofertadas suelen ser aquellas con menor acceso a electricidad, agua potable e internet. Otra característica en contra es que la infraestructura no es la mejor. En todos los años se observa que, la proporción de IIEE con paredes de material noble es menor en las ofertadas que en las no ofertadas.

En cuanto a las intervenciones que otorga el MINEDU, se encuentra que las IIEE cuyas plazas fueron ofertadas gozan, en mayor proporción, de al menos una intervención. Finalmente, un mayor porcentaje de plazas ofertadas están concentradas en la región selva. Esto haría sospechar que, gran parte de las plazas ofertadas año a año son aquellas que no fueron otorgadas en los concursos anteriores, pues presentan varias carencias y están ubicadas en zonas muy alejadas de la ciudad.

La Tabla 4 del mismo anexo muestra los principales estadísticos descriptivos de las plazas ganadoras y otorgadas en los tres últimos concursos. Se observa que, del total de plazas ofertadas, las plazas seleccionadas y ganadoras suelen ser las menos alejadas de la UGEL o la capital departamental, así como las menos rurales. Además, la proporción de IIEE EIB es menor entre las seleccionadas y ganadoras.

En cuanto a la infraestructura de las IIEE con plazas ganadoras, estas presentan paredes y pisos de material noble en mayor proporción también, así como mayor acceso a luz, agua e internet. Por lo general, estas IIEE suelen ser más grandes (reciben más alumnos) y una mayor proporción de estas reciben al menos una intervención por parte del MINEDU. Finalmente, se ubican en mayor proporción en la región costa y presentan mayor número de institutos y universidades con carrera de educación en el distrito.

Por el lado de la demanda, los datos son muy limitados, pues no se recogen muchas variables que describan las características de los postulantes a las plazas. No obstante, gracias al primer concurso de nombramiento en 2015, Bertoni et al. (2019) reporta la **Tabla N° 5**, la cual muestra las principales características de los postulantes según su desempeño en dicho concurso. Como se observa, los postulantes que aprueban la PUN y, por tanto, seleccionan plazas son, en promedio, más jóvenes y tienen más años de experiencia enseñando en IIEE privadas con respecto a sus pares que no pasaron la prueba. Asimismo, los postulantes que escogieron plazas son, en mayoría, mujeres y estudiaron en una de las universidades públicas del top 15.

4. Metodología

El presente trabajo analizará la dinámica entre la oferta y la demanda de plazas de los últimos tres concursos de nombramiento. A partir de ello, se generará una tipología de las mismas con la finalidad de plantear un conjunto de políticas y esquemas de incentivos que respondan a la heterogeneidad de las mismas.

Para ello, un primer paso es la predicción de la probabilidad de que una plaza sea seleccionada. Esto se logrará utilizando datos históricos como insumo para plantear la tipología de plazas. En ese sentido, más allá de los modelos convencionalmente usados para la estimación de una probabilidad (modelos de probabilidad lineal o logísticos), el presente trabajo plantea utilizar modelos basados en árboles de decisión. En específico, se propone trabajar con tres modelos: *Least Absolute Shrinkage and Selection Operator (LASSO)*, *Random Forests* y *Light Gradient Boosting Machine (LightGBM)*.

Si bien el estudio pretende mostrar la relevancia de metodologías de analítica avanzada en la investigación social, primero se debe mostrar por qué este método es mejor que los modelos de predicción convencionales. Por ello, un primer paso será comparar modelos base como la regresión lineal y logística con modelos de aprendizaje automático como los

mencionados anteriormente. A continuación, se procederá a describir cada método predictivo que se utilizará, así como su implementación. Luego, se describirá cómo se implementarán los modelos de aprendizaje automático para obtener la tipología de plazas.

4.1. Métodos Predictivos

a) **Modelo Base.** El presente estudio tomará como base un modelo muy famoso en la literatura de los microdatos: la regresión logística. Si bien lo ideal será partir de un modelo de probabilidad lineal, a continuación, se explica por qué se prefiere un modelo logístico (*logit*) a uno lineal.

El modelo de probabilidad lineal presenta la siguiente forma:

$$y_i = \beta' X_i + \varepsilon_i \quad (1)$$

Donde y_i toma los valores de cero y uno y X_i es una matriz de variables independientes que explican y_i . De este modo, se puede tomar a y_i como una variable aleatoria que se distribuye como una Bernouilli. Así:

$$\mathbb{E}[y_i|X_i] = 1 \times Prob(y_i = 1|X_i) + 0 \times Prob(y_i = 0|X_i)$$

Además, bajo $\mathbb{E}[\varepsilon_i|X_i] = 0$:

$$\mathbb{E}[y_i|X_i] = \beta' X_i$$

En los modelos de probabilidad lineal (MPL), el valor predicho de y_i se interpreta como la probabilidad de que y_i tome el valor de 1. Por ende, el parámetro β asociado a la matriz X_i responde al cambio en la probabilidad de ocurrencia de y_i ante un cambio en unitario de X_i . El método de estimación usado en este tipo de modelo es la de Mínimos Cuadrados Ordinarios (MCO). Este método de estimación busca minimizar los errores del modelo para caracterizar los parámetros β asociados a cada elemento de la matriz X_i . De modo que:

$$\min_{\beta} \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \beta' X_i)^2 \quad (2)$$

Si bien este tipo de modelos son muy famosos en la literatura, no suelen usarse para la predicción de probabilidades, pues presenta diversos problemas. Uno de los principales es que, debido a su linealidad, no hay nada que restrinja que el valor predicho de y_i se encuentre dentro del intervalo $[0; 1]$ (Baltagi, 2011). Adicionalmente, Hoxby y Oaxaca (2006) demuestran de manera formal cómo este tipo de modelos presentan sesgo e inconsistencia en su estimación.

Debido a ello, el modelo a utilizar como base y que lidia con los problemas presentados por los MPL será el modelo *logit*. Este tipo de modelos reciben dicho nombre porque parten de una distribución acumulada para una función de distribución logística (Cameron y Trivelpic, 2005). De ese modo, se modela la probabilidad de ocurrencia de y_i como:

$$\Pr(y_i = 1|X_i) = F(\beta'X_i)$$

Donde $F(*)$ Es la función de distribución acumulada que se caracteriza de la siguiente manera:

$$F(\beta'X_i) = \frac{1}{1 + e^{-\beta'X_i}} \quad (3)$$

Como se observa, dada la forma funcional de la distribución, el valor de predicción de y_i permanece en el rango entre 0 y 1. Asimismo, la distribución del error ya no es un problema, pues se asume una distribución logística en todo momento. Otra diferencia con el modelo lineal es que el parámetro β no corresponde al efecto marginal de la variable independiente sobre la dependiente. El cambio en la probabilidad está dado por:

$$\frac{\partial \Pr(y_i=1)}{\partial x_j} = f(\beta'X_i)\beta_j, \quad \text{en caso } x_j \text{ sea continua.}$$

$$\Delta \Pr(y_i = 1) = F(\beta x_1) - F(\beta x_0) \quad \text{en caso } x_j \text{ sea discreta.}$$

Donde $f(*)$ y $F(*)$ son las funciones de densidad y de distribución acumulada, respectivamente. Para estimar un modelo *logit* se utiliza el método de máxima verosimilitud. Así, la función de verosimilitud es:

$$L = \prod_{i=1}^n f(\beta; Y|X) = \prod_{i=1}^n [\Phi(\beta' X_i)]^{y_i} [1 - \Phi(\beta' X_i)]^{(1-y_i)} \quad (4)$$

Donde $\Phi(*) = F(*)$ (Baltagi, 2011).

b) Least Absolute Shrinkage and Selection Operator. El método Least Absolute Shrinkage and Selection Operator (LASSO) fue propuesto por Tibshirani (1996) y se utiliza para la selección de variables que ayuden a mejorar la exactitud e interpretación de modelos estadísticos. La idea detrás de este método es muy similar a la regresión lineal generada por el MCO. Se asume que el set de variables x_i e y_i contiene observaciones distribuidas de manera independiente. Asimismo, se asume que x_i es una variable estandarizada¹⁶.

Así, LASSO minimiza la suma de los residuos al cuadrado sujeto a que la suma del valor absoluto de los coeficientes β del modelo lineal es menor que una constante k .

$$(\hat{\alpha}, \hat{\beta}) = \arg \min \left\{ \sum_{i=1}^N \left(y_i - \alpha - \sum_j \beta_j x_{ij} \right)^2 \right\}$$

s. t. $\sum_j |\beta_j| \leq k$ (5)

Donde α es el parámetro constante de la regresión y k es un parámetro de afinación. A través de este método, se puede obtener mayor confiabilidad en la selección de variables en un modelo sin dejar de lado la calidad del mismo. Al limitar la suma de los valores absolutos de los coeficientes, se fuerza la contracción de algunos parámetros de modo que se seleccionan específicamente las variables que cumplan con dicha condición (Dinov, 2018).

La motivación detrás del método LASSO proviene de la propuesta de Breiman (1995) del garrote no negativo que parte de la estimación MCO y los contrae por factores no negativos cuya suma se restringe a un parámetro de afinación también. Si bien el trabajo de Breiman

¹⁶ Se resta la media y divide la desviación estándar. De este modo, se cumple que $\frac{1}{N} \sum x_i = 0$ y $\frac{1}{N} \sum x_i^2 = 1$.

(1995) tiene errores de predicción pequeños, el método deja de ser eficiente cuando el verdadero modelo contiene muchos coeficientes con valores cercanos a cero (Tibshirani, 1996).

c) **Random Forests.** De acuerdo con Breiman (2001), el Random Forest es un clasificador que consiste en un conjunto de árboles independientes e idénticamente distribuidos cuyo resultado es una clasificación basada en el resultado de cada árbol. Esto quiere decir que cada árbol da una clasificación lo suficientemente independiente que, al englobar el conjunto, se puede obtener una precisión razonable.

La ventaja de los modelos basados en esta clase de algoritmos es que, aun cuando se tiene un número muy alto de árboles, la ley fuerte de grandes números asegura que el error de generalización converja. Esto indicaría que, a pesar de tener un gran número de árboles, la probabilidad de un sobreajuste a los datos es mínima (Breiman, 2001).

La implementación de los modelos *random forests* es bastante sencilla. Primero, se escoge un conjunto de datos de entrenamiento, de los cuales, se escogen N muestras de manera aleatoria y con reemplazo. A partir de estas muestras se construirá un árbol de clasificación. Finalmente, se escoge el número de árboles que se quiere en el algoritmo y se repiten los primeros pasos tantas veces como árboles de clasificación se han escogido. Cabe resaltar que, a mayor número de árboles, existe mayor precisión. Sin embargo, los resultados suelen ser convergentes, por lo que el riesgo de sobreajuste es relativamente bajo.

Para que el resultado mantenga una precisión razonable, la idea del algoritmo detrás es maximizar la independencia entre el conjunto de árboles. Para ello se deben evaluar dos parámetros importantes en el conjunto de clasificadores: la fuerza y la correlación. El primero mide la precisión y el segundo, la dependencia entre ellos. Así, la interacción entre ambos permite entender cómo funciona el modelo planteado (Breiman, 2001). El primer parámetro se define como:

$$s = \mathbb{E}_{X,Y} mr(X, Y)$$

Donde $mr(X, Y)$ es la función de margen definido como $mr(X, Y) = \mathbb{E}_{\Theta}[c(X, \Theta) = Y] - \mathbb{E}_{\Theta}[c(X, \Theta) \neq Y]$. A su vez, $\mathbb{E}_{\Theta}[c(X, \Theta) = Y]$ es la proporción de árboles c que, gracias a un patrón X definido por las variables, han sido clasificados correctamente. Así, el margen no es otra cosa que la diferencia entre la proporción de árboles que clasifican correctamente y los que no. Si el total de árboles han sido clasificados correctamente, el margen tomará el valor de 1. Caso contrario, sus valores quedarán definidos en el intervalo $[-1, 1]$. Por lo tanto, a medida que el margen sea mayor (o más cercano a la unidad), mayor será la fuerza del modelo.

En cuanto al segundo parámetro, este se mide de la siguiente manera:

$$\bar{\rho} = \mathbb{E}_{\Theta, \Theta'} [\rho(c(\cdot, \Theta), c(\cdot, \Theta'))]$$

Donde ρ es el coeficiente de correlación entre dos variables aleatorias en el conjunto de información de cada árbol. Las variables están dadas por el set de información que caracteriza a la clasificación (variables demográficas, socioeconómicas, características de las IIEE que ofertan plazas, características de los docentes que ocupan las plazas no ofertadas en esas mismas IIEE, etc.). En este caso, es deseable que la correlación del conjunto sea la menor posible, de modo que la independencia sea mayor entre cada árbol en el conjunto. Por lo tanto, la estrategia a seguir en este tipo de modelos es maximizar la fuerza y minimizar la correlación.

d) Light Gradient Boosting. El *LightGBM* es un modelo aditivo de árboles de decisión basado en el algoritmo *Gradient Boosting Decision Tree* (GBDT) y al cual se le añaden técnicas de *Gradient-based One-Side Sampling* (GOSS) y *Exclusive Feature Bundling* (EFB) (Ke et al., 2017). Los algoritmos GBDT requieren de tres elementos: (1) una función de pérdida a optimizar; (2) un algoritmo de aprendizaje que ayude realizar las predicciones; y, (3) un modelo aditivo para añadir los algoritmos de aprendizaje de modo que se minimice la función de pérdida.

Primero, se requiere que la función de pérdida sea diferenciable. En este caso, se utilizará como función de pérdida el error cuadrático medio, que mide la diferencia entre un vector de los valores de una variable y un vector de predicciones de la misma. Segundo, se utiliza un algoritmo de aprendizaje basado en árboles de decisión. En particular, se utilizan árboles de clasificación dado que se busca predecir una variable discreta. Tercero, se aplica un modelo aditivo que agregue uno a uno a los árboles de decisión de manera homogénea a través de un procedimiento *steepest descent*, el cual minimizará la función de pérdida anteriormente planteada.

En este sistema, el método GOSS permite realizar muestreos descendentes de los datos de modo que se pueda ganar precisión en la ganancia de la información, la cual puede ser incluso más precisa que un muestreo aleatorio uniforme. De este modo, se utiliza la varianza estimada por esta metodología para muestras más pequeñas en lugar de la varianza estimada por el método GBDT para determinar el punto de división de cada árbol de decisión. Asimismo, el método EFB permite agrupar características exclusivas con el fin de reducir el problema de agrupación óptima, lo cual hace que la predicción del parámetro sea mayor (Ke et al., 2017).

Realizar este estudio en el marco de la reforma magisterial resulta interesante, pues en la actualidad, la literatura es muy limitada. En especial, la aplicación de modelos computacionales de inteligencia artificial suele ser nuevo en cuanto a la investigación de temas sociales. Si bien en los últimos años se han desarrollado estudios sobre contratación, asignación y retención de docentes como los de Simon, Johnson y Reinhorn (2019); Perrone y Eddy-Spicer (2019); Walker (2019); y Loeb, Kalogrides y Béteille (2012); ninguno de ellos utiliza modelos de predicción basados en inteligencia artificial, siendo la mayoría provenientes de enfoques cualitativos o de *value-added*.

La implementación de los modelos *LightGBM* tampoco es muy complicado. Primero, se parte de un ajuste inicial de los datos (F_0) que minimice la función de pérdida L . Formalmente:

$$F_0(x) = \arg_{\gamma} \min \sum_{i=1}^n L(y_i, \gamma) = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (8)$$

Donde L representa el error cuadrático medio. De este modo, se calcula el gradiente de L con respecto a F_0 :

$$r_{i1} = - \frac{\partial L(y_i, F_0(x_i))}{\partial F_0(x_i)}$$

Luego, se ajusta el árbol de clasificación a los residuos y se estima el gradiente promedio para cada nodo. Finalmente, se aplicará un procedimiento *steepest descent* que minimizará la pérdida en cada hoja a medida que se avance hacia el gradiente promedio. A medida que el árbol contenga mayor profundidad, este irá aprendiendo a través de una tasa de aprendizaje que ajusta una vez más los datos, mejorando así los resultados:

$$F_1(x) = F_0(x) + \lambda_1 h_1(x)$$

Donde λ_1 es la tasa de aprendizaje y $h_1(x)$ representa el nodo del árbol de decisión. Así, la idea central de este modelo consiste en agregar árboles con distintos parámetros cuya combinación minimice el error de predicción (Friedman, 2001; Li, 2012). Este proceso se repite tantas veces como se decida ajustar los datos. Sin embargo, existe la probabilidad de que haya un sobreajuste. Es decir, que el algoritmo se entrene tanto con los datos que el modelo que arroje no se pueda ajustar a datos nuevos. No obstante, se pueden ajustar parámetros de profundidad para evitar este problema.

4.2. Implementación de los Métodos Predictivos

Existen tres conceptos importantes en la implementación de los modelos de *machine learning* que ayudarán a mejorar su desempeño y evitar el problema de sobreajuste (*overfitting*):

i) partición de la muestra, ii) validación cruzada y iii) selección de hiperparámetros.

La partición de la muestra es un procedimiento utilizado para testear el desempeño del modelo predictivo por fuera de los datos con los que estimó el método y de esa manera evitar el sobreajuste; es decir, que el modelo prediga bien en la muestra de entrenamiento pero que, al enfrentarse a una nueva muestra, su capacidad predictiva decaiga. Para ello, se parte la muestra total en dos sub-muestras: una de entrenamiento y otra de prueba. De este modo, se destinó el 70% de la muestra a entrenar los datos y el 30% de la muestra a testear su capacidad predictiva. La muestra del presente estudio consta de 51,965 escuelas que han ofertado plazas en los concursos de nombramiento de los años 2017, 2018 y 2019. Siguiendo la regla mencionada, se destinaron 36,375 escuelas para el entrenamiento y 15,590 escuelas para la prueba.

Un siguiente aspecto de los modelos de *machine learning* es la validación cruzada que ayuda a evaluar los resultados dentro de la muestra de entrenamiento a medida que aplican los métodos predictivos y diversas configuraciones de los mismos. El método más común es el de *k-fold cross-validation* que consiste en partir la muestra en k partes iguales de manera aleatoria, entrenar el modelo con las $k - 1$ partes y evaluar los resultados sobre la parte restante. De este modo se podrá construir indicadores de precisión (*accuracy*) en base al promedio de las k muestras aleatorias. Kohavi (1995) muestra que no es necesario tener un k muy elevado (tal como caso de *leave-one-out*) y que valores de k entre 5 o 10 son adecuados para tener buena precisión. Por ello, sin perjuicio de los resultados, y como es común en la literatura, se aplicará un método de *5-fold cross-validation*.

Finalmente, la selección de los hiperparámetros ayudará a mejorar el rendimiento de los métodos de *machine learning*. Para ello, se siguió un proceso de dos etapas utilizando las herramientas de *Scikit-Learn* en el programa *Python*. Primero, dado que no se tenía mucha claridad de los hiperparámetros, se utilizó una búsqueda aleatoria de los mismos con validación cruzada (*Random Search CV*). Esto con el fin de definir una grilla de rangos de hiperparámetros,

tomar valores aleatorios de las combinaciones de los mismos y evaluar los resultados aplicando métodos de validación cruzada. Este método tiene la ventaja de ser menos demandante computacionalmente y ayuda a definir valores iniciales cuando no se tiene mucha claridad de los hiperparámetros a utilizar.

Posteriormente, se utilizó el método de Grilla de Búsqueda con validación Cruzada (*Grid Search CV*). Para ello se tomaron los hiperparámetros encontrados en la etapa previa, sobre los cuales se definió una grilla más acotada y se procedió a evaluar sobre todas las combinaciones posibles. Los hiperparámetros utilizados en los métodos de *LightGBM* y *Random Forest* son los listados a continuación y la selección de ellos ha sido descrita anteriormente:

- Número de árboles en el bosque (*n_estimators*)
- Número máximo de características consideradas para dividir un nodo (*max_features*)
- Número máximo de niveles en cada árbol de decisión (*max_depth*)
- Número mínimo de puntos de datos colocados en un nodo antes de que el nodo se divida (*min_samples_split*)
- Número mínimo de puntos de datos permitidos en un nodo hoja (*min_samples_leaf*).

4.3. Métodos de Conglomerados

Este método que busca construir grupos de observaciones (conglomerados) de modo que las observaciones dentro de un conglomerado sean similares entre sí y a su vez distintos a los de cualquier otro conglomerado. Este se denomina un problema “no supervisado” porque busca determinar estructuras que agrupen los datos, mientras que, por otro lado, los problemas supervisados se busca predecir un vector de resultados (por ejemplo, que una escuela sea o no seleccionada en un concurso de nombramiento).

La construcción de los conglomerados se basará en la aplicación del método de *k-means* cuya función objetivo a minimizar es la siguiente expresión:

$$\text{Minimizar } \left\{ \sum_{k=1}^K W(C_k) \right\}$$

$$C_1, \dots, C_K$$

Donde, si la i -ésima observación pertenece al k -ésimo conglomerado, entonces $i \in C_k$. Asimismo, la varianza intra-conglomerado $W(C_k)$ del conglomerado C_k es una medida de las disimilitudes entre las observaciones del conglomerado C_k . Existen diversas formas de medir la varianza intra-conglomerado pero la más utilizada es la distancia euclídeana definida de la siguiente forma:

$$W(C_k) = \frac{1}{N_k} \sum_{i, i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2$$

Donde N_k denota el número de observaciones en el k -ésimo conglomerado, y la varianza intra-conglomerado está definido como la suma de las distancias euclídeanas al cuadrado de todos los pares de observaciones dentro del k -ésimo conglomerado. Finalmente, la aplicación del método se hace siguiendo el siguiente algoritmo.

1. Asignar aleatoriamente un número, de 1 a K , a cada una de las observaciones. Estos sirven como asignaciones iniciales de los conglomerados para las observaciones.
2. Iterar hasta que las asignaciones del conglomerado dejen de cambiar:
 - a. Para cada uno de los K conglomerados, calcule el centroide del conglomerado. El centroide del k -ésimo conglomerado es el vector de las medias de las p características para las observaciones en el k -ésimo conglomerado.
 - b. Asignar cada observación al grupo cuyo centroide es el más cercano (donde más cercano se define usando la distancia euclídeana).

5. Estimaciones de los Modelos Predictivos

5.1. Calidad Predictiva de los Métodos Implementados

Una vez que se han estimado todos los métodos, se evalúa la capacidad predictiva de cada uno de ellos en la muestra de prueba (15,590 escuelas), donde se compara los valores

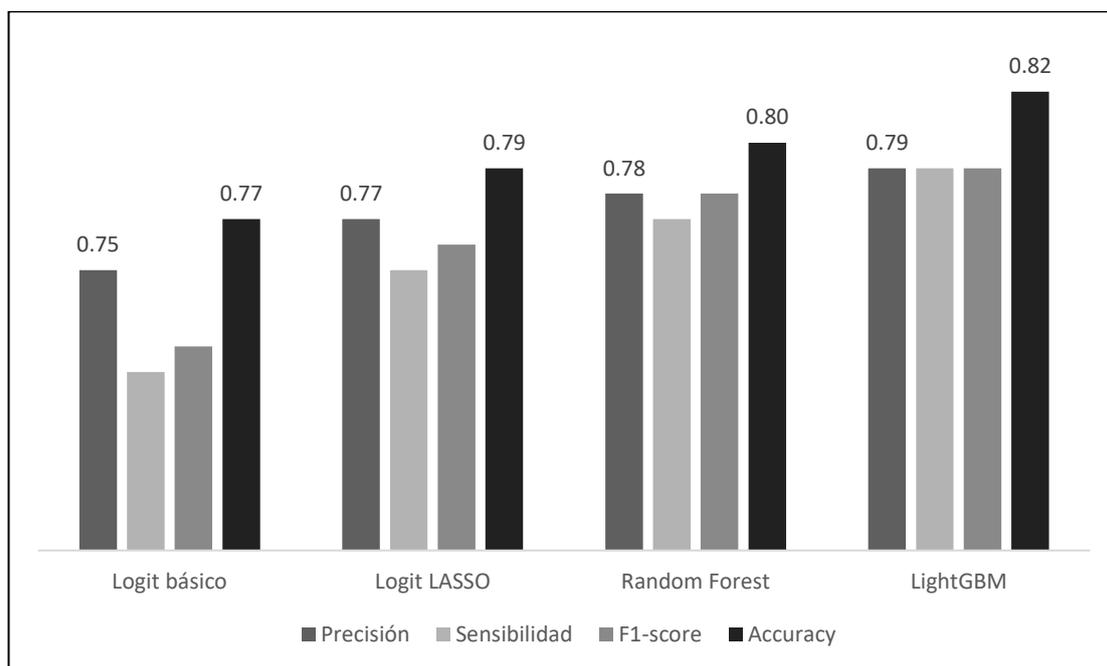
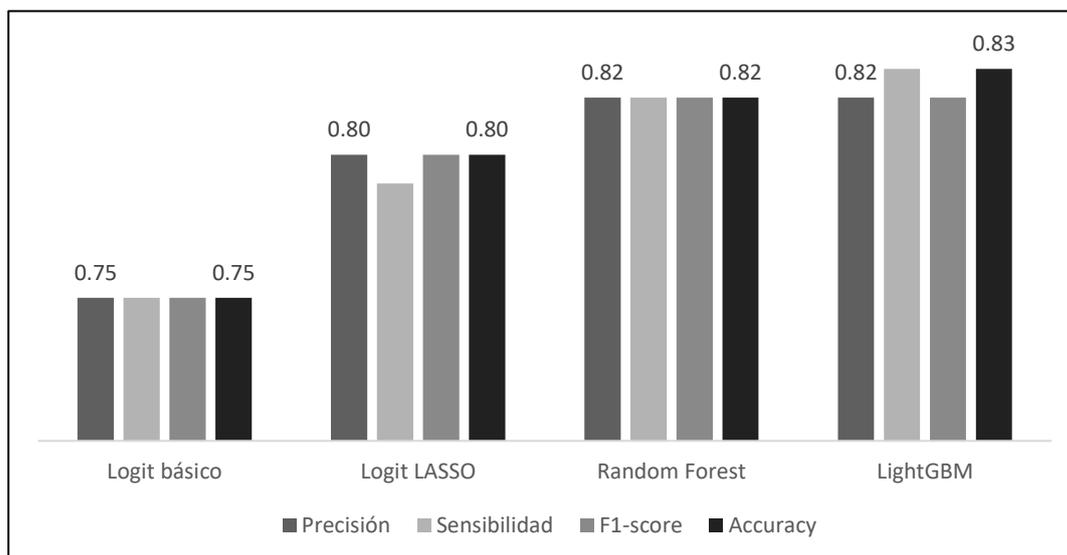
predichos y los valores reales (observados). Para comparar entre modelos se tomará en consideración los reportes de clasificación (análisis de precisión y sensibilidad) y la curva ROC¹⁷. El reporte de clasificación es utilizado para medir la calidad predictiva de cada algoritmo en base a las predicciones correctas e incorrectas. Para ello, genera todas las combinaciones posibles de las predicciones y los valores reales: Verdaderos Positivos (*VP*), Falsos Positivos (*FP*), Verdaderos Negativos (*VN*) y Falsos Negativos (*FN*), y se construyen los indicadores de precisión, sensibilidad (*recall*), F-beta y exactitud (*accuracy*).

La precisión es la capacidad del método de clasificar correctamente los casos positivos, por lo que se calcula como $\frac{VP}{VP+FP}$. La sensibilidad indica la capacidad del método de clasificar correctamente los casos negativos y se calcula como $\frac{VN}{VN+FN}$. Asimismo, el F-beta puede ser interpretada como la media armónica ponderada entre la precisión y la sensibilidad, y toma el valor F-1 cuando se pondera de la misma forma ambos indicadores. Finalmente, la exactitud es una medida global de las predicciones correctas entre el total de predicciones realizadas, y se calcula como:

$$\frac{VP + FN}{VP + FP + VN + FN}$$

A continuación, se presentan los resultados de los cuatro modelos estimados (*logit* básico, *logit* con LASSO, *Random Forest* y *LightGBM*) para la predicción de escuelas con plazas seleccionadas y otorgadas. Los **Gráficos 5** y **6** muestran los reportes de los cuatro indicadores mencionados previamente para cada modelo estimado. Como puede observarse en ambos casos, todos los indicadores son crecientes a medida que se complejiza el modelo. Asimismo, se observa que los modelos *logit* básico y regularizado muestran desempeños similares y son dominados por los modelos de *machine learning*: *Random Forest* y *LightGBM*.

¹⁷ ROC, por sus siglas en inglés *Receiver Operating Characteristic*, significa Características Operativas del Receptor

Gráfico 5*Indicadores del Reporte de Clasificación de Plazas Otorgadas***Gráfico 6***Indicadores del Reporte de Clasificación de Plazas Seleccionadas*

Por otro lado, la curva ROC es un gráfico que muestra el rendimiento de un modelo de clasificación en todos los umbrales de clasificación, con base en dos parámetros: tasa de

verdaderos positivos y falsos positivos. A medida que la curva se aleja de la línea diagonal de 45 grados, el modelo reduce ambos tipos de errores y se vuelve más confiable. Esta característica de la curva ROC permite comparar modelos de manera global. De este modo el Área bajo la Curva ROC (AROC) proporciona una medida agregada del rendimiento en todos los umbrales de clasificación posible. Si este tomara el valor 1, la curva ROC cubriría todo el espacio y, por tanto, minimizaría ambos tipos de errores.

Los Gráficos 7 y 8 muestran las curvas ROC de los modelos estimados y, al igual que el caso anterior, se puede observar que los métodos *Random Forest* y *LightGBM* se desempeñan mejor que los métodos *logit* básico y regularizado, lo que puede comprobarse al analizar el AROC. Las predicciones de plazas otorgadas con los modelos de árboles de decisión (*Random Forest* y *LightGBM*) tienen valores AROC de 0.77 y 0.79, que son superiores a los 0.71 y 0.75 de los modelos *logit* básico y regularizado, respectivamente. Asimismo, las predicciones de plazas seleccionadas siguen los mismos patrones; es decir, se notan incrementos en su precisión a medida que se complejiza el modelo: *LightGBM* (0.83), *Random Forest* (0.82), *Logit* regularizado (0.79) y *logit* básico (0.75).

Gráfico 7

Curva ROC de Clasificación de Plazas Otorgadas

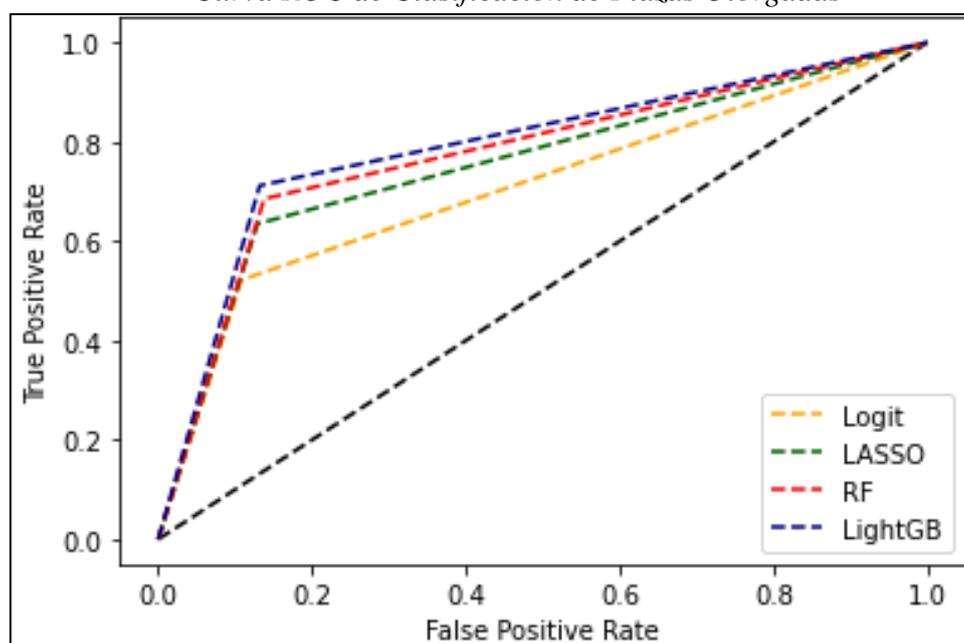
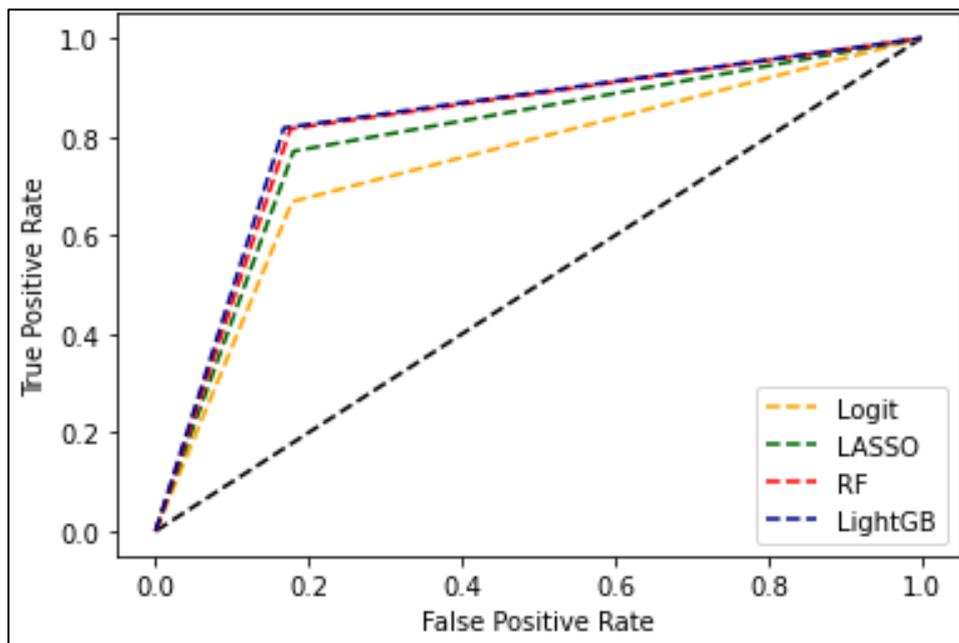


Gráfico 8

Curva ROC de clasificación de plazas otorgadas



De este modo, se puede concluir que los modelos predicen bien tanto las probabilidades de otorgar como de seleccionar una plaza en los concursos de nombramiento de años anteriores. Más allá de las limitaciones de información que se ha tenido en el presente estudio, los predictores utilizados en ambos modelos parecen ser lo suficientemente buenos para lograr buenos indicadores de precisión y exactitud, en concordancia con la literatura revisada. Por lo tanto, gracias a esta sección, se puede tener dos conclusiones adicionales.

Primero, los modelos árboles se desempeñan mejor que los modelos básico y regularizado, siendo las diferencias lo suficientemente grandes como para afirmar ello. Asimismo, dentro de los modelos de árboles, se nota una ligera superioridad no concluyente de los modelos *LightGBM* con respecto a los *Random Forest*. Sin perjuicio de los resultados, en el presente trabajo se utilizará el modelo *LightGBM*, pero las conclusiones y predicciones no serán afectadas por ello.

Segundo, los modelos estimados se desempeñan mejor para predecir la probabilidad de seleccionar una plaza que para otorgarla. El modelo *LightGBM* de seleccionar una plaza tiene

un AROC de 0.83, mientras que el de otorgar una plaza un AROC de 0.79. Esto puede deberse a que la etapa de selección de plazas refleja mejor las decisiones de los docentes en base a características de las escuelas y su entorno; mientras que la etapa de otorgamiento, depende de los algoritmos de asignación de los concursos a cargo la Dirección de Evaluación Docente (DIED), así como del número y la calidad de los postulantes por plaza, algo que probablemente no esté siendo aproximado tan bien con los predictores utilizados en el presente estudio.

5.2. Principales Predictores

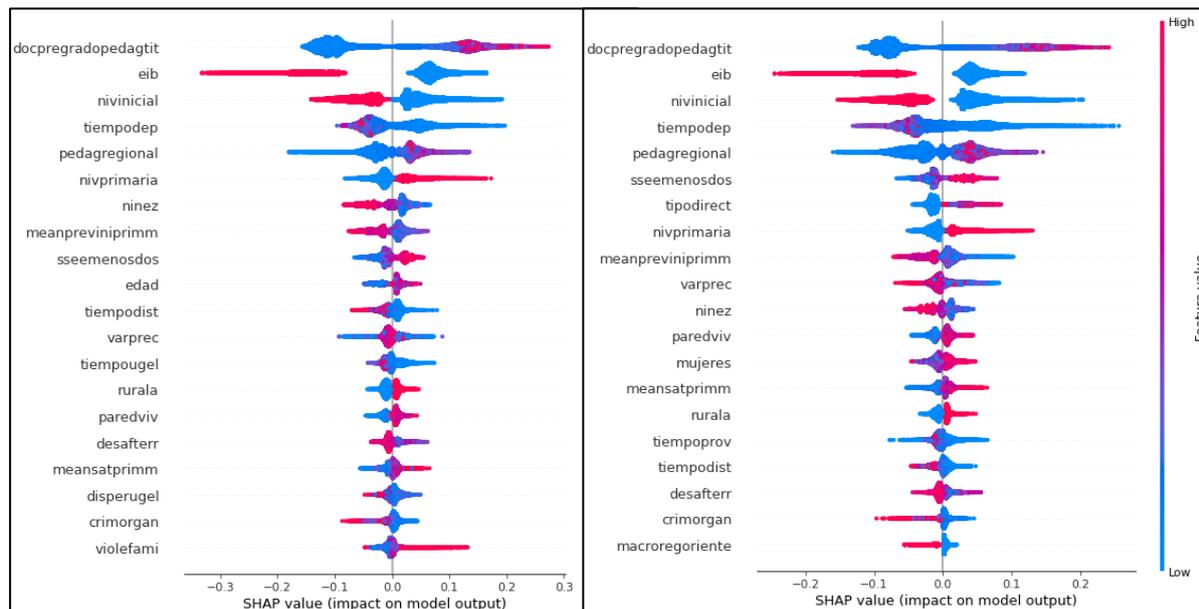
El modelo *LightGBM* es una combinación de modelos de árboles de decisión y, por tanto, no tienen parámetros que puedan compararse directamente como ocurre en otros tipos de modelos. Sin embargo, sí es posible construir una aproximación a la importancia de los predictores en base a los pesos de los árboles de decisión.

Bajo esa lógica, se elabora y presenta los gráficos SHAP (*Shapley Additive Explanations*) de los modelos predictivos de la probabilidad de ocupar y seleccionar una plaza. Estos gráficos ayudan a entender la importancia y dirección de los principales predictores que tiene el modelo. Por un lado, el eje Y indica el nombre de la característica, en orden de importancia de mayor a menor. Por otro lado, en el eje X se muestran los valores SHAP que indican la magnitud del cambio en *log-odds* centrados en cero.

Así, hacia el lado derecho se muestra la magnitud de la característica “ x ” que correlaciona positivamente con la ocurrencia del evento (no ocupar plaza docente); mientras que, hacia el lado izquierdo, la magnitud de la correlación negativa con la ocurrencia del evento. Finalmente, la gradiente de color se torna rosa a medida que la característica analizada toma valores mayores y torna más azul a medida que toma valores menores.

Gráfico 9

Importancia de Predictores



Nota: En el eje Y indica el nombre de la característica, en orden de importancia de mayor a menor, mientras que en el eje X se muestran los valores SHAP que indican la magnitud del cambio en *log-odds* centrados en cero. Los colores rosados muestran valores mayores de las variables y los azules valores más menores.

El panel A del Gráfico 9 muestra las principales características que explicarían la probabilidad de seleccionar una plaza en un concurso de nombramiento; mientras que, en el panel B, lo mismo para el otorgamiento de plaza. Ambos bajo el ajuste del modelo *LightGBM*. Las características más relevantes en ambos modelos son similares y están alineadas a estudios previos, tal como se explicará a continuación.

En ambos modelos, el predictor más relevante es una aproximación a la vulnerabilidad o discapacidad actual de cada escuela. Por ejemplo, una escuela que actualmente tiene menos docentes con título pedagógico (*docpregradopedagtit*) es, probablemente, una escuela poco deseable y, por tanto, esto se refleja en su correlación negativa (lado izquierdo del gráfico SHAP) con la probabilidad de que la plaza sea seleccionada u otorgada en un concurso de nombramiento. Esta característica ha sido seleccionada por el modelo como la más relevante por fines predictivos, pero no se le puede dar una interpretación de política educativa.

Aun así, existen otros indicadores que, probablemente, sí estén más relacionadas al conjunto de características que evalúan los docentes en su proceso de toma de decisiones al momento de seleccionar una plaza, así como su posterior otorgamiento. Una de ellas es el tiempo a la capital regional (*tiempodep*). Tal y como se espera, a medida que es menor (más azul) se correlaciona negativamente con la probabilidad de no ocupar una plaza en el concurso de nombramiento. Otras características relevantes y robustas en ambas estimaciones es ser una escuela de Educación Intercultural Bilingüe (*eib*) o de Educación Inicial (*nivinicial*). De esta manera, ser una escuela EIB o de educación inicial correlaciona negativamente con la selección y otorgamiento de una plaza.

También existen otras características, tales como la presencia de una Institución de Educación Superior (IES), específicamente, de un Instituto Superior Pedagógico en la región (*pedagregional*). Esto es consistente con otros estudios para el caso peruano, tales como los trabajos de Jaramillo (2013) y Bertoni et al. (2019). En cuanto a las características del entorno de la escuela que son relevantes y que también podrían ser parte del proceso de decisión de docente, se tiene a la infraestructura de las viviendas en el centro poblado donde está ubicada la escuela (*paredviv*) o la estructura demográfica del entorno de la escuela (menor población en etapa de niñez) (*ninez*).

Finalmente, existe un grupo de características del entorno no físico que son importantes de resaltar. Estos son i) estar situado en un lugar con alto riesgo de criminalidad, como el crimen organizado (*crimorgan*) o violencia familiar (*violefami*); ii) y el costo de vida, con el indicador de inflación utilizado (*varprec*).

En resumen, se ha identificado las principales características de la escuela y su entorno que correlacionan con la probabilidad no tener plazas otorgadas durante un concurso de nombramiento. A pesar de lo razonable que puedan parecer y del respaldo en evidencia empírica que tengan, deben ser interpretadas con precaución dado que solo muestran

correlaciones y no necesariamente causalidad. Sin embargo, estas características ayudan a predecir la probabilidad de no ocupar una plaza e identificar a las IIEE que tienen mayor riesgo de no ser cubiertas en un concurso de nombramiento.

5.3. Predicción de los Modelos

A partir de los modelos estimados se predicen las probabilidades de que una escuela tenga una plaza seleccionada u otorgada en un concurso de nombramiento en todas escuelas de Educación Básica Regular de los niveles inicial, primaria y secundaria. Para ello, se toman las características de la escuela y de su entorno del año 2019 y se predicen las probabilidades para cada escuela (59,212 escuelas).

El Gráfico 10 muestra los resultados agregados a nivel provincial de las probabilidades de seleccionar o ganar una plaza. Estos resultados son consistentes con lo observado en los concursos de nombramiento de los años anteriores. Las zonas del mapa con menor intensidad de color indican las provincias con mayor probabilidad de tener plazas seleccionadas o ganadoras en los concursos de nombramiento. Del mismo modo, las provincias con mayor intensidad de color son las que concentran la mayor cantidad de IIEE con baja probabilidad de tener una plaza ganadora en un concurso de nombramiento.

Como es de esperarse, en promedio, las probabilidades que una plaza sea seleccionada en un concurso de nombramiento son mayores a las probabilidades de que se otorgue (ver escalas de las probabilidades). Asimismo, se observa que existe mayor probabilidad de no ocupar una plaza en escuelas pertenecientes a la región natural selva y nororiente (tonalidad más clara) y mayor probabilidad de ocuparla si la plaza pertenece a las provincias de la región natural costa.

Sin embargo, también se nota la existencia de heterogeneidades dentro de los niveles más agregados: nacional, región natural, área o incluso a nivel departamental. Es decir, si bien las probabilidades de seleccionar u otorgar una plaza son mayores en la costa o en zonas

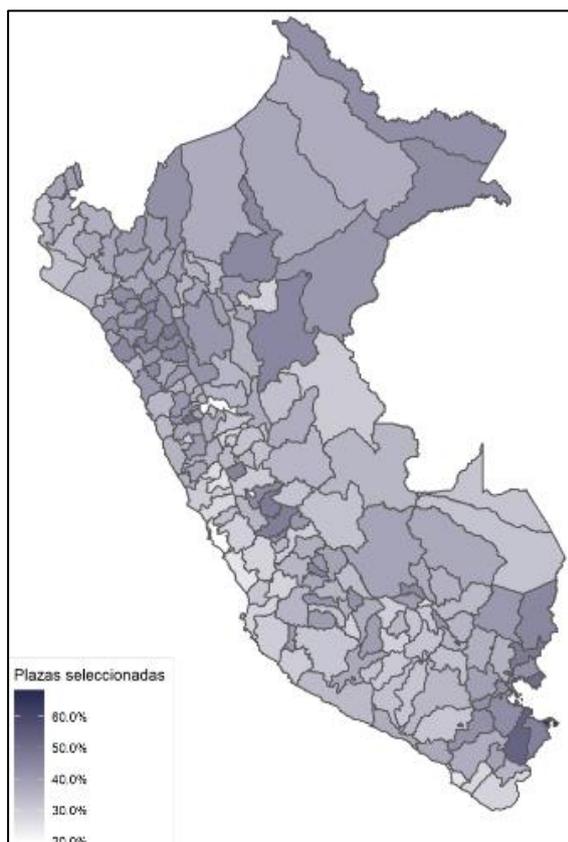
urbanas, también existen dentro de ellas, provincias con probabilidades menores. Asimismo, dentro de un mismo departamento se observan diferentes probabilidades de que las plazas sean seleccionadas u otorgadas en un concurso de nombramiento.

Este es un punto central del presente estudio pues evidencia, que si bien los niveles más agregados (escuelas urbanas, costeras, más cercanas) son buenas aproximaciones, resultan insuficiencia para capturar toda la heterogeneidad existente entre las escuelas en los concursos de nombramiento. Por ello, la siguiente sección se enfocará en las plazas “menos atractivas” para construir nuevas clasificaciones que ayuden a orientar el diseño de políticas de atracción docente en el Perú.

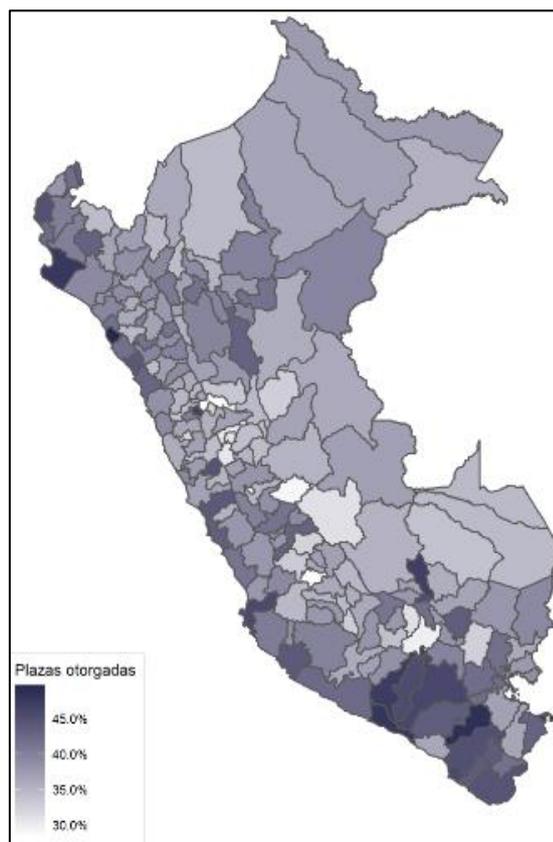
Gráfico 10

Predicción de la Probabilidad de Otorgamiento y Selección de Plazas

Panel A: Selección de plaza



Panel B: Otorgamiento de plaza



Nota: La intensidad del color se ajusta a la proporción de plazas en las provincias que no han sido seleccionadas u ocupadas. Por ende, las zonas más azules indican mayor proporción de plazas no seleccionadas u otorgadas en los concursos de nombramiento.

5.4. Análisis de Conglomerados

En la subsección anterior se determinó la probabilidad de ser seleccionado o no por un docente en un concurso de nombramiento y, con este insumo, se pudo identificar a las escuelas con alta y baja probabilidad de ser seleccionadas. En la presente sección, el análisis se enfocará en las escuelas “menos atractivas”, que, de acuerdo con la clasificación propuesta, son 26,980 escuelas (45.5% del universo de escuelas).

Enfocarnos en este grupo nos permitirá identificar políticas de atracción que respondan a necesidades específicas y un paso necesario es reconocer que dichas escuelas no son homogéneas y, por tanto, responden a diferentes incentivos y políticas. Así, las escuelas “menos atractivas” pueden serlo por estar ubicadas en zonas de difícil acceso, por sus características internas (i.e. plana directiva, tamaño de la escuela, infraestructura) o las características de su entorno (i.e. niveles de violencia, acceso a servicios). Asimismo, las políticas o incentivos serán distintas, incluso si nos referimos a una misma política. Por ejemplo, el monto de un incentivo monetario será distinto si nos referimos a una característica de lejanía o de entorno violento.

Para identificar qué tan similares entre ellas o no son las escuelas de este grupo, se aplicó un modelo de *Machine Learning* no supervisado que construye conglomerados jerárquicos basados en la media de los grupos. Conceptualmente, es un algoritmo que reduce la distancia euclidiana de las características de los individuos, de modo que se construyan grupos similares entre sí y distintos entre ellos. Para lograr grupos más parsimoniosos y reducir las dimensiones bajo análisis, partimos de las principales características (“*features*”) del modelo *Light Gradient Boosting* y la cantidad de conglomerados se define utilizando las pruebas de Caliński y Harabasz y de Duda-Hart, que determinaron la conformación de cinco grupos¹⁸¹⁹.

¹⁸ El Anexo N° 5 muestra los resultados para 3 y 4 conglomerados. Los resultados muestran que las agrupaciones de escuelas identificadas son robustas a modificaciones del número de conglomerados. Específicamente, reducir el número de conglomerados preserva las agrupaciones de escuelas de alta y media dispersión, y solo tiende a subdividir los grupos restantes.

¹⁹ Adicionalmente, se realizó un análisis de sensibilidad excluyendo de la muestra a las escuelas con una distancia mayor a 4,000 minutos de la capital departamental, equivalente a una reducción de 298 escuelas y 50 minutos (en

La Tabla 2 muestra los resultados de la agrupación de escuelas en conglomerados de las más de 26 mil escuelas que tienen una baja probabilidad de ser seleccionada en un concurso de nombramiento, mientras que la Tabla 3 su distribución por departamento.

Tabla 2

Conglomerados de Escuelas con Baja Probabilidad de ser Seleccionadas

	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
Número de escuelas	624	3,474	10,130	8,281	4,381
Tiempo (en min) al departa.	3955	899	299	210	82
Tiempo (en min) a la provincia	1489	599	145	114	44
Tiempo (en min) al distrito	705	313	73	51	23
Tiempo (en min) a la UGEL	1492	570	140	98	41
Presencia de instituto pedagógico	5	8	8	8	30
Vivienda con pared en buen estado (CCPP)	0.05	0.25	0.40	0.58	0.65
Vivienda con techo en buen estado (CCPP)	0.27	0.49	0.61	0.65	0.70
Vivienda del CPPP con acceso a agua	0.06	0.23	0.43	0.49	0.65
Vivienda del CPPP con acceso a luz	0.22	0.33	0.51	0.59	0.72
EIB	0.74	0.62	0.43	0.37	0.05
Total de alumnos	74.7	37.9	83.0	115.4	393.8
Ratio alumno por sección	10.6	7.1	10.6	13.7	23.7
Docentes con título pedagógico	2.5	2.5	5.8	7.0	19.4
Violencia familiar	265.4	752.9	610.2	1102.0	896.8
Crimen organizado (nro. denuncias)	2.5	25.1	18.2	30.1	197.9
Tráfico de drogas (nro. denuncias)	13.6	43.0	29.8	7.8	536.2
Crimen organizado (tasa por 1000 hab.)	0.003	0.031	0.026	0.031	0.026
Tráfico de drogas (tasa por 1000 hab.)	0.023	0.065	0.049	0.010	0.072

Nota: Se presentan los valores promedios de los principales predictores de la probabilidad de seleccionar u ocupar una plaza para cada uno de los cinco conglomerados de escuelas “menos atractivas”.

Tabla 3

Conglomerados de Escuelas por Departamento

	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
Amazonas	3	193	555	0	6
Ancash	0	107	1,254	5	28
Apurímac	0	28	0	1,079	0
Arequipa	0	105	0	773	3

promedio) y se volvieron a construir todos los conglomerados (K = 3, 4 y 5). Si los resultados fueran sensibles a la exclusión de estas escuelas, entonces, la composición de los conglomerados debería variar significativamente, lo que es probable al modificarse el promedio de los grupos. A pesar de ello, se observa que, en líneas generales, el número de escuelas y las características de los conglomerados se preservan

Ayacucho	0	458	974	0	30
Cajamarca	0	282	1,323	0	13
Callao	0	0	0	162	116
Cusco	0	248	0	1,336	16
Huancavelica	0	81	1,094	0	3
Huánuco	0	274	1,104	201	56
Ica	0	7	0	612	35
Junín	0	389	0	1,302	37
La Libertad	1	99	692	0	38
Lambayeque	0	86	0	531	46
Lima	2	40	0	0	3,695
Loreto	583	267	452	0	14
Madre de Dios	0	31	0	145	6
Moquegua	0	12	0	126	0
Pasco	0	272	238	88	5
Piura	3	93	67	1,543	73
Puno	2	18	839	0	25
San Martín	0	72	1,050	0	40
Tacna	0	0	0	261	8
Tumbes	0	0	0	117	4
Ucayali	30	312	488	0	84
Total	624	3,474	10,130	8,281	4,381

Nota: Se presenta el número de escuelas por región para los cinco conglomerados de escuelas “menos atractivas”.

Como es de esperarse, al enfocarnos en las escuelas “menos atractivas”, se observan características más desfavorables. Sin embargo, también se observan diferencias entre los grupos construidos, tanto en características como en su distribución espacial.

El primer grupo está conformado por escuelas extremadamente dispersas, alejados de las capitales departamentales, provinciales y distritales y precarias condiciones de acceso a servicio e infraestructura, entre otros aspectos relacionados. Para tener una idea de la dispersión de estas escuelas, están a 30 horas de su UGEL y casi a 3 días de la capital departamental. Asimismo, casi la totalidad de estas escuelas están concentradas en la región natural selva (98.7% de este grupo), específicamente en las provincias de Datem del Marañón y Alto Amazonas del departamento de Loreto (59.6% de este grupo)²⁰, tal como puede observarse en el Gráfico 11.

²⁰ Sin embargo, solo representan el 8.2% de las escuelas del departamento de Loreto.

Gráfico 11

Escuelas “no atractivas” de Mayor Dispersión (Grupo 1)



En las escuelas de este grupo, las políticas de incentivos monetarios o no monetarios son necesarias, pero probablemente también sean insuficientes. En el corto plazo, además de las políticas de atracción docente que incrementen la probabilidad de provisión de docentes públicos, se sugiere diseñar e implementar intervenciones remediales complementarias que aseguren la calidad de la oferta educativa, que conlleven a mejores logros de aprendizajes y menores tasas de abandono escolar.

Una alternativa, podría ser la implementación de modelos híbridos de educación utilizando tecnologías educativas y educación a distancia otorgadas por las estrategias de Cierre de Brecha Digital (entrega de tabletas a estudiantes y docentes) y Aprendo en Casa (educación a distancia) desarrolladas en el marco de la pandemia COVID-19, que tienen antecedentes en intervenciones como las Telesecundarias o las Telecurso en México y Brasil, respectivamente (Navarro-Sola, 2019).

Otra alternativa es la contratación de habitantes no entrenados pertenecientes a dichas comunidades que ayuden a brindar un servicio educativo complementario, lo que en la literatura se le conoce como “para-docentes”. Banerjee et al. (2007) y Eble et al. (2021) muestran su efectividad como oferta educativa complementaria y por fuera del horario regular (en extra-horario o campamentos de verano), en lugares rurales y dispersos en la India y Gambia²¹. De acuerdo a este último, los para-docentes son potencialmente más motivados, más susceptible a monitoreo frecuente y menos probable de sufrir problemas de selección adversa en comparación a los docentes, pero deben ir acompañados de una capacitación, planes de lección y monitoreo.

Por otro lado, en el largo plazo, las políticas deben enfocarse principalmente en asegurar la provisión de oferta de docentes de dichos lugares. Tal como se muestra en la sección previa y en otros estudios (Bertoni et al. 2020, Jaramillo 2013), la presencia de institutos de formación docente, es un determinante de la demanda de plazas en escuelas públicas.

Tal como se discutirá en la próxima sección, la inversión en mejoramiento de universidades con carreras de educación o institutos pedagógicos es esencial para proveer oferta docente de calidad. Sin embargo, podría ser insuficiente en escuelas del grupo más disperso presentado en el análisis de conglomerados. Por ello, deben complementarse con estrategias de concientización o provisión de becas para estudiantes locales. El análisis de conglomerados podría ayudar a focalizar tanto las políticas de corto como de largo plazo, discutidas en la presente sección.

El segundo grupo está conformado por escuelas muy dispersas pero accesibles y ligeramente con mejores condiciones básicas que el grupo anterior. Este grupo de escuelas sigue siendo de difícil acceso (23 horas a su UGEL) y muy vulnerables (menos de la tercera parte de las viviendas del centro poblado tiene acceso a servicios básicos). Como se observa en la Tabla

²¹ Eble et al. (2021) desarrollan una intervención remedial que combina para-docentes, planes de lección guiados y monitoreo frecuente centrado en la práctica docente, que tuvo impactos de 3.2 desviaciones estándar en aprendizajes.

3, en este grupo no se observa la alta concentración en algunos departamentos, como sí ocurre en el grupo anterior. No obstante, se observa una fuerte participación de departamentos de la sierra (Ayacucho y Pasco) y selva (Ucayali, Loreto y Amazonas), principalmente.

Las políticas de largo plazo discutidas para el grupo más disperso también deberían ser implementadas en las escuelas de este grupo, pero las políticas de corto plazo deberían enfocarse en la atracción de los docentes. En la próxima sección se analizará las políticas actuales de atracción docente del MINEDU. Pero dada las condiciones de vulnerabilidad de este grupo, los incentivos monetarios podrían ser insuficientes, por lo que otros tipos de políticas (incentivos no monetarios) o herramientas (economía del comportamiento, modificaciones en los concursos) deberían ser implementadas de manera complementaria.

En comparación a los dos grupos anteriores, el tercer y cuarto grupo de escuelas muestran mejoras considerables en las condiciones básicas del entorno a la escuela y dispersión. Asimismo, el tercer grupo tiene alta concentración de escuelas situadas en departamentos de la sierra, pero con altos niveles de pobreza (Ancash, Cajamarca, Huancavelica, Huánuco), mientras que el cuarto grupo tiene alta concentración de escuelas en departamentos de la costa (Tumbes, Piura, Moquegua, Ica, Callao) o de la sierra con menores niveles de pobreza (Arequipa, Cusco, Junín). Ello podría ayudar a explicar las diferencias de accesibilidad y distancia a los centros urbanos, así como de acceso a servicios básicos entre el tercer y cuarto grupo.

En términos de políticas de atracción docente, los incentivos monetarios podrían ser suficientes para reducir la brecha de atracción docente en estas escuelas. Por ello, en la próxima sección se analizará su efectividad en el contexto internacional y hará un análisis crítico de los actuales incentivos monetarios que se implementan en el Perú.

Finalmente, el quinto grupo está conformado por escuelas más urbanas y con entornos más favorables (en infraestructura y acceso a servicios), aunque clasificadas como “menos

atractivas”. Tal y como puede observarse en la Tabla 3, las escuelas de este grupo están muy concentradas en Lima y Callao (87%) y específicamente en distritos de Lima Metropolitana con bajos niveles de ingreso: San Juan de Lurigancho (283), Ate (184), San Martín de Porres (156), Comas (154), Villa El Salvador (135), Villa María del Triunfo (133), entre otros.

De acuerdo con las características de vulnerabilidad y accesibilidad, las escuelas de este grupo no deberían ser parte de las “menos atractivas”. Sin embargo, tienen entornos desfavorables de alta criminalidad que se visibiliza en indicadores como el crimen organizado, tráfico de drogas y violencia familiar. Lamentablemente, los indicadores que se disponen para el presente estudio son a nivel agregado, por lo que es necesario acceder a datos de criminalidad con mayores niveles de desagregación e implementar estudios específicos en este grupo de escuelas, lo que queda para una agenda futura de investigación.

6. Análisis y Recomendaciones de las Políticas Enfocadas en la Atracción Docente

La sección anterior identifica a las escuelas con baja probabilidad de ser seleccionada en los concursos de nombramiento y se enfoca en las escuelas “menos atractivas” para construir conglomerados de escuelas. Estas agrupaciones evidencian que las escuelas clasificadas como “menos atractivas” son muy heterogéneas y no existe una “receta” única para abordar esta problemática. Como ya se vio, existen grupos de escuelas que requieren de políticas de atracción docente de corto plazo; mientras que otras, de largo plazo.

Otras agrupaciones requieren combinaciones de políticas de atracción docente (incentivos monetarios y no monetarios), mientras que otras requieren incluso políticas articuladas con otros sectores. Por último, incluso si se analiza las políticas de atracción más comunes para abordar esta problemática, tal como los incentivos monetarios, existen diversas consideraciones a tomar en cuenta para el caso peruano.

La presente sección busca formalizar esta discusión, así como el debate sobre potenciales políticas de atracción que ayuden a mejorar la distribución de docentes en las plazas

menos atractivas. Para ello, un siguiente paso es revisar qué políticas de atracción se han implementado en Latinoamérica y en otros países en desarrollo y qué resultados han obtenido. Posteriormente, se busca revisar las intervenciones y políticas de atracción docente implementadas por el MINEDU con la finalidad de analizar su diseño y entender si responden a la tipología y características identificadas en el análisis de oferta y demanda de plazas.

En base a los resultados obtenidos, esta sección busca plantear recomendaciones de política que se alineen a: (i) las necesidades de los docentes que determinan la elección de una plaza y (ii) compensar aquello que hace que una plaza sea menos atractiva a sus pares. Este conjunto de políticas (viables) responden a la reducción de la brecha en cuanto a la probabilidad de que una plaza sea escogida. De este modo, si bien cada plaza posee características diferentes, la existencia de políticas dirigidas a grupos específicos de estas puede incrementar su atracción y su probabilidad de ser ocupada.

6.1. Políticas en el Contexto Internacional

Siguiendo la línea de Chetty et al. (2014) y Hanushek y Rivkin (2012), diversos estudios en América Latina se enfocan en fomentar mejoras en la productividad de los docentes, pues ello no solo mejora los resultados educativos de corto plazo, sino también de largo plazo en los estudiantes. En Ecuador, existe una mayor contribución por parte de los docentes hacia los resultados de los estudiantes cuando estos provienen de hogares en condición de pobreza. No obstante, gran parte de los sistemas educativos en la región carecen de docentes en las escuelas vulnerables (ubicadas en zonas rurales, población indígena, educación especial, menores niveles socioeconómicos, etc.) (Araujo et al., 2016).

Este problema se observa, principalmente, en la educación secundaria y preescolar. Además, es mucho más persistente en aquellas áreas del currículo que requieren mayor especialización, como matemáticas, ciencias y lenguas distintas al castellano (Bertoni et al., 2020). Elacqua et al. (2018) mencionan que la desigualdad en la distribución de los docentes

responde, en parte, a que los docentes más calificados eligen enseñar en escuelas con mejores condiciones. Esto conlleva a que los que enseñan en IIEE vulnerables sean precisamente los menos calificados. Ello, sumado al hecho de que atraer docentes (ya sean calificados o no) es muy difícil en dichas escuelas, presenta un reto para los formuladores de política al diseñar estrategias que reduzcan la brecha observada.

A continuación, se exponen algunas políticas que se implementaron en el contexto internacional con el fin de atraer más y mejores docentes. Sin embargo, no en todos los casos se tuvo éxito con la implementación de las medidas²².

a) Incentivos Monetarios. Evans, Yuan y Filmer (2020) afirman que los maestros tienen casi dos veces más probabilidades de tener un segundo empleo que otros trabajadores en países en desarrollo. Esto debido a que sus sueldos mensuales son inferiores a los de otros trabajadores del sector formal con niveles de educación y experiencia comparables. Si bien el incremento salarial está directamente relacionado con la atracción de profesionales de calidad a un sector, esto no necesariamente sucede en el caso de los docentes (Ferraz y Finan, 2009; Dal Bó, Finan y Rossi, 2013; Dolton et al., 2011). En Indonesia, De Ree et al. (2018) mostraron que los aumentos sustanciales en la remuneración de los docentes solo incrementó los niveles de satisfacción laboral, mas no su desempeño.

Un caso interesante es el de Gambia, donde se otorgó un subsidio de entre 30% y 40% del salario a los profesores de escuelas primaria alojadas en zonas remotas. Este era una compensación por alojarse en zonas cuyas condiciones de vida eran más difíciles. El estudio de Pugatch y Schroeder (2014) muestra que el programa de subsidios incrementó la tasa de docentes calificados en zonas rurales en 10 puntos porcentuales (pp.). No obstante, esto no fue suficiente para atraer docentes en las escuelas más alejadas.

²² En el Anexo N° 6 se agrega un cuadro resumen de las principales políticas implementadas según el país.

En Uruguay, se focalizó a las escuelas con mayores desventajas a través de un programa donde los docentes podrían ganar mayores salarios en caso accedan a ir a enseñar. Según Cabrera y Webbink (2018), el programa tuvo resultados satisfactorios en contratar a docentes con mayor experiencia (*proxy* de calidad) y en retenerlos. Sin embargo, los efectos sobre los estudiantes fueron muy pequeños.

Por su parte, Brown y Andrabi (2020) realizan un ejercicio de elección de contratos (sin costo de cambio) y un experimento aleatorio controlado (RCT por sus siglas en inglés) para analizar si una remuneración por rendimiento permite a las escuelas atraer y retener docentes de calidad en Pakistán. Los autores encuentran que aplicar remuneraciones condicionadas permite clasificar a los docentes por su calidad y por su capacidad de respuesta a los incentivos. Asimismo, se evidencia que la magnitud del efecto de esta intervención depende de los costos de cambio de escuela y del alcance de información de los docentes.

Adicionalmente, con el objetivo de predecir su calidad, la elección del tipo de contrato por parte del docente es tres veces más eficaz que basarse solo en la información de los directores y lugar de residencia del docente. Se detalla también que la preferencia por una remuneración por rendimiento entre docentes variará entre un 86% y 44% dependiendo del tamaño del incentivo, la permanencia y la facilidad de los costes de cambio de escuela. Además, dado que unos incentivos mayores y más permanentes podrían atraer a personas fuera del sector de la enseñanza para que se incorporen a la profesión.

Similar al caso anterior, en Chile, Elacqua et al. (2019) encontraron que el programa de Asignación de Excelencia Pedagógica incrementó la retención de docentes entre 22 y 29 puntos porcentuales (pp) en las escuelas vulnerables. Este programa consistía en la entrega de subvenciones económicas según el desempeño de los docentes. Para ello, se le sometía a una evaluación de manera voluntaria a la que podían participar si cumplían con dos requisitos: i)

enseñar un mínimo de 20 horas por semana y ii) postular a una categoría específica según el nivel y curso que enseñaba.

La evaluación constaba de dos partes. La primera parte consistía en un set de preguntas de opción múltiple, mientras que la segunda parte era una prueba escrita con un set de preguntas abiertas, las cuales se evaluaban según las rúbricas definidas. La combinación de los resultados de ambas partes consolidaba el resultado final de los docentes. Así, el monto que recibían los docentes dependía de su desempeño en la evaluación y era de manera proporcional a sus salarios. El programa ofrecía tres niveles de premios: el primer nivel recibía el 33% de su salario base; el segundo nivel recibía el 22% y el tercer nivel recibía el 11%. Además, por un tema de equidad, los docentes de escuelas vulnerables recibían un incentivo adicional de 40% del premio.

b) Incentivos no Monetarios y Estrategias Informativas. Si bien los incentivos monetarios son los mecanismos más utilizados para la atracción docente; también existen casos en los que no necesariamente se incide en los ingresos de los docentes para su atracción al sistema educativo. Mulkeen (2005) menciona que, si bien los pagos son importantes, en zonas rurales, donde menos llega la educación, el costo no solo es monetario, sino también implica transporte y acceso a diversos servicios.

Por ejemplo, en Colombia, debido a la existencia de brechas educativas relacionadas con la ubicación y tipo de contratación docente; las escuelas vulnerables suelen tener docentes con menores niveles educativos, menos experiencia y con contratos provisionales (Figuroa et al., 2018). Además, alrededor del 15% de las vacantes definitivas eran ocupadas por docentes provisionales. Por ello, una política que se implementó fue la creación del Banco Nacional de la Excelencia, cuyo objetivo fue centralizar la información de dichas vacantes y contar con un proceso meritocrático para nombramientos provisionales.

Otro caso interesante es el de Ecuador, donde Drouet y Westh (2020) analizan la centralización de la asignación docente y las mejoras en el algoritmo y plataforma del sistema informático del Ministerio de Educación del Ecuador (SIME). Los autores mencionan que la presentación de la información en la plataforma web sirvió para evidenciar una cobertura del 76% de las vacantes publicadas, porcentaje mayor a lo registrado en el concurso previo (69%). Además, los puntajes promedio obtenidos por los docentes mejoraron en un 11.2% respecto al último concurso.

Entre los cambios y mejoras mencionados por los autores se tiene una mayor importancia a los puntajes obtenidos en las fases de méritos y conocimientos en relación a la selección del lugar de postulación. Por otro lado, el cambio en la plataforma consistió en presentar el nombre de la escuela, la dirección donde se ubica, el total de vacantes ofertadas y el número de postulaciones realizadas sobre esa vacante a la fecha y hora de la postulación de un nuevo aspirante.

Mulkeen (2005) también revela que en países como Malawi y Uganda se encuentra una fuerte asociación entre la disponibilidad de casas en un área y la presencia de profesoras en las escuelas. Por ese motivo, algunas políticas están enfocadas en la construcción de casas para los docentes. Algo similar sucede en Mozambique, donde, si bien el Ministerio no provee casas para los profesores, existen Organizaciones No Gubernamentales que se encargan de ello, lo cual incrementa la atracción de docente a las zonas rurales del país.

6.2. Políticas en el Contexto Nacional

I) Políticas de Corto Plazo

a) Incentivos Monetarios. Los incentivos monetarios son las políticas más comunes y efectivas para atracción docente (Glazerman, 2012; Rosa, 2017; Elacqua, 2019). Este tipo de políticas son útiles cuando se busca compensar, de algún modo, ciertas desventajas de algunas escuelas frente a otras, ya sea por su ubicación o a que el tipo de público que atienden requiere

de esfuerzos diferenciados. Asimismo, estas políticas se utilizan a modo de compensación por algún determinado mérito o logro destacado.

Si bien estas políticas son las más comunes por su facilidad de implementación, no están exentas de aspectos desfavorables. La principal crítica es el impacto fiscal que generan. El MINEDU invierte alrededor de S/150 millones soles de su presupuesto anual en sus dos principales incentivos monetarios: i) el bono atracción docente y ii) las asignaciones temporales.

El Bono de Atracción Docente es el principal incentivo monetario para atraer docentes de mayor calidad a las escuelas públicas, en el marco de los concursos de nombramiento. El bono se otorga solo a los postulantes que se ubiquen en el tercio superior del orden final de méritos de los concursos de nombramiento para el ingreso a la CPM, con el compromiso de que los beneficiarios permanezcan en la CPM por lo menos 3 años adicionales posteriores al término del beneficio²³. El monto total asciende a S/ 18,000 y es abonado a los beneficiarios en tres (3) armadas anuales de 6 mil soles durante tres (3) años consecutivos; siendo equivalente a aproximadamente tres salarios básicos de un docente (docente contratado o nombrado en primera escala).

Al ser un incentivo universal (todos los docentes están expuestos al incentivo), el bono no tiene evidencia de su efectividad en atraer nuevos docentes a la CPM. Sin embargo, una evaluación de impacto interna llevada a cabo en el MINEDU (MINEDU, 2020²⁴) muestra que el bono no es efectivo en retener a los docentes en la plaza o escuela asignada si se compara

²³ Entre los requisitos para que los docentes gocen de este beneficio por los tres años, se tiene que, en el segundo y tercer año, los beneficiarios deberán: i) Tener nombramiento vigente; ii) Haber realizado labor efectiva como docente en una IE por lo menos cinco (05) meses continuos o acumulados durante el año lectivo; y iii) Haberse comprometido a permanecer en la CPM por al menos 3 años adicionales posteriores al término del beneficio.

²⁴ Esta evaluación de impacto fue realizada por la Oficina de Seguimiento y Evaluación Estratégica (OSEE), quienes facilitaron los resultados para los fines del presente estudio. Para evaluar el impacto del bono se comparó a los ingresantes a la CPM que recibieron el Bono con los ingresantes a la CPM comparables que no lo recibieron. Se empleó la metodología de Regresión Discontinua Difusa (RDD), utilizando como punto de corte el puntaje obtenido por el último ingresante en el tercio superior del orden de méritos del concurso de nombramiento 2015 que tuvo 8,137 docentes ingresantes, de los cuales 2,702 docentes fueron beneficiados por el bono. Los datos utilizados provienen de diversos registros administrativos producidos por el Minedu en este periodo de tiempo.

con docentes que marginalmente no fueron ganadores. Esta evaluación de impacto fue realizada con datos del periodo 2016-2019 para el bono que corresponde al concurso de nombramiento 2015. La principal hipótesis de estos resultados es que los docentes ganadores del bono están en ubicados en escuelas de alta atracción docente (poco vulnerables), por lo que la deserción de docentes no es un problema per se.

El otro incentivo monetario que tiene el Ministerio de Educación son las Asignaciones Temporales, las cuales buscan atraer docentes a escuelas clasificadas como vulnerables. Estas asignaciones tienen una frecuencia mensual y constituyen incentivos para ejercer la docencia en escuelas ubicadas en contextos que pueden resultar más desafiantes para los docentes.

En línea con los estudios de Pugatch y Schroeder (2014) y Cabrera y Webbink (2018), el objetivo de estas asignaciones es atraer a los docentes a las poblaciones vulnerables y a escuelas con características específicas. Esto se debe a que se busca compensar directamente a los docentes porque el costo de atender en estas escuelas es mayor, ya sea por ubicación o por característica.

Por ejemplo, en términos de ubicación, laborar en una IE rural 1 es más costoso en términos de traslado, pues se está mucho más alejado de la ciudad que una IE en zona rural 3. En términos de características de la IE, hay mayor desafío en la práctica pedagógica cuando se cuenta con solo un docente para atender todos los grados de estudio del nivel o modalidad (unidocente); cuando uno o más docentes tienen a su cargo dos o más grados de estudio (Multigrado); o cuando se brinda un servicio educativo de calidad a niños, niñas y adolescentes de inicial, primaria y secundaria que pertenecen a un pueblo indígena u originario, y que hablan una lengua originaria como primera o como segunda lengua (Escuela intercultural bilingüe).

A pesar de estar enfocadas en escuelas vulnerables, estos incentivos monetarios no son una política que busque atraer docentes a la CPM debido a que no está enmarcada en los concursos de nombramiento; por tanto, las asignaciones son percibidas tanto por los docentes

nombrados (en su totalidad) como por los contratados de tiempo completo. En el caso de los contratados, cuyo trabajo se vincula a la modalidad “Bolsa de Horas”, se le reconoce asignaciones proporcionales a la jornada de trabajo de tiempo completo correspondiente. Los montos proporcionados se detallan en la Tabla 4²⁵.

Tabla 4

Asignaciones por Ubicación Geográfica

Asignación	Detalle	Monto S/
Por tipo de IE	Unidocente (*)	200.00
	Multigrado (*)	140.00
	EIB	50.00
	Bilingüe Acreditado	100.00
Por ubicación de IE ²⁶	Rural tipo 1 (**)	500.00
	Rural tipo 2 (**)	100.00
	Rural tipo 3 (**)	70.00
	Frontera (***)	100.00
	VRAEM (***)	300.00

(*) (**) (***) Son excluyentes.

Fuente: LRM.

Elaboración Propia.

²⁵ Las condiciones requeridas para la percepción de estas asignaciones son las siguientes:

- Que la IE se encuentre en los padrones de las Resoluciones Ministeriales (RM) que habilitan el pago de estas asignaciones para los años en cuestión. Actualmente, se rige bajo la RM N° 026-2020-MINEDU, la cual está vigente hasta el mes de febrero de 2021.
- Que el profesor y auxiliar de educación se encuentre realizando trabajo efectivo en la IE (incluye periodo vacacional y licencia subsidiada por EsSalud).
- Para percibir la asignación por unidocente o multigrado, el profesor y auxiliar de educación debe trabajar en zona rural o frontera.
- Para percibir la asignación de bilingüe acreditado, el profesor debe figurar en el padrón de docentes bilingües acreditados y trabajar en una IE bilingüe (auxiliar de educación solo percibe asignación por laborar en una IE bilingüe y no por bilingüe acreditado).
- Un profesor puede percibir hasta 5 asignaciones temporales a la vez. En el caso del auxiliar de educación, este puede percibir hasta 4 asignaciones a la vez.

²⁶ Gradientes de ruralidad utilizados son los que maneja la Unidad de Estadística del MINEDU, a saber: Rural 1, IIEE ubicadas en centro poblados (CCPP) rurales con máximo de 500 habitantes y pueden acceder a la capital provincial más cercana en un tiempo mayor de 2 horas; Rural 2, más de 500 habitantes y pueden acceder a la capital provincial más cercana en un tiempo mayor a 2 horas, o IIEE ubicadas en ccpp de máximo 500 habitantes y pueden acceder a la capital provincial más cercana en un tiempo mayor a 30 minutos y menor igual a 2 horas; Rural 3, más de 500 habitantes y pueden acceder a la capital provincial más cercana en no más de 2 horas, o IIEE ubicadas en ccpp con menos de 500 habitantes y pueden acceder a la capital provincial más cercana en no más de 30 minutos.

Existen diversos estudios que miden la efectividad de las asignaciones temporales, específicamente de las relacionadas a la ubicación (por ruralidad). Por ejemplo, Castro y Esposito (2019) sostienen que las asignaciones temporales por ruralidad (específicamente ruralidad 1) reducen la rotación docente en 2 pp. e incrementan la probabilidad de llenar una plaza vacante en 2.5 pp. Sin embargo, no es posible distinguir diferencias por tipo de contratación (nombrados y contratados). Por otro lado, Alva et al. (2020) también analizan las mismas asignaciones por ruralidad, pero para plazas vacantes en los concursos de nombramiento, y encuentran que dichos bonos no incrementan la probabilidad de llenar una plaza en los concursos de nombramiento, pero sí mejora la calidad de los docentes que la completan (medidos por los resultados de la PUN).

Las asignaciones temporales son acumulativas. Por tanto, dependiendo del tipo y ubicación de la escuela, pueden alcanzar hasta los 1,050 nuevos soles, que representa casi el 50% de un salario básico de un docente (contratado o nombrado en la primera escala salarial).

i) Análisis Crítico de los Incentivos Monetarios en el Perú

Dada la importancia de los incentivos monetarios, en este apartado se hará un breve análisis crítico de los dos bonos de atracción docente mencionados anteriormente.

- **Focalización de los Incentivos Monetarios.** Las dos bonificaciones no están focalizando adecuadamente a sus beneficiarios. El bono atracción docente tiende a enfocarse en docentes ganadores de plazas en escuela no vulnerables. Si bien esto ha ido cambiando en los posteriores concursos, el diseño centralizado de los concursos de nombramiento hace que el bono favorezca, por construcción, a este tipo de escuelas.

Hasta el último concurso de nombramiento, cerca de 11 mil docentes a nivel nacional fueron beneficiarios con el bono de atracción. No obstante, al ser estos docentes los primeros puestos en sus respectivos concursos, tiene sentido que sean también los que obtengan las plazas ofertadas más atractivas. Por lo que obtienen un doble beneficio. Por un lado, son atraídos con

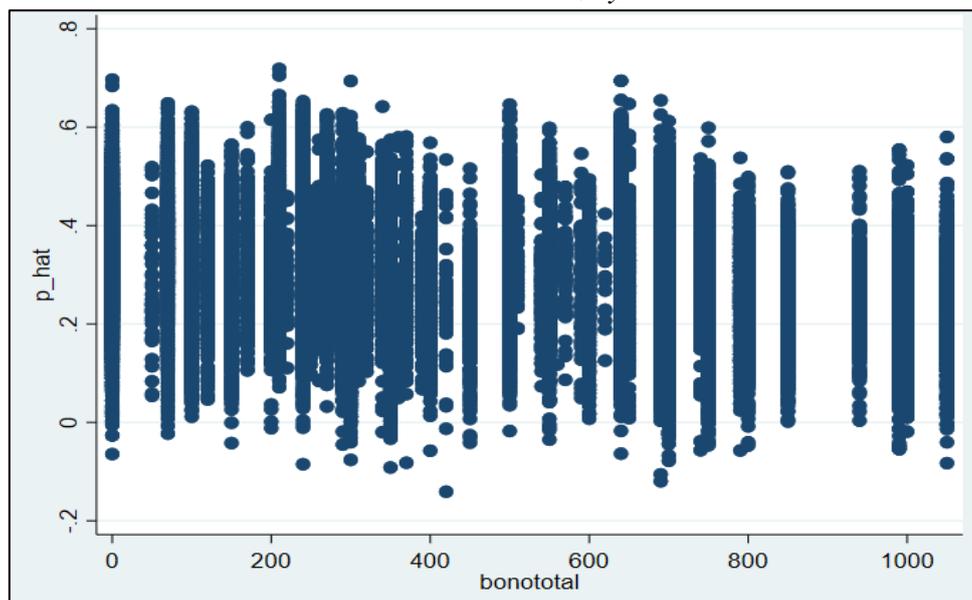
una subvención anual de 6 mil soles por su buen rendimiento. Por otro lado, tienen la opción de seleccionar plazas en contextos no vulnerables, con mejores condiciones y mayor accesibilidad.

Por su parte, las asignaciones temporales focalizan sus esfuerzos explícitamente en escuelas más vulnerables. Sin embargo, las dimensiones tomadas en consideración para su otorgamiento (por ubicación y por tipo) parecen ser insuficientes aun para capturar las heterogeneidades de las escuelas públicas menos atractivas. Esto se alinea al caso de Gambia estudiado por Pugatch y Schroeder (2014), donde, si bien los subsidios incrementaron la presencia de docentes de calidad en las zonas rurales, no fue suficiente para atraer docentes a las zonas más alejadas y, por ende, más vulnerables.

Para avalar esta hipótesis, se correlaciona el bono acumulado por escuela y la probabilidad predicha de que dicha escuela sea seleccionada en un concurso de nombramiento. Como es de esperarse, existe una correlación negativa entre ambas variables; es decir, a medida que una plaza es más vulnerable (menor probabilidad de que la plaza sea seleccionada), se incrementa el monto del bono acumulado. Sin embargo, esa correlación es de reducida magnitud (-0.218) y tiene mucha variabilidad (ver Gráfico 12).

Gráfico 12

Probabilidad de Selección de Plaza y Bono Acumulado



Otra forma de ver el mismo resultado es analizando el Gráfico 9, el cual muestra los principales predictores de probabilidad de seleccionar u otorgar una plaza. Como se observa, existen otros predictores que no están relacionados a las asignaciones temporales y que tienen mayor peso para explicar que una plaza sea seleccionada tales como la composición de los docentes y directivos en la escuela o indicadores externo (índices de precios regionales e indicadores de violencia).

Por último, se analiza si el bono responde a los conglomerados elaborados en la sección previa. Como se describió anteriormente, existen grupos de escuelas que tienen alta dispersión y vulnerabilidad, por lo que, probablemente, la sola presencia de los incentivos monetarios sería insuficiente. Idealmente, se espera que el bono acumulado correlacione con las agrupaciones y sea mayor en los grupos con mayor vulnerabilidad.

No obstante, tal como se observa en la Tabla 5, las escuelas del grupo 1 (con dispersión y vulnerabilidad extrema) reciben en promedio 684 nuevos soles de bonificación, cuyo monto máximo (850 nuevos soles) está por debajo del máximo posible (1,050 nuevos soles). Es interesante notar que, en el grupo 2, a pesar de tener menor dispersión que el grupo 1, reciben mayor bonificación acumulada en todos los estadísticos analizados. Esto puede deberse a que la ubicación o características de estas escuelas responden directamente a las asignaciones temporales.

Entre los grupos 3 y 5 se denota una caída progresiva del bono, la cual está relacionada a la dispersión y ruralidad mencionada en la sección previa. Como era de esperarse, pocas escuelas del grupo 5 son beneficiadas por las asignaciones temporales (ver percentiles). Sin embargo, están ubicadas en entornos peligrosos que pueden hacerlas poco atractivas.

Tabla 5*Conglomerados de Escuelas con Baja Probabilidad*

	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
Bono acumulado promedio	684	757	641	342	104
Bono acumulado p25	650	690	600	100	0
Bono acumulado p50	740	750	700	300	0
Bono acumulado p75	800	850	750	640	0
Bono acumulado máximo	850	1,050	1,050	1,050	750
Bono acumulado mínimo	0	0	0	0	0

- Monto de los Incentivos Monetarios. Un primer aspecto para analizar en los montos de las bonificaciones es conocer si tienen una base teórica y/o empírica para su determinación. Al revisar las normativas del MINEDU de ambas bonificaciones, no se encuentran mayores sustentos de los montos asignados. Así surgen preguntas tales como ¿cómo se determinó un monto anual de S/ 6,000 soles por el periodo de tres años para los ganadores del bono atracción docente? ¿cómo se asignó los montos por tipo y ubicación de escuela? y ¿cómo se determinó la distribución de los montos de las asignaciones por ruralidad?

Solo se encontró un estudio (Alva et al., 2020) que utiliza la elasticidad salario proveniente de las asignaciones por ruralidad y análisis contrafactuales para determinar la bonificación óptima de los incentivos monetarios para el caso peruano. Sin embargo, este es un estudio incipiente y, por tanto, este análisis forma parte de una agenda pendiente de investigación para futuros estudios.

Un segundo aspecto es el valor en el tiempo de los incentivos monetarios. Ambas bonificaciones bajo análisis fueron determinadas posteriores a la LRM y puestas en implementación el año 2015. Desde ese entonces el monto no ha variado, pero su importancia relativa ha decaído en el tiempo. Para tener una idea, en 2015 el bono por ruralidad 3 (escuelas ubicadas en lugares más dispersos) era equivalente al 32% de la remuneración mensual docente, mientras que, para el presente año, ese mismo monto solo equivale al 20.8% de la remuneración docente actual.

Por último, un tercer aspecto a considerar es que la bonificación, en especial, las asignaciones temporales, no son crecientes en la experiencia del docente. A medida que un docente acumula más experiencia y avanza en la CPM, pierde los incentivos relativos otorgados por el bono. Para tener una idea de esto, el bono por ruralidad 3 para un docente de tercera escala equivale al 17.3% de su remuneración, mientras que para un docente de la escala más alta equivale a un 9.3%. Este diseño de las asignaciones temporales, contrasta con experiencias en otros países como Chile donde las bonificaciones son crecientes con la experiencia y la calidad docente.

- **Inadecuado Conocimiento de los Incentivos Monetarios.** A pesar del importante monto que se puede llegar a otorgar por las asignaciones temporales, esta no parece ser una variable que determine actualmente la selección y otorgamiento de plazas en los concursos de nombramiento. Esto se documenta en el estudio de Ajzenman et al. (2020) y será abordado posteriormente cuando se analicen las intervenciones de economía del comportamiento.

Sin embargo, para avalar la hipótesis de poco conocimiento y relevancia en la toma de decisiones del docente en los concursos de nombramiento, se toman los resultados del modelo predictivo desarrollado en el presente trabajo. En primer lugar, se incluyó como predictor el bono acumulado por escuela (entre S/ 50 y S/ 1,050 soles) y los resultados del modelo *LightGBM* denotan que dicha variable tiene muy poco valor predictivo. La relevancia de los predictores del modelo *LightGBM* son pesos en los árboles de decisión, pero en sí mismos no tienen alguna interpretación factible. Por ello, y a modo de análisis de robustez, adicionalmente se estimó un modelo de regularización *LASSO* para determinar si dicho predictor es lo suficientemente importante como para permanecer en el modelo luego del proceso de regularización, aunque resulta excluido del modelo final.

En resumen, los incentivos monetarios pueden ser herramientas efectivas para atraer docentes, pero también son costosas. Por ello, es necesario un adecuado diseño que asegure la efectividad de estos incentivos, de modo que la focalización de escuela tiene un rol determinante. Tal y como se puede observar en los resultados anteriormente mostrados, las definiciones de vulnerabilidad que actualmente tiene el MINEDU (expresadas en las asignaciones temporales) resultan insuficientes para capturar los problemas de accesibilidad y las vulnerabilidades reales.

En ese sentido, la aplicación de la tipología (clasificación modo semáforo) puede ayudar a focalizar de manera más adecuada las políticas de incentivos monetarios, de modo que lleguen a las escuelas más vulnerables. Asimismo, el análisis de conglomerados nos puede ayudar a identificar en qué escuelas focalizar los esfuerzos (grupos 2, 3 y 4 del análisis de conglomerados) y qué montos responden de manera más adecuada a las necesidades de cada grupo. En este último punto, un estudio cualitativo para aproximar los incentivos monetarios necesarios en cada uno de los grupos podría ser parte de una posterior agenda de investigación.

b) Incentivos no Monetarios. Como se mencionó en la sección previa, los incentivos monetarios son las políticas de atracción docente de mayor uso. Los incentivos no monetarios son políticas que funcionan bajo la misma lógica, pero no necesariamente representan inversiones fuertes de presupuesto público. La evidencia internacional no muestra muchos casos de este tipo de incentivos debido a que su diseño e implementación es específico a la problemática que se aborda, así como al contexto donde se implemente. Asimismo, los incentivos no monetarios pueden ser muy variados, aunque también pueden ser muy flexibles como para combinarse con otras políticas.

De acuerdo a Schildberg-Hörisch y Wagner (2020), los incentivos no monetarios pueden clasificarse; por un lado, en tangibles; y, por otro lado, en otorgación de derechos y privilegios. En el primer caso, pueden encontrarse incentivos no monetarios tales como

certificados, medallas, capacitaciones, entre otros. Mientras que, en el segundo caso, se pueden encontrar varios incentivos no tangibles, tales como los reconocimientos privados o sociales, beneficios, entre otros. Lamentablemente, los casos de incentivos no monetarios dirigidos a docentes son muy escasos y tampoco se tiene mucha evidencia que pruebe su efectividad. En general, estos están más enfocados en padres y estudiantes que en docentes.

Del análisis de las intervenciones del MINEDU, podemos deducir que existen dos políticas que siguen el diseño de una intervención de incentivos no monetarios: i) ascenso acelerado en la CPM y ii) Beca Vocación Maestro. La primera es el ascenso acelerado en la Carrera Pública Magisterial en escuelas rurales y de zona de frontera. Una vez que un docente ha ingresado a la CPM, por defecto, está en la primera escala y su posterior ascenso está condicionado por un tiempo mínimo de permanencia en cada escala. La primera y segunda escala tienen tiempos mínimos de permanencia de dos (02) años, y a partir de la tercera a la séptima escala, se requiere un mínimo de tres (03) años para acceder a los concursos de ascenso.

No obstante, los docentes que laboran en escuelas ubicadas en zonas rurales o de frontera, tienen la opción de reducir el tiempo mínimo requerido en un (01) año a partir de la tercera escala. De este modo, ocupar una plaza en una escuela ubicada en zonas vulnerables reduciría el tiempo necesario para llegar a la escala máxima de 19 a 14 años de permanencia. Por tanto, se puede asegurar ingresos futuros permanentes de manera acelerada.

Si bien este mecanismo parecería interesante desde la reducción de años necesarios para el ascenso de los docentes en la CPM, ganar 5 años a cambio de permanecer 14 años en zonas remotas parecería no ser un incentivo lo suficientemente atractivo para los docentes. Además, no se tiene total garantía del ascenso, pues según los resultados del concurso de ascenso, menos del 30% de los evaluados logran subir de escala. Por lo que un docente promedio tardaría más que 14 años en llegar a la escala más alta.

El segundo incentivo no monetario identificado es la Beca Vocación Maestro. Esta es una beca integral para formación inicial docente, que financia la carrera de Educación a nivel pregrado en las instituciones de educación superior del país y dirigida a egresados de la educación secundaria, tanto de colegios públicos como privados. Si bien esta beca es abierta a estudiantes de todo el país (bajo algunos requisitos establecido por el Programa Nacional de Becas y Crédito), una vez que se ha concluido la carrera, los egresados noveles, obtienen puntajes adicionales en los concursos de nombramiento en la CPM, lo cual incrementa su probabilidad de ingreso. Adicionalmente, con una adecuada focalización, estos podrían ser dirigidos a las escuelas con mayor índice de vulnerabilidad.

En ambos casos, la focalización sigue siendo un aspecto recurrente y relevante. Por ello, al igual que en el caso de los incentivos monetarios, los análisis de conglomerados pueden ayudar a identificar los grupos de escuelas donde este tipo de incentivos serán más efectivos. Como lo indica la literatura, los incentivos no monetarios tienen menos efectividad que los incentivos monetarios (que representan ingresos actuales), por lo que los esfuerzos podrían enfocarse en el grupo 4 del análisis de conglomerado.

Finalmente, un incentivo no monetario puede ser entendido como brindar facilidades de vivienda y acceso a necesidades básicas. Esto va en línea con lo estudiado por Mulkeen (2015), donde el factor vivienda era un determinante de la atracción docente. El análisis de conglomerados nos ayuda a identificar las escuelas vulnerables y de accesibilidad extrema y que, por tanto, en base a un trabajo articulado con otros ministerios (por ejemplo, el Ministerio de Vivienda, Construcción y Saneamiento o FONCODES del Ministerio de Desarrollo e Inclusión Social), podrían brindarse mayores beneficios, además de los incentivos monetarios.

c) Economía del Comportamiento e Intervenciones Informativas. Un tercer grupo de políticas de atracción docente más novedosa son las intervenciones conductuales o informativas. En los últimos años, se ha evidenciado el uso de la economía conductual para

mejorar diversas políticas en contexto como educación, salud, entre otros. Esta es una disciplina de la ciencia económica que utiliza a la psicología como insumo principal para identificar y describir diversos fenómenos de la realidad. En el campo educativo, se tiene evidencia sobre cómo las ciencias del comportamiento tienen efectos positivos sobre la gestión educativa, así como a la atracción docente a zonas desfavorecidas.

Un caso pionero del uso de economía del comportamiento en docentes en el contexto peruano es el estudio de Dustan et al. (2018), quienes conducen un experimento que consiste en el envío de distintos tipos de mensajes de texto (informativo, norma social, monitoreo, entre otros) a personal directivo de escuelas encargados de la ejecución del presupuesto de mantenimiento preventivo. Todos los fraseos incrementan la probabilidad de rendición de cuenta de los directivos, pero en particular, los relacionados a norma social (comparación con pares similares) y monitoreo, resultan ser más efectivos.

Para el caso específico de atracción docente a escuelas vulnerables, Ajzenman et al. (2020) utilizaron técnicas de economía del comportamiento para brindar información que promueva la motivación intrínseca de los docentes por enseñar en las escuelas menos favorecidas. Los resultados sugieren que este tipo de intervenciones incrementan la probabilidad de que los docentes seleccionen plazas con mayor grado de vulnerabilidad como las más rurales o las que requieren atenciones especiales (multigrado, EIB, entre otros).

El estudio muestra que una intervención de bajo costo, basada en recordatorios por SMS y *pop-up*, logró incrementar la probabilidad de que un docente incluya a escuelas vulnerables en su set de elección (entre 1.9 y 2.2. pp.) y que finalmente también logre obtener dicha plaza (2.7 pp.). Asimismo, los recordatorios relacionados a motivación intrínseca tuvieron impactos mayores en docentes de alto rendimiento, tanto en la selección de plazas vulnerables (2.7 pp.) como en el otorgamiento de dichas plazas (4.7 pp.), mientras que los recordatorios de

motivación extrínseca, tuvieron el efecto opuesto (mayor atracción de docentes de bajo rendimiento).

Los resultados del estudio de Ajzenman et al. (2020) son similares e incluso mayores a los mostrados por otros estudios que miden la efectividad de las asignaciones por ruralidad (Castro y Esposito 2019; Alva et al. 2020). Sin embargo, más allá de establecer comparaciones entre ambos tipos de políticas, se debe tener en cuenta los límites de este tipo de intervenciones, por lo que deben ser utilizadas de manera complementaria a otros tipos de políticas más convencionales.

Otro hallazgo que brinda el estudio de Ajzenman et al. (2020) es que son muy pocos los docentes que tienen información sobre los beneficios de la CPM como el bono de atracción, las asignaciones temporales, escalas magisteriales, entre otros. Por ello, apelar a la motivación extrínseca, a través de la información a estos beneficios, también incrementa la probabilidad de que los docentes quieran enseñar en las escuelas más vulnerables.

De este modo, se propone utilizar estrategias de información diversificadas que muestren los beneficios de la CPM, así como las oportunidades de crecimiento dentro de la misma. La idea es que los docentes sepan qué opciones tienen *ex-ante* la selección de sus plazas. Asimismo, se podría simular la asignación temporal real que el docente recibiría de ir a una plaza con determinadas características. Al igual que en el caso de Colombia, podría crearse una plataforma que centralice la información de las plazas más vulnerables y el monto total a recibir como asignación temporal en cada una de ellas.

Bajo esa misma perspectiva, similar a lo realizado en Ecuador, se puede utilizar los resultados de la tipología de plazas, de modo que también se pueda informar acerca de la probabilidad de que dicha plaza sea seleccionada por otros docentes. Así, en el proceso de selección de plazas, los docentes sabrían en qué plazas tienen más oportunidades de ingresar y cuáles son las plazas con mayor demanda. Luego, su proceso de selección dependerá de qué tan

demandada sea la plaza y de su nivel de confianza en el desempeño que tenga en el resto de la evaluación.

A modo de síntesis, los recordatorios tipo *nudges* y estrategias comunicaciones parecen ser muy costo--efectivos para lograr mejorar la atracción docente a escuelas vulnerables y/o “menos atractivas”. Es importante resaltar que no todos los tipos de fraseos pueden ser efectivos o adecuados, sino que es pertinente analizar el contexto. Por ejemplo, en el estudio de Dustan et al. (2018) muestra mayor efectividad en norma social y monitoreo porque el fin es mejorar rendición de cuentas, mientras que el estudio de Ajzenman et al. (2020) muestra mayor efectividad en motivación intrínseca porque el fin es atraer docentes a escuelas vulnerables. Se recomienda seguir explorando este tipo de herramientas con más pilotos, pues es aún un campo novedoso.

En línea con esto, los conglomerados de escuelas “menos atractivas” identificadas en el presente trabajo pueden ayudar a identificar las heterogeneidades de las escuelas y abordar diversas propuestas de *nudges* que respondan más a sus necesidades. De este modo, además de focalizar las plazas más desfavorecidas, se mejora la distribución general de la demanda.

Por último, es importante identificar a los actores involucrados en estas recomendaciones de política. La implementación de los concursos de nombramiento docente está a cargo de la Dirección de Evaluación Docente (DIED), dentro de la Dirección General de Desarrollo Docente (DIGEDD). Por tanto, el diseño y la implementación de este tipo de pilotos e intervenciones de bajo costo también serían fáciles de articular dentro del MINEDU.

II) Políticas de Largo Plazo

Si bien el foco del presente estudio no está en las políticas a largo plazo, existen diversas razones para ahondar en ello. Primero, la sostenibilidad de las políticas de corto plazo depende de las políticas de largo plazo. Es decir, a largo plazo se debe asegurar una oferta docente de calidad que permita generar una sobredemanda de docentes que sea absorbida por escuelas

“menos atractivas” con las políticas discutidas en la subsección anterior. Para tener una idea de esta problemática, la sección 4 del presente documento muestra que solo alrededor del 10% de docentes que rinden la Prueba Única Nacional, logran pasar los requerimientos técnicos mínimos establecidos por el MINEDU.

Segundo, como se discutió en la sección anterior del presente documento, existe un grupo de escuelas que tienen condiciones muy adversas (alta dispersión y malas condiciones básicas) como para asegurar una oferta docente de calidad en el corto plazo. Por ello, para acceder a una oferta docente de calidad en el largo plazo, se debe formar docentes que provengan y tengan arraigo en dichos lugares, tal como se muestra en este y en anteriores estudios (Bertoni et al. 2020, Jaramillo 2013).

Bajo esa perspectiva, un primer punto es seguir apostando por una carrera pública magisterial meritocrática y con políticas que revaloricen la carrera docente, tanto desde el punto de vista social como monetario. En este último punto se ha avanzado considerablemente en los últimos años, incrementando el piso salarial que en 2016 era de S/ 1,555 a S/ 2400 soles en 2020²⁷, lo que equivale a un incremento de más del 50%. Si bien este incremento es importante, las escalas magisteriales aún son poco empinadas (un docente con 30 horas no puede aspirar a más de S/ 5,040 soles en su escala máxima) y las remuneraciones no tienen los beneficios de otros profesionales en el sector público, tales como los sectores de salud, policía y fuerzas armadas.

Por ello, es evidente que no basta con el incremento del salario de entrada. Debe procurarse mostrar que también es accesible poder escalar en la CPM. En este sentido, una propuesta es revisar y reevaluar los tiempos mínimos para el salto de escala; especialmente en el caso de los profesores que enseñan en zonas remotas. Como se mencionó anteriormente, un docente promedio tendría que pasar más de 14 años de su vida habitando en una zona remota

²⁷<https://www.gob.pe/institucion/minedu/noticias/312586-nuevo-incremento-de-remuneraciones-para-mas-de-405-mil-docentes>

para poder llegar a la escala máxima, motivo por el cual, en muchos casos, el costo podría superar al beneficio potencial de ascender en la carrera.

Este punto se resume en tener una carrera docente atractiva y competitiva que incentive no solo a los docentes de escuelas no públicas a la CPM, sino también a los estudiantes egresados de secundaria. Este último punto es estudiado por Alfonso et al. (2019), quienes muestran que brindar una campaña informativa de los beneficios, retribución social y la meritocracia en la CPM en estudiantes de quinto grado de secundaria incrementa la probabilidad de matricularse en educación universitaria, específicamente en carreras relacionadas a educación.

Una vez que se haya logrado atraer mejores estudiantes a las carreras de educación, una segunda línea en la agenda de largo plazo es reducir las limitaciones financieras de acceso a la carrera de educación. Una herramienta muy efectiva para lograr estos fines es el otorgamiento de créditos y becas. El MINEDU ya promueve una serie de incentivos como los programas Beca 18 y Beca Vocación Maestro que apuestan por la formación en jóvenes hacia la carrera pedagógica, y que tienen un fuerte potencial para reorientar la oferta de docentes en escuelas “menos atractivas”. En ese sentido, se recomienda seguir impulsando las nuevas modalidades de Beca 18, diseñadas e implementadas por PRONABEC, que focaliza geográficamente en zonas vulnerables (modalidad VRAEM, Huallaga y comunidades nativas amazónicas) y por población vulnerable (modalidad EIB, dirigida a jóvenes interesados en estudiar Educación Intercultural Bilingüe).

Por un lado, el otorgamiento de becas puede estar condicionado a compromisos que los estudiantes asuman de modo que aseguren su inserción en la CPM posterior al egreso. Así, los beneficiarios que logren egresar de la carrera e ingresar a la CPM podrían comprometerse a trabajar por un periodo plausible en aquellas escuelas con menor probabilidad de ser seleccionadas. Asimismo, se podría tener acuerdos con las universidades e institutos

pedagógicos para que incluso antes del egreso, los estudiantes puedan hacer sus prácticas pre-profesionales en estas plazas.

En campos como la medicina, ha sido demostrado que el hecho de que algunos programas de educación consideren una experiencia en zonas rurales influye directamente sobre las decisiones de trabajar en dichas zonas (Dolea, Stormont y Braichet, 2010; Woloschuk y Tarrant, 2002). La motivación de los estudiantes por elegir esta modalidad de prácticas no debería centrarse solamente en el altruismo, sino también de beneficios adicionales como puntajes extra en los concursos de nombramiento, especialmente, en la parte de experiencia.

Por otro lado, las becas también pueden ayudar a redirigir la oferta de docente en zonas muy vulnerables al asignar becas o cuotas de becas a estudiantes locales, tal como lo viene haciendo el MINEDU en sus nuevas modalidades de Beca 18. Este estudio y estudios previos (Bertoni et al. 2020, Jaramillo, 2013) muestran que los docentes tienen arraigo al espacio geográfico donde nacieron, y por ello ofrecer becas a estudiantes de escuelas de dichas comunidades es una buena alternativa, más aún en lugares extremadamente disperso o con condiciones muy poco favorables, como se pudo observar en el análisis de conglomerados de la sección 6 del presente documento. Cabe mencionar que el diseño e implementación de estas políticas involucra diversas direcciones como la Dirección General de Desarrollo Docente (DIGEDD) y el Programa Nacional de Becas y Créditos (PRONABEC).

Finalmente, una tercera línea en la agenda de largo plazo es el fortalecimiento de las instituciones de formación inicial docente (institutos pedagógicos y universidades). Este es un punto muy extenso, con diferentes aristas de análisis y por fuera de los alcances del presente estudio, pero debe ser abordado desde el punto de vista pedagógico y curricular, buscando mejores profesores, mejores remuneraciones, innovación en prácticas pedagógicas, aspectos socioemocionales y enseñanza en educación multigrado, entre otros. También debe abordarse desde el punto de vista físico (inversión en infraestructura y acceso a servicios). Cabe

mencionar que el diseño e implementación de políticas en este ámbito involucra diversas direcciones del MINEDU tales como la Dirección de Formación Inicial Docente (DIFOID), Dirección General de Desarrollo Docente (DIGEDD) y la Dirección General de Educación Universitaria (DIGESU).

6.2. Focalización de Incentivos: La Gradiente de Ruralidad

Tal como se evidenció en las subsecciones previas, un aspecto relevante en el diseño de las diversas políticas de atracción docente es cómo están focalizadas. Una vez entendido ello, se puede mejorar la efectividad de estas y aprovechar mejor los recursos invertidos.

La gradiente de ruralidad es un instrumento de política elaborada por el Ministerio de Educación en base a la densidad poblacional (tamaño de la población de los centros poblados) y la dispersión de las escuelas (grado de accesibilidad de los centros poblados a la capital provincial más cercana). La principal utilidad de esta gradiente es la focalización de diversas intervenciones y políticas educativas dentro del ministerio. Como ya se mencionó, dicha gradiente se utiliza para determinar los montos de las asignaciones temporales. Por ello, se espera que su estructura refleje las diferencias en deseabilidad por parte de los docentes en los concursos de nombramiento.

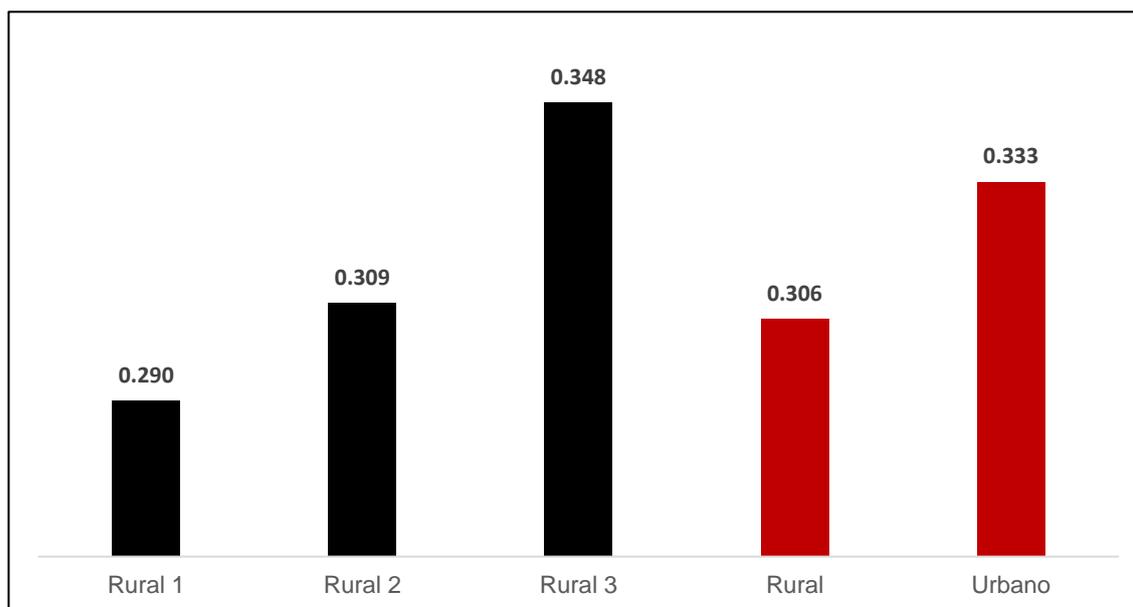
Para analizar esto, se comparan las probabilidades predichas de que un docente seleccione una plaza en un concurso de nombramiento (ver Gráfico 13). Como es de esperarse, a medida que las escuelas son más dispersas (ruralidad 1), las probabilidades de que sea seleccionada son, en promedio, menores. Sin embargo, las diferencias entre estos grupos no son muy marcadas. Incluso, no se evidencia mayores cambios entre la ruralidad 1 y ruralidad 2, a pesar de que los montos de las asignaciones temporales son distintos.

Otro aspecto importante a destacar, si bien existen diferencias en las probabilidades de seleccionar una plaza en áreas urbanas y rurales, estas no son de gran magnitud. Esto está alineado con los resultados previos que denotan la existencia de otras variables a considerar,

tales como la criminalidad, niveles de precio o entorno de la escuela. De ello se desprende que una potencial modificación al diseño del bono de atracción docente, no debería pasar solo por considerar la ruralidad o la gradiente de ruralidad subyacente.

Gráfico 13

Probabilidad de Seleccionar una Plaza por Tipo de Ruralidad



7. Comentarios Finales

El objetivo del presente estudio fue generar una tipología de plazas en base a su probabilidad para ser seleccionada en los concursos de nombramiento realizados por el MINEDU en el periodo 2017 – 2019. Esta tipología ayudaría a revelar la heterogeneidad de las plazas y así rediseñar políticas y esquemas de incentivos de atracción docente específicos a cada contexto. De forma resumida, podemos señalar que al utilizar modelos de analítica avanzada se pudo predecir las probabilidades de que una escuela tenga plazas seleccionadas u otorgadas en un concurso de nombramiento. Con este insumo se identificó a las escuelas “menos atractivas” y, posteriormente, se caracterizó a dichas escuelas en cinco conglomerados.

Los resultados del análisis de conglomerados evidencian una existente heterogeneidad de las escuelas “menos atractivas”. Contrariamente a lo que se puede pensar, la atracción

docente no está ligada únicamente a problemas de vulnerabilidad o dispersión, ya que también existen escuelas urbanas con esta característica en Lima Metropolitana. Dicho grupo de escuelas no está afecto a los principales incentivos monetarios del MINEDU, por lo que esta evidencia resulta relevante. Sin embargo, ahondar en su poco atractivo forma parte de una agenda de investigación futura²⁸.

Otro conglomerado lo conforman escuelas con gran dispersión y lejanas a las capitales departamentales, con condiciones precarias en cuanto a servicios e infraestructura. Como se argumenta en el estudio, es probable que las políticas de atracción docente de corto plazo no sean efectivas en este grupo. Por lo que también serán necesarias políticas de atracción docente a largo plazo. Algunas alternativas para incentivar el acceso a carreras de educación a estudiantes locales son analizadas en la sección de políticas de largo plazo. Sin embargo, la sola identificación de este grupo de escuelas ya representa un aporte valioso del presente estudio.

Los otros conglomerados de escuelas están compuestos por aquellas con diversos niveles de dispersión, accesibilidad y condiciones básicas. Pero también por aquellas donde es posible que las políticas convencionales de atracción docente puedan operar, ya sea solas o en combinación con otras medidas. La sección de análisis y recomendaciones de políticas enfocadas en la atracción docente formaliza y presenta las principales recomendaciones de políticas de atracción docente para estos grupos de escuelas.

Así, a raíz del análisis de conglomerados, se revisó intervenciones o políticas educativas que respondan a una problemática similar según la evidencia en el contexto internacional de países en desarrollo. Entre las políticas más resaltantes se tienen los incentivos monetarios como pieza clave de la atracción docente, pero también incentivos no monetarios como el acceso a información y mejoras en las plataformas que guían los procesos de selección. De este modo,

²⁸ Para ello se recomienda realizar un análisis cualitativo exploratorio a los docentes y otros actores de la comunidad educativa (padres de familia, personal de la UGEL) para ahondar en sus percepciones sobre las condiciones de vulnerabilidad y riesgos en estas escuelas que podrían hacerla pocas atractivas.

planteamos diversas recomendaciones de políticas enfocadas tanto en el corto, como en el largo plazo. Asimismo, para las de corto plazo, se ha desarrollado recomendaciones en tres bloques: incentivos monetarios, incentivos no monetarios y el uso de la economía del comportamiento.

En primer lugar, los incentivos monetarios son las políticas más comunes y efectivas para atracción docente. El MINEDU tiene a cargo dos intervenciones con este enfoque: el Bono de Atracción Docente y las Asignaciones Temporales. Mientras que la primera se enfoca en la atracción de docentes de alta calidad a la CPM, la segunda se enfoca en la atracción a plazas muy alejadas o que requieren algún tipo de atención especial.

Aunque la implementación del bono de atracción suene interesante, no se tiene evidencia de su efectividad para retener a los nuevos docentes a la CPM. Esto se explicaría debido a que los ganadores suelen estar ubicados en escuelas muy deseables, por lo que la deserción o atracción no es un problema per se. De este modo, se propone rediseñar este incentivo de tal forma que responda también a las heterogeneidades observadas por las plazas. Una opción podría ser destinar parte de los fondos a un bono de atracción enfocado a zonas rurales o con mayor dispersión (grupo 1) o con necesidades básicas insatisfechas (grupo 2).

Por su parte, las asignaciones temporales de ruralidad han evidenciado incrementar la probabilidad de llenar una plaza, pero no necesariamente proveniente de concursos de nombramientos. Ello se debe a dos posibles motivos. El primero es porque existen otros predictores que no están relacionados a las asignaciones temporales y que tienen mayor peso para explicar que una plaza sea seleccionada. El segundo es debido a que son muy pocos los docentes que saben de la existencia de estas asignaciones. Por ello, una segunda política está basada en la difusión de información sobre los montos asignados a cada plaza. Adicionalmente, se podrían utilizar los resultados hallados para definir nuevos focos de vulnerabilidad que también merezcan ser compensados a través de asignaciones y tengan mayor peso en la probabilidad de seleccionar u otorgar una plaza.

En segundo lugar, los incentivos no monetarios son políticas que funcionan bajo la misma lógica, pero no necesariamente representan inversiones fuertes de presupuesto público. Actualmente, el MINEDU tiene dos intervenciones de este tipo que pueden ser muy útiles para la atracción de docentes a escuelas con alto grado de vulnerabilidad: el ascenso acelerado en la CPM y la Beca Vocación Maestro. El primero se enfoca en reducir el requerimiento de permanencia mínima en cada escala para postular a los concursos de ascenso a partir de la tercera escala; mientras que el segundo atrae a la carrera docente a través de becas integrales para los estudiantes egresados de la educación secundaria.

En el caso del ascenso acelerado, la principal recomendación pasa por la promoción o mayor información de este beneficio a los docentes. Si bien las reglas de juego consideran que el docente debe ocupar una plaza ubicada en zonas vulnerables para acceder a este beneficio, se debe dar a conocer que el tiempo que le tomaría en llegar a la escala máxima de la CPM pasaría de 19 a 14 años, lo cual lo ayudaría a asegurar ingresos futuros permanentes de manera acelerada. Además, es necesario repensar el esquema de reducciones en los tiempos mínimos requeridos, pues el costo de vivir 14 años (o más) en una zona remota podría ser mayor al beneficio potencial de reducir en 5 años el ascenso a la escala máxima.

En cuanto a la Beca Vocación Maestro, se propone trabajar directamente con los egresados noveles, quienes obtienen puntajes adicionales en los concursos de nombramiento en la CPM y mayor probabilidad de ingreso. De modo que, con una adecuada focalización, estos podrían ser dirigidos a las escuelas con mayor índice de vulnerabilidad.

En tercer lugar, se propone utilizar herramientas novedosas como la economía conductual para la atracción de docentes a las plazas con menor probabilidad de selección. Gracias a lo que muestra la evidencia, algunas políticas a recomendar son el uso de estrategias de información diversificadas que muestren sobre los beneficios de la CPM, así como las oportunidades de crecimiento dentro de la misma. Además, gracias a la tipología de plazas, se

podría brindar información a través de plataformas digitales sobre la probabilidad de que una plaza sea seleccionada o no como una aproximación de qué tan demandada es esta. Otra información que se puede entregar es sobre montos simulados de las asignaciones temporales que recibiría de aplicar a una determinada plaza. Ello con el fin de apelar a la motivación extrínseca de los postulantes.

En cuanto a las políticas de largo plazo, se tiene que mencionar la necesidad de diseñar y reforzar políticas que brinden sostenibilidad a las políticas de corto plazo. Así, se debe apuntar por la revalorización de la carrera docente. La idea es atraer a más estudiantes egresados de secundaria a través de programas como Beca 18 y Beca Vocación Maestro. Asimismo, los beneficiarios que logren egresar e ingresar a la CPM podrían comprometerse a trabajar por un periodo plausible en las escuelas con menor probabilidad de ser seleccionadas.

Otra alternativa sería forjar acuerdos con las universidades e institutos pedagógicos para que los estudiantes ejerzan sus prácticas pre-profesionales en estas plazas a cambio de beneficios no monetarios al término de la carrera. Ello alineado a la difusión de información por parte del MINEDU sobre todos los beneficios que trae consigo el ingreso a la CPM, así como el problema con las heterogeneidades de las plazas.

Cabe mencionar que muchas de las recomendaciones del presente estudio recaen en diversos actores, dentro y fuera del MINEDU. Si bien la Dirección de Promoción del Bienestar y Reconocimiento Docente (DIBRED) tiene la rectoría de las políticas de atracción docente, las recomendaciones del presente estudio involucran otras direcciones dentro del MINEDU como la Dirección de Formación Inicial Docente (DIFOID), la Dirección de Servicios Educativos en el Ámbito Rural (DISER), el Programa Nacional de Becas y Créditos (PRONABEC), entre otros. No obstante, las recomendaciones también pueden involucrar una agenda articulada con otros ministerios como el Ministerio de Economía y Finanzas (MEF), el Ministerio de Vivienda,

Construcción y Saneamiento, entre otros. A lo largo del documento, además, se ha tratado de identificar a los principales actores decisores de política.

Por otro lado, la principal limitación del estudio ha sido la escasez de datos desagregados del entorno de la escuela. La mayoría de ellos provienen de fuentes administrativas censales del MINEDU, pero la imposibilidad de acceder a datos georreferenciados del Censo de Población y Vivienda y del Datacrim, así como la inexistencia de otros datos a nivel de escuela (por ejemplo, niveles de precios) han hecho que se tenga que trabajar con datos agregados a nivel distrital, provincial o, incluso, regional. A pesar de ello, se han logrado muy buenos indicadores de precisión y confiabilidad de los modelos y los principales predictores están alineados a la literatura y estudios previos.

Finalmente, tanto las predicciones de la probabilidad de selección de plazas como la tipología de escuelas desarrolladas en el presente estudio pueden actualizarse en los años posteriores con nuevos resultados de concursos de nombramiento y la generación de datos más desagregados del entorno de la escuela. Para ello, es importante establecer un plan de acción con instancias como el Instituto Nacional de Estadística e Informática (INEI) para acceder a datos ya existentes con menores niveles de desagregación tales como el Censo de Población y Vivienda (CPV) y la Data de Criminalidad (Datacrim), así como la generación de nuevos indicadores de costo de vida y seguridad ciudadana a nivel distrital, o al menos provincial, que permitan tener variabilidad dentro de cada región.

Bibliografía

- Agüero, J. (2016). Evaluación de impacto de la Jornada Escolar Completa. Documento Técnico – Proyecto FORGE.
- Ajzenman, N., Bertoni, E., Elacqua, G., Marotta, L., y Mendez, C. (2020). *Altruism or Money? Reducing Teacher Sorting using Behavioral Strategies in Peru*. IDB Working Paper Series N° IDB-WP-01143.
- Alfonso, M., Busso, M., Ñopo, H. y Yentzen, T. (2019) *Civil Service Reform and Self-Selection into Teaching: Experimental evidence from an Information Intervention*. IDB Working Paper Series N° IDB Technical Note; 1725.
- Alva, C., Boba, M., Ederer, T., León-Ciliotta, G., Neilson, C. y Nieddu, M. (2020). Teacher Compensation and Structural Inequality: Evidence from Centralized Teacher School Choice in Peru. Working paper.
- https://christopherneilson.github.io/work/documents/TeacherSchoolChoice/Draft_2020Dec_TeacherSchoolChoice.pdf
- Araujo, M. C., Cameiro, P., Cruz-Aguayo, Y., & Schady, N. (2016). *Teacher Quality and Learning Outcomes in Kindergarten*. *The Quarterly Journal of Economics*, 131(3), 1415 - 1453.
- Ayala, M.C. y Sánchez, F. (2017). *Efecto de los docentes provisionales sobre desempeño académico: Evidencia para la educación secundaria oficial en Colombia*. Bogotá: Universidad de los Andes.
- Baltagi, B. H. (2011). *Econometrics*. Springer Texts in Business and Economics.
- Banerjee, A., Cole, S., Duflo, E., y Linden, L. (2007). *Remedying Education: Evidence from Two Randomized Experiments in India*. *The Quarterly Journal of Economics*. Vol 122 (3).

- Bertoni, E., Elacqua, G., Marotta, L., Martínez, M., Méndez, C., Montalva, V., Soares, S. (2020). *El problema de la escasez docente en Latinoamérica y las políticas para enfrentarlo*. Banco Interamericano del Desarrollo.
- Bertoni, E.; Elacqua, G.; Hincapié, D.; Méndez C. y Paredes D. (2019) *Teachers' Preferences for Proximity and the Implications for Staffing Schools: Evidence from Peru*. IDB Working Paper Series N° IDB-WP-01073.
- Bonhomme, S., Jolivet, G., y Leuven, E. (2016). *School characteristics and teacher turnover: Assessing the role of preferences and opportunities*. *The Economic Journal*, 126(594), 1342-1371.
- Breiman, L. (1995). *Better Subset Regression Using the Nonnegative Garrote*. *Technometrics*, Vol. 37, No. 4, 373-384.
- Breiman, L. (2001). *Random forests*. *Machine Learning*, 45(1), 5-32.
- Brown, C., & Andrabi, T. (2020). *Inducing positive sorting through performance pay: Experimental evidence from Pakistani schools*.
- Cabrera, J., y Webbink, D. (2018). *Do higher salaries yield better teachers and better students outcomes?* MPRA working papers series.
- Cameron, A. C., & Trivelpic, P. K. (2005). *Microeconometrics: Methods and Applications*. Cambridge University Press.
- Castro, J. y Esposito, B. (2019). *The Effect of Bonuses on Teacher Behavior and Learning Outcomes in Rural Schools: A Story with Spillovers*. Working paper. <https://drive.google.com/file/d/1NFSGtyUvnV7j-ssYqnQvQhIQBacwD2fT/view>
- Chetty, R., Friedman, J., y Rockoff, J. (2014). *Measuring the Impacts of Teachers II: Teacher Value-Added and Student Outcomes in Adulthood*. *American Economic Association*, 104(9), 2633-2679.

- Chinen, M. y Bonilla, J. (2017). Evaluación de impacto del Soporte Pedagógico. Documento Técnico – Proyecto FORGE.
- Cueto, S., León, J., Sorto, M. A., & Miranda, A. (2017). *Teachers' pedagogical content knowledge and mathematics achievement of students in Peru*. *Educational Studies in Mathematics*, 94(3), 329-345.
- Dal Bó, E., Finan, F., & Rossi, M. A. (2013). *Strengthening State Capacibilities: The Role of Financial Incentives in the Call to Public Service*. *The Quarterly Journal of Economics*.
- De Ree, J., Muralidharan, K., Pradhan, M., & Rogers, H. (2018). *Double for nothing? The effect of unconditional teachers' salary increases on performance*. *Quarterly Journal of Economics*.
- Dinov, I. D. (2018). *Data Science and Predictive Analytics: Biomedical and Health Applications using R*. Switzerland: Springer.
- Dolea C, Stormont L, Braichet JM. (2010) *Evaluated strategies to increase attraction and retention of health workers in remote and rural areas*. *Bull World Health Organ*. May;88(5):379-85. doi: 10.2471/BLT.09.070607. PMID: 20461133.
- Dolton, P., Marcenaro-Gutierrez, O., Pistaferri, L., & Algan, Y. (2011). *If you pay peanuts do you get monkeys? A cross-country analysis of teachers pays and pupil performance*. *Economic Policy*.
- Drouet Arias, M., & Westh Olsen, A. (2020). "Quiero ser maestro": Mejoras del concurso docente del Ministerio de Educación de Ecuador. Banco Interamericano de Desarrollo. Nota técnica del BID.
- Eble, A., Frost, C., Camara, A, Bouy, B., Bah, M., Sivaraman, M., Pei-Tseng Jenny Hsieh, Jayanty, Brady, T., Gawron, P., Vansteelandt, S., Boone, P., Elbourne, D. (2021). *How much can we remedy very low learning levels in rural parts of low-income countries?*

- Impact and generalizability of a multi-pronged para-teacher intervention from a cluster-randomized trial in the Gambia.* Journal of Development Economics, Vol 148.
- Elacqua, G., Hincapié, D., Hincapié, I., & Montalva, V. (2019). *Can financial incentives help disadvantaged schools to attract and retain high-performing teachers? Evidence from Chile.* Inter-American Development Bank. IDB - Working Papers Series.
- Elacqua, G., Hincapie, D., Vegas, E., Alfonso, M., Montalva, V., & Paredes, D. (2018). *Profesión: Profesor en América Latina ¿Por qué se perdió el prestigio docente y cómo recuperarlo?* Inter-American Development Bank. IDB Publications (Books).
- Evans, D. K., Yuan, F., & Filmer, D. (2020). *Are teachers in Africa poorly paid? Evidence from 15 countries.* Center for Global Development. Washington, DC.: CGD Working paper 538.
- Ferraz, C., & Finan, F. (2009). *Motivating Politicians: The Impacts of Monetary Incentives on Quality and Performance.* NBER Working Paper No. 14906.
- Figuerola C., M., García J., S., Malonado C., D., Rodríguez O., C., Saavedra P., & Vargas M., G. (2018). *La profesión docente en Colombia: normatividad, formación, selección y evaluación.* Universidad de los Andes - Escuela de Gobierno Alberto Lleras Camargo.
- Friedman, J. H. (2001). *Greedy function approximation: a gradient boosting machine.* Annals of statistics, 1189-1232.
- Guadalupe Mendizábal, C., León, J., Rodríguez, J. S., & Vargas, S. (2017). *Estado de la educación en el Perú: análisis y perspectivas de la educación básica.*
- Hanushek, E. A., & Rivkin, S. G. (2012). *The Distribution of Teacher Quality and Implications for Policy.* Annual Review of Economics.
- Horrace, W. & Oaxaca, R. (2006). *Results on the bias and inconsistency of ordinary least squares for the linear probability model.* Economics Letters, Vol. 90(3), pp. 321-327

- Jaramillo, M. (2013). *Apego al terruño: La geografía especial de los mercados aborales de docentes*. Documento de Investigación n.68, Grupo de Análisis para el Desarrollo (GRADE).
- Johnston, A. C. (2020). *Teacher Preferences, Working Conditions, and Compensation Structure*. Working Conditions, and Compensation Structure (February 5, 2020).
- Hanushek, E. (2002). *Teacher Quality*. In Lance T. Izumi and Williamson M. Evers (ed.). pp. 1-12.
- Hanushek, E. y Rivkin, S. (2010). *Generalizations about Using Value-Added Measures of Teacher Quality*. American Economic Review: Papers & Proceedings 100, 267–271.
- Ke, G., Meng, Q., Finley, T., Wang, T, Chen, W., Ma, W., Ye, Q., Liu, T-Y. (2017). *LightGBM: A Highly Efficient Gradient Boosting Decision Tree*. Advances in Neural Information Processing Systems (pp. 3146-3154).
- Li, P. (2012). *Robust logitboost and adaptive base class (abc) logitboost*. arXiv preprint arXiv:1203.3491.
- Loeb, S., Kalogrides, D., & Béteille, T. (2012). *Effective schools: Teacher hiring, assignment, development, and retention*. Education Finance and Policy, 7(3), 269-304.
- Marotta, L. (2019). *Teachers' Contractual Ties and Student Achievement: The Effect of Temporary and Multiple-School Teachers in Brazil*. Comparative Education Review. 3(3), 356-376.
- MINEDU (2020). *Evaluación de impacto del Bono Atracción Docente*. Manuscrito no publicado.
- Mulkeen, A. (2005). *Teachers for Rural Schools: A Challenge for Africa*. Working paper. Biennale on Education in Africa (Libreville, March 27-31, 2006). Association for the Development of Education in Africa.

- Navarro-Sola, Laia (2019) Secondary School Expansion through Televised Lessons: The Labor Market Returns of the Mexican Telesecundaria. Working paper. https://laianaso.github.io/laianavarrosola.com/Navarro-Sola_JMP.pdf
- Ñopo, H., & Díaz, J. J. (2016). *La carrera docente en el Perú*. En GRADE, Investigación para el desarrollo del Perú: Once balances.
- Pugatch, T., & Schroeder, E. (2014). *Incentives for teacher's relocation: Evidence from the Gambian hardship allowance*. Economics of Education Review.
- Perrone, F., & Eddy-Spicer, D. (2019). *Teacher Hiring and Fit Within A Diverse School District*. Leadership and Policy in Schools, 1-23.
- Simon, N. S., Johnson, S. M., & Reinhorn, S. K. (2019). *Making a Match: How Successful High-Poverty Schools Hire Teachers*. EdWorkingPaper No. 19-45.
- Tibshirani, R. (1996). *Regression Shrinkage and Selection via the Lasso*. Journal of the Royal Statistical Society. Series B (Methodological), Vol. 58, No. 1, 267-288.
- Walker, B. N. (2019). *Teacher Hiring and Placement at the Elementary School Level: The Challenges of Implementing Strategic Human Resource Management Practices*. Doctor of Philosophy (PhD), dissertation, Educ Foundations & Leadership, Old Dominion University.
- Woloschuk, W. and Tarrant, M. (2002) *Does a rural educational experience influence students' likelihood of rural practice? Impact of student background and gender*. Medical Education, 36: 241-247. <https://doi.org/10.1046/j.1365-2923.2002.01143.x>

Anexos

Anexo 1

Tabla 1

*Plazas Ofrecidas, Seleccionadas y Otorgadas en los Concursos de Nombramiento entre
2017-2018*

Región	2017		2018		2019	
	Plazas ofertadas	Plazas otorgadas	Plazas ofertadas	Plazas otorgadas	Plazas ofertadas	Plazas otorgadas
Amazonas	1,408	12.7%	1,314	15.7%	1,208	6.2%
Ancash	1,600	29.5%	1,687	31.6%	763	20.8%
Apurímac	1,417	15.8%	1,502	15.8%	983	14.1%
Arequipa	847	44.7%	629	45.2%	475	29.1%
Ayacucho	1,514	18.1%	1,635	22.4%	933	9.0%
Cajamarca	1,833	41.9%	1,949	41.0%	850	30.7%
Callao	549	41.2%	704	41.1%	397	32.5%
Cusco	2,204	34.2%	2,292	27.2%	1,248	17.7%
Huancavelica	1,615	20.6%	1,445	21.1%	824	14.0%
Huánuco	1,379	21.4%	1,410	24.6%	1,033	14.1%
Ica	414	51.9%	367	59.9%	218	30.3%
Junín	1,841	31.1%	1,801	26.2%	1,311	15.9%
La Libertad	1,848	37.3%	1,934	34.2%	1,213	22.8%
Lambayeque	541	58.8%	514	45.5%	291	19.6%
Lima Metropolitana	3,220	63.9%	1,974	72.0%	1,943	45.3%
Lima Provincias	1,309	39.3%	1,294	41.0%	683	34.4%
Loreto	3,799	3.8%	2,792	6.8%	3,402	2.3%
Madre De Dios	370	19.7%	269	14.1%	393	21.4%
Moquegua	135	58.5%	89	66.3%	52	19.2%
Pasco	864	20.4%	782	20.7%	673	10.4%
Piura	2,532	24.0%	2,607	26.4%	2,053	19.5%
Puno	2,363	29.5%	2,339	29.5%	943	23.2%
San Martín	1,145	18.9%	1,385	20.5%	1,094	12.5%
Tacna	216	75.5%	142	66.9%	85	27.1%
Tumbes	260	30.4%	313	24.3%	174	12.1%
Ucayali	914	13.1%	1,261	10.1%	976	7.2%
Total	36,137	29.4%	34,430	28.9%	24,218	17.8%

Fuente: DIED-MINEDU

Elaboración: Propia

Tabla 2*IIEE con Plazas Vacantes en Todos los Concursos de Nombramiento entre 2015-2019*

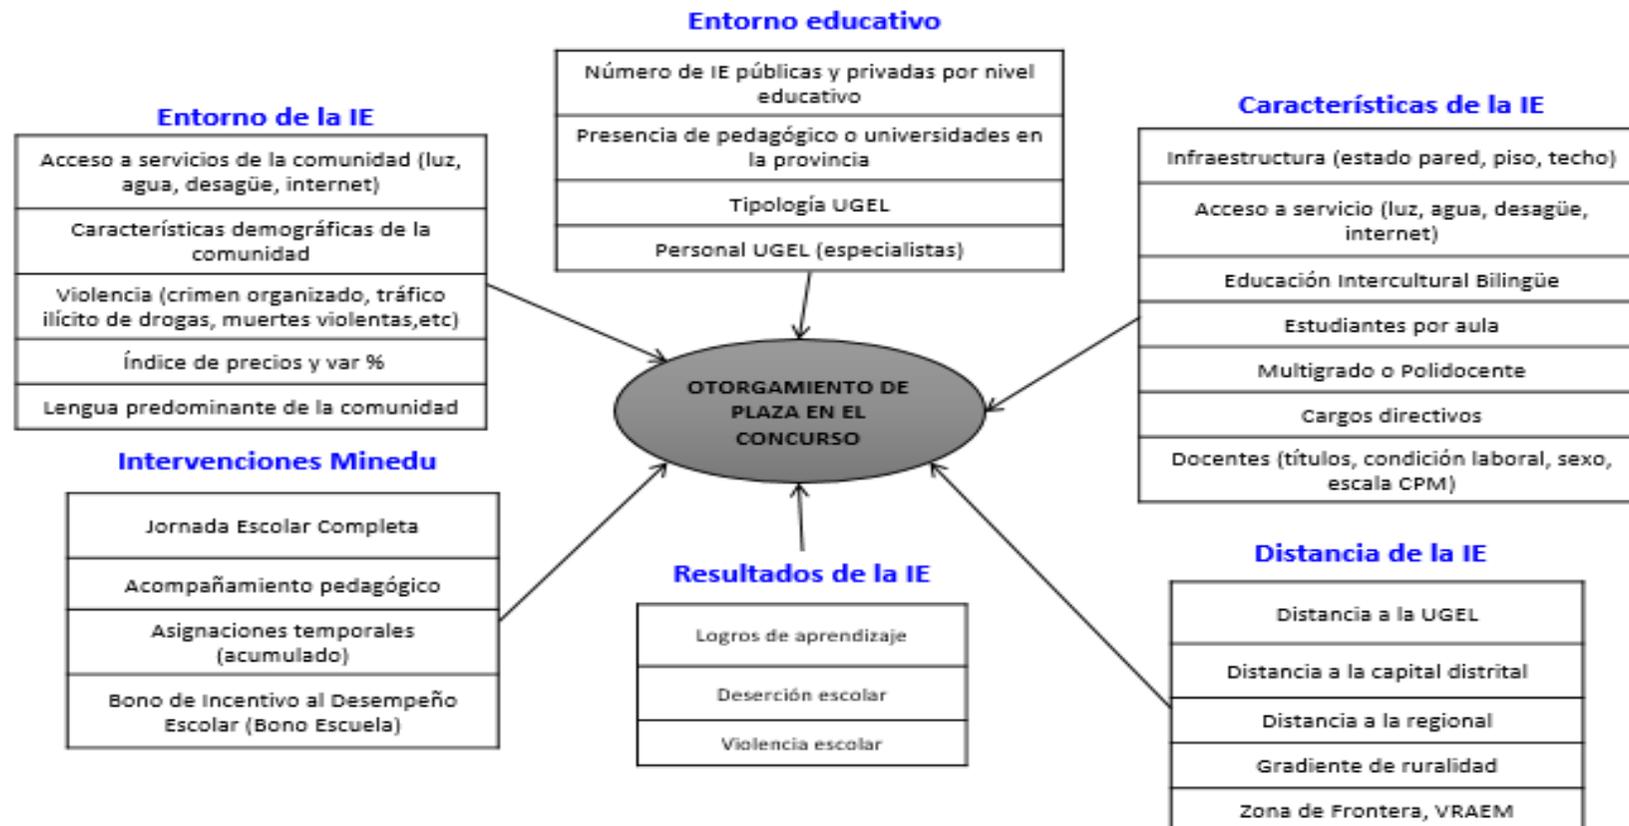
Región	Plazas vacantes	Plazas ofertadas	%
Amazonas	290	1,202	24%
Apurímac	302	1,339	23%
Ucayali	201	978	21%
La Libertad	359	1,834	20%
San Martín	233	1,201	19%
Ayacucho	245	1,473	17%
Pasco	120	753	16%
Huánuco	225	1,459	15%
Junín	264	1,826	14%
Loreto	411	3,027	14%
Huancavelica	194	1,503	13%
Piura	301	2,372	13%
Puno	252	2,057	12%
Cusco	215	1,896	11%
Áncash	152	1,598	10%
Cajamarca	199	2,170	9%
Madre de Dios	23	252	9%
Lambayeque	59	698	8%
Tumbes	9	224	4%
Lima Provincias	38	1,131	3%
Ica	11	446	2%
Callao	5	345	1%
Lima Metropolitana	25	2,175	1%
Arequipa	6	832	1%
Moquegua	1	173	1%
Tacna	0	257	0%
Total	4,153	34,382	12%

Fuente: DIED-MINEDU

Elaboración: Propia.

Anexo N° 2

Gráfico 1. Principales variables explicativas en el modelo de clasificación



Detalle de Variables Según Fuente de Información

Fuente	Nombre de la variable	Descripción
Concurso de Nombramiento	plaza	= 1 si la IE tiene al menos una plaza otorgada
	eib	= 1 si la IE es de Educación Intercultural Bilingüe
Censo Educativo	tiempo_ugel	Tiempo en minutos a la sede de UGEL jurisdiccional
	tiempo_dist	Tiempo en minutos a la capital distrital jurisdiccional
	tiempo_prov	Tiempo en minutos a la capital provincial jurisdiccional
	tiempo_dep	Tiempo en minutos a la capital departamental jurisdiccional
	discrecer	= 1 si el distrito está incorporado a la Estrategia CRECER
	dis_juntos	= 1 si el distrito está incorporado al programa JUNTOS
	zona_vrae	= 1 si el distrito está en el valle de los ríos Apurímac, Ene y Marañón (VRAEM)
	zona_front	= 1 si el distrito cuenta con zona de frontera
	pared	= 1 si la IE cuenta con paredes de material noble
	techo	= 1 si la IE cuenta con techos de material noble
	piso	= 1 si la IE cuenta con pisos de material noble
	alumbrado	= 1 si la IE cuenta con acceso a electricidad
	desague	= 1 si la IE cuenta con acceso a desagüe
	internet	= 1 si la IE cuenta con acceso a internet
	doc_pregrado_pedag_tit	Número de docentes en la IE con estudios pedagógicos concluidos con título
	doc_pregrado_pedag	Número de docentes en la IE con estudios pedagógicos concluidos sin título
	doc_pregrado_nopedag_tit	Número de docentes en la IE con estudios no pedagógicos concluidos con título
	doc_pregrado_nopedag	Número de docentes en la IE con estudios no pedagógicos concluidos sin título
tot_alum	Total de alumnos promedio en la IE	
p_lengnat_ie	Tasa de alumnos promedio que hablan un idioma nativo en la IE	

	r_retirados_ie	Tasa de alumnos retirados promedio en la IE
	r_alum_sec_ie	Tasa de alumnos por sección
	r_desaprobados_ie	Tasa de desaprobados en la IE
Censo Educativo	pbre_quintil	Quintil de pobreza
	nro_inicial	Número de IIEE iniciales en el centro poblado
	inicial_priva	Número de IIEE iniciales privadas en el centro poblado
	nro_primaria	Número de IIEE primarias en el centro poblado
	primaria_priva	Número de IIEE primarias privadas en el centro poblado
	nro_secundaria	Número de IIEE secundarias en el centro poblado
	secunda_priva	Número de IIEE secundarias privadas en el centro poblado
	pedagogicos	Presencia de instituto pedagógico en la provincia
	universidades	Presencia de universidades con carrera de educación en la provincia
	univeregional	Presencia de universidades con carrera de educación en la región
	pedagregional	Presencia de instituto pedagógico en la región
Padrón Web	unidocente	= 1 si la IE tiene característica Unidocente
	multig	= 1 si la IE tiene característica Multigrado
	completo	= 1 si la IE tiene característica Polidocente completo
	niv_inicial	= 1 si la IE es de nivel Inicial
	niv_primaria	= 1 si la IE es de nivel Primaria
	niv_secundaria	= 1 si la IE es de nivel Secundaria
	nacro_reg_norte	= 1 si la IE se ubica en la macroregión Norte
	macro_reg_sur	= 1 si la IE se ubica en la macroregión Sur
	macro_reg_lima	= 1 si la IE se ubica en la macroregión Lima
	macro_reg_orient	= 1 si la IE se ubica en la macroregión Oriente
	macro_reg_centro	= 1 si la IE se ubica en la macroregión Centro
	rural_a	= 1 si la IE se ubica en una zona rural 1
rural_b	= 1 si la IE se ubica en una zona rural 2	
rural_c	= 1 si la IE se ubica en una zona rural 3	

	urbano	= 1 si la IE se ubica en una zona urbana
	ap_eib	= 1 si la IE recibe intervención de Acompañamiento pedagógico EIB
	ap_multigrado	= 1 si la IE recibe intervención de Acompañamiento pedagógico multigrado
	ap_polidoc	= 1 si la IE recibe intervención de Acompañamiento pedagógico polidocente
	jec	= 1 si la IE recibe intervención de Jornada Escolar Completa
Evaluación Censal Estudiantil	mean_prev_ini_prim_c	Promedio de estudiantes de primaria que están en nivel En Inicio en comprensión lectora
	mean_prev_ini_prim_m	Promedio de estudiantes de primaria que están en nivel En Inicio en matemáticas
	mean_sat_prim_c	Promedio de estudiantes de primaria que están en nivel Satisfactorio en comprensión lectora
	mean_sat_prim_m	Promedio de estudiantes de primaria que están en nivel Satisfactorio en matemáticas
Nexus	tot_ch	Número de docentes en la IE que son cuadro de horas
	tot_direct	Número de directivos en la IE
	tot_doc	Número de docentes en la IE
	eventuales	Número de docentes en la IE que están en plazas eventuales
	contratados	Número de docentes contratados en la IE
	doc_cat_1	Número de docentes en escala 1 en la IE
	doc_cat_2	Número de docentes en escala 2 en la IE
	doc_cat_3	Número de docentes en escala 3 en la IE
	doc_cat_4	Número de docentes en escala 4 en la IE
	doc_cat_5	Número de docentes en escala 5 en la IE
	doc_cat_6	Número de docentes en escala 6 en la IE
	doc_cat_7	Número de docentes en escala 7 en la IE
	tipo_direct	Proporción de directivos en la IE que ocupan plazas designadas
	pl_vacante	Proporción de plazas docentes vacantes en la IE
nombrados	Proporción de docentes nombrados en la IE	

	sexo_doc	Proporción de docentes mujeres en la IE
	jor_lab	Jornada laboral promedio en la IE
	ratio_dir_doc	Proporción de directivos en la IE
	tiene_event	= 1 si la IE tiene plazas eventuales
	tiene_dir	= 1 si la IE tiene directivos
Sistema Integrado de Estadísticas de la Criminalidad y Seguridad Ciudadana	casoscem	Número de casos atendidos por Centro de Emergencia Mujer (CEM) - Nivel distrital
	denunciadelitos	Número de denuncias por comisión de delitos – Nivel distrital
	muertesviolens	Número de muerte violentas por hechos delictivos dolosos (2015-2017) – N. Distrital
	tasadenuncdel~i	Tasa de denuncias por delitos contra patrimonio (x 100 mil hab) – N. distrital (2018)
	crimorgan	Número de denuncias por criminalidad organizada (2015-2019) – Nivel regional
	dentrafidrogas	Número de denuncias por tráfico ilícito de drogas (2015-2019) – Nivel regional
	violefami	Tasa de denuncias por violencia familiar (x 100 mil hab) – N. distrital (2015-2019)
	violsexmujer	Tasa de denuncias por violencia sexual a mujeres (x 100 mil hab) – Regional (15-18)
Censo de Población y Vivienda 2017	totalviv	Total de viviendas en el centro poblado
	vivnoble	Porcentaje de viviendas con material noble en el centro poblado
	luzviv	Porcentaje de viviendas con acceso a luz eléctrica en el centro poblado
	paredviv	Porcentaje de viviendas con paredes de material noble en el centro poblado
	techoviv	Porcentaje de viviendas con techo de material noble en el centro poblado
	thab	Total de habitaciones en las viviendas del centro poblado
	pisoviv	Porcentaje de viviendas con piso de material noble en el centro poblado
	aguaviv	Porcentaje de viviendas con acceso a agua potable en el centro poblado
desagueviv	Porcentaje de viviendas con acceso a desagüe en el centro poblado	

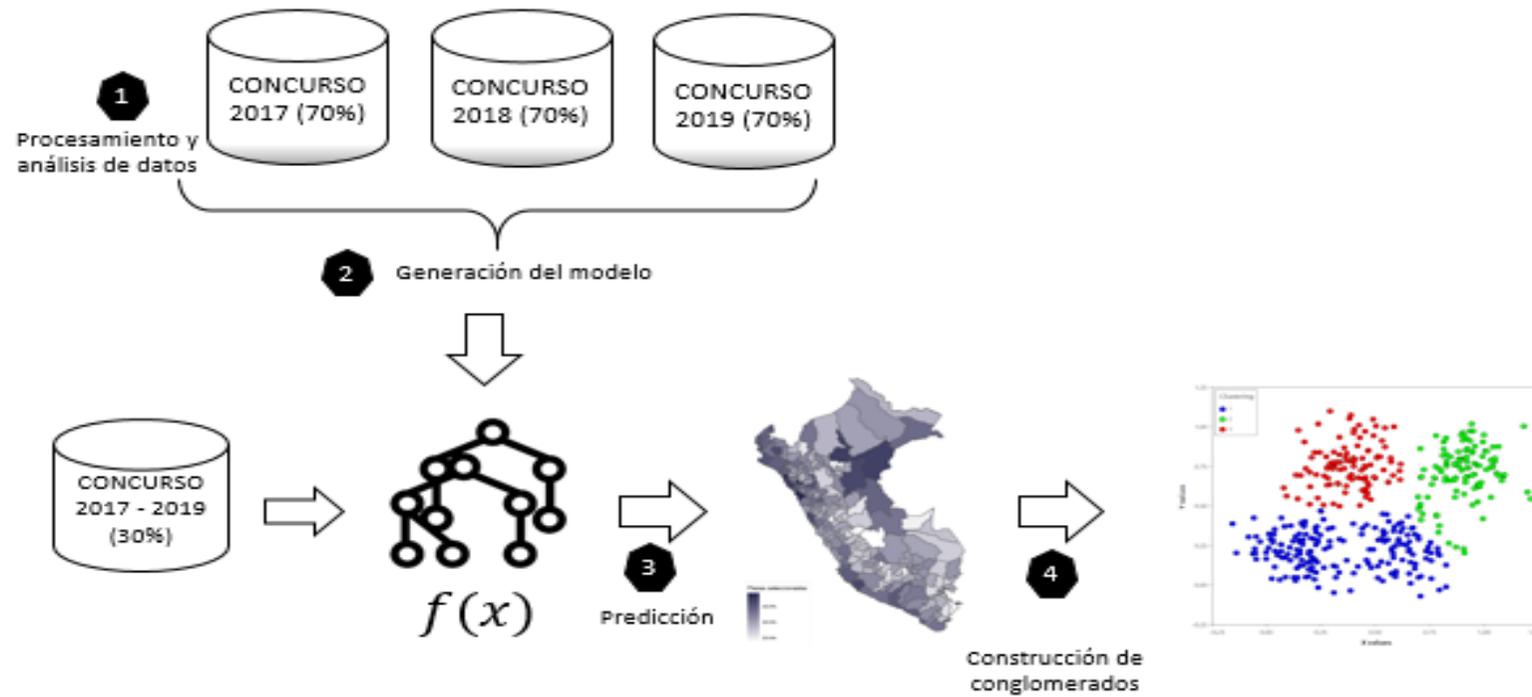
	pobviv tothog activosnb informacion bnlujo internethog	Total de población de las viviendas en el centro poblado Total de hogares en el centro poblado Porcentaje de hogares que poseen activos para necesidades básicas (cocina, refrigeradora y otros electrodomésticos) en el centro poblado Porcentaje de hogares que poseen activos que proveen información (radio, televisor, celular, etc.) en el centro poblado Porcentaje de hogares que poseen bienes de lujo (computadora, automovil, señal de televisión pagada.) en el centro poblado Porcentaje de hogares que tienen acceso a internet en el hogar en el centro poblado
Censo de Población y Vivienda 2017	pobtotal edad prim_infan ninez adolesc jovenes adult_jov adultos mayores mujeres seguro dni lengua_orig otro_orig leer_escrib s_nivel	Población total en el centro poblado Edad promedio en la población del centro poblado Porcentaje de población con 5 años de edad o menos en el centro poblado. Porcentaje de población entre 6 y 11 años de edad en el centro poblado. Porcentaje de población entre 12 y 17 años de edad en el centro poblado. Porcentaje de población entre 18 y 29 años de edad en el centro poblado. Porcentaje de población entre 30 y 44 años de edad en el centro poblado. Porcentaje de población entre 45 y 60 años de edad en el centro poblado. Porcentaje de población con más de 60 años de edad en el centro poblado. Porcentaje de mujeres en el centro poblado. Porcentaje de población que tienen seguro en el centro poblado. Porcentaje de población que tienen DNI en el centro poblado. Porcentaje de población con lengua materna originaria en el centro poblado. Porcentaje de población con otra lengua materna originaria en el centro poblado. Porcentaje de población que saben leer y escribir en el centro poblado. Porcentaje de población que no tienen ningún nivel educativo en el centro poblado.

Censo de Población y Vivienda 2017	inicial	Porcentaje de población con nivel educativo más alto inicial en el centro poblado.
	primaria	Porcentaje de población con nivel educativo más alto primaria en el centro poblado.
	secundaria	Porcentaje de población con nivel educativo más alto secundaria en el centro pob.
	bas_esp	Porcentaje de población con educación básica especial en el centro poblado.
	sup_no_univ_in	Porcentaje de población con educ. superior no universitaria incompleta en el CCPP.
	sup_no_univ	Porcentaje de población con educ. superior no universitaria completa en el CCPP.
	sup_univ_in	Porcentaje de población con educ. superior universitaria incompleta en el CCPP.
	sup_univ	Porcentaje de población con educ. superior universitaria incompleta en el CCPP.
	ms_phd	Porcentaje de población con educ. superior no universitaria incompleta en el CCPP.
	pet	Porcentaje de población en edad de trabajar en el centro poblado.
	nini	Porcentaje de población que no estudia ni trabaja en el centro poblado.
	quechua	Porcentaje de población que se autoidentifica como quechua en el centro poblado.
	aimara	Porcentaje de población que se autoidentifica como aimara en el centro poblado.
	negro	Porcentaje de población que se autoidentifica como negro en el centro poblado.
blanco	Porcentaje de población que se autoidentifica como blanco en el centro poblado.	
mestizo	Porcentaje de población que se autoidentifica como mestizo en el centro poblado.	
Banco Central de Reserva del Perú	ipc	Índice de precios al consumidor de la región.

	var_prec	Variación de precios en la región
Ministerio de Educación	costa	= 1 si la IE se ubica en la región natural Costa
	sierra	= 1 si la IE se ubica en la región natural Sierra
	selva	= 1 si la IE se ubica en la región natural Selva
	tipougela	= 1 si la IE pertenece a una UGEL del tipo A
	tipougelb	= 1 si la IE pertenece a una UGEL del tipo B
	tipougelc	= 1 si la IE pertenece a una UGEL del tipo C
	tipougeld	= 1 si la IE pertenece a una UGEL del tipo D
	tipougele	= 1 si la IE pertenece a una UGEL del tipo E
	tipougelf	= 1 si la IE pertenece a una UGEL del tipo F
	tipougelg	= 1 si la IE pertenece a una UGEL del tipo G
	tipougelh	= 1 si la IE pertenece a una UGEL del tipo H
	tipougeli	= 1 si la IE pertenece a una UGEL del tipo I
	disperugel	Indicador de dispersión de las escuelas de la UGEL
	personalagp	Trabajadores AGP/ número IIEE públicas (EBR)
	scoresistemas	Score Número de Sistemas Informáticos de Gestion utilizados
	ambbuenest	Porcentaje de ambientes de las DRE y UGEL que se encuentran en buen estado
	especmonitoreo	Número de especialistas de la UGEL que realizan exclusivamente monitoreo pedagógico a IIEE
sseemenosdos	Porcentaje de SSEE a menos de 2 horas de la UGEL (todos los niveles)	
capacope	Índice de Capacidad Operativa de la UGEL	
desafterr	Índice de Desafío Territorial de la UGEL	
bde	=1 si la IE recibió Bono de Desempeño Escolar	

Anexo 3

Gráfico 3

Síntesis de la Metodología en los Modelos Aplicados

Anexo 4

Tabla 3

Estadísticos Descriptivos de las Plazas Ofertadas por Año

VARIABLE	2017				2018				2019			
	No Ofertada	Ofertada	Diferencia	N	No Ofertada	Ofertada	Diferencia	N	No Ofertada	Ofertada	Diferencia	N
Tiempo en minutos a la UGEL	149.37 (1.351)	296.44 (3.157)	- 147.064*** (3.004)	61,440	183.65 (1.630)	257.16 (3.070)	-73.502*** (3.203)	62,615	169.32 (1.345)	341.53 (4.601)	- 172.211*** (3.525)	62,615
Tiempo en minutos a la capital departamental	363.56 (3.171)	639.75 (6.375)	- 276.183*** (6.415)	61,453	430.62 (3.571)	558.92 (6.229)	- 128.304*** (6.821)	62,628	385.31 (2.850)	783.00 (9.792)	- 397.684*** (7.485)	62,628
IE en zona rural	0.78 (0.002)	0.78 (0.003)	0.001 (0.003)	61,913	0.79 (0.002)	0.76 (0.003)	0.026*** (0.004)	62,897	0.78 (0.002)	0.77 (0.004)	0.008* (0.004)	63,000
IE en zona rural 1 (mayor ruralidad)	0.24 (0.002)	0.39 (0.003)	-0.143*** (0.004)	61,913	0.32 (0.002)	0.39 (0.004)	-0.059*** (0.004)	62,897	0.37 (0.002)	0.48 (0.004)	-0.117*** (0.005)	63,000
IE con paredes de material noble	0.87 (0.002)	0.82 (0.003)	0.049*** (0.003)	60,498	0.85 (0.002)	0.84 (0.003)	0.013*** (0.003)	62,310	0.86 (0.002)	0.79 (0.004)	0.069*** (0.004)	61,498
IE con techo de material noble	0.94 (0.001)	0.94 (0.002)	0.004* (0.002)	60,498	0.94 (0.001)	0.95 (0.002)	-0.005*** (0.002)	62,310	0.94 (0.001)	0.94 (0.002)	0.001 (0.002)	61,498
IE con piso de material noble	0.76 (0.002)	0.73 (0.003)	0.029*** (0.004)	60,495	0.76 (0.002)	0.76 (0.003)	0.004 (0.004)	62,310	0.78 (0.002)	0.78 (0.004)	-0.005 (0.004)	61,495
IE tiene acceso a electricidad	0.77 (0.002)	0.71 (0.003)	0.066*** (0.004)	60,594	0.72 (0.002)	0.72 (0.003)	-0.007* (0.004)	62,315	0.88 (0.001)	0.84 (0.003)	0.035*** (0.003)	61,315

IE tiene acceso a internet	0.21 (0.002)	0.25 (0.003)	-0.035*** (0.003)	61,913	0.20 (0.002)	0.29 (0.003)	-0.086*** (0.004)	62,790	0.21 (0.002)	0.24 (0.004)	-0.025*** (0.004)	63,000
Total de alumnos en la IE	67.21 (0.649)	120.10 (1.438)	-52.899*** (1.393)	61,856	64.18 (0.577)	138.10 (1.752)	-73.927*** (1.443)	62,856	74.99 (0.679)	127.85 (1.882)	-52.860*** (1.634)	62,000
IE recibe alguna intervención del MINEDU	0.22 (0.002)	0.28 (0.003)	-0.063*** (0.004)	61,913	0.23 (0.002)	0.26 (0.003)	-0.038*** (0.004)	62,897	0.15 (0.002)	0.23 (0.004)	-0.072*** (0.004)	63,000
Presencia de institutos pedagógicos en el distrito	0.31 (0.004)	0.22 (0.004)	0.086*** (0.006)	61,363	0.29 (0.003)	0.23 (0.005)	0.061*** (0.006)	62,517	0.29 (0.003)	0.22 (0.005)	0.068*** (0.007)	62,000
Presencia de universidad con carrera en educación en el distrito	0.16 (0.003)	0.10 (0.003)	0.055*** (0.004)	61,363	0.15 (0.002)	0.12 (0.003)	0.026*** (0.004)	62,517	0.15 (0.002)	0.11 (0.004)	0.037*** (0.005)	62,000
Región natural Costa	0.20 (0.002)	0.18 (0.003)	0.017*** (0.003)	61,913	0.20 (0.002)	0.17 (0.003)	0.026*** (0.003)	62,897	0.20 (0.002)	0.17 (0.003)	0.034*** (0.004)	63,000
Región natural Sierra	0.57 (0.003)	0.50 (0.003)	0.073*** (0.004)	61,913	0.55 (0.002)	0.52 (0.004)	0.027*** (0.004)	62,897	0.57 (0.002)	0.42 (0.004)	0.153*** (0.005)	63,000
Región natural Selva	0.23 (0.002)	0.32 (0.003)	-0.089*** (0.004)	61,913	0.25 (0.002)	0.31 (0.003)	-0.053*** (0.004)	62,897	0.23 (0.002)	0.42 (0.004)	-0.187*** (0.004)	63,000
N	38,781	23,132		61,913	44,252	18,645		62,897	49,745	13,260		63,000
Proporción	62.6%	37.4%		100%	70.4%	29.6%		100%	79.0%	21.0%		100%

Desviaciones estándar en paréntesis.

Tabla 4*Estadísticos Descriptivos de las Plazas Otorgadas y Seleccionadas (2017-2019)*

VARIABLE	Plazas ganadoras				Plazas seleccionadas			
	No otorgada	Otorgada	Diferencia	N	No Seleccionada	Seleccionada	Diferencia	N
Tiempo en minutos a la UGEL	374.00 (2.776)	128.20 (1.795)	245.796*** (4.187)	54,945	416.06 (3.26)	143.21 (1.60)	272.85*** (3.90)	54,945
Tiempo en minutos a la capital departamental	823.52 (5.762)	280.81 (3.137)	542.708*** (8.578)	54,957	915.44 (6.78)	315.12 (2.89)	600.32*** (7.97)	54,957
IE en zona rural	0.87 (0.002)	0.57 (0.004)	0.307*** (0.004)	55,033	0.91 (0.002)	0.61 (0.003)	0.297*** (0.003)	55,033
IE en zona rural 1 (mayor ruralidad)	0.50 (0.003)	0.21 (0.003)	0.289*** (0.004)	55,033	0.54 (0.003)	0.24 (0.003)	0.305*** (0.004)	55,033
La IE es EIB	0.40 (0.003)	0.09 (0.002)	0.312*** (0.004)	55,033	0.46 (0.00)	0.11 (0.00)	0.35*** (0.00)	55,033
IE con paredes de material noble	0.77 (0.002)	0.92 (0.002)	-0.145*** (0.003)	53,963	0.75 (0.00)	0.91 (0.00)	-0.16*** (0.00)	53,963
IE con techo de material noble	0.94 (0.001)	0.94 (0.002)	-0.002 (0.002)	53,968	0.94 (0.00)	0.94 (0.00)	-0.01** (0.00)	53,968
IE con piso de material noble	0.72 (0.002)	0.82 (0.003)	-0.098*** (0.004)	53,966	0.71 (0.00)	0.81 (0.00)	-0.10*** (0.00)	53,966
IE tiene acceso a electricidad	0.67 (0.002)	0.91 (0.002)	-0.240*** (0.004)	54,022	0.63 (0.00)	0.89 (0.00)	-0.26*** (0.00)	54,022
IE tiene acceso a agua potable	0.58 (0.003)	0.79 (0.003)	-0.208*** (0.004)	53,916	0.55 (0.00)	0.77 (0.00)	-0.22*** (0.00)	53,916

IE tiene acceso a internet	0.15 (0.002)	0.49 (0.004)	-0.335*** (0.004)	55,001	0.11 (0.00)	0.44 (0.00)	-0.33*** (0.00)	55,001
Total de alumnos en la IE	76.78 (0.768)	234.55 (2.294)	- (1.939)	55,023	62.46 (0.68)	209.26 (1.85)	- (1.83)	55,023
IE recibe alguna intervención del MINEDU	0.24 (0.002)	0.30 (0.003)	-0.059*** (0.004)	55,033	0.25 (0.00)	0.28 (0.00)	-0.03*** (0.00)	55,033
Presencia de institutos pedagógicos en el distrito	0.14 (0.002)	0.40 (0.007)	-0.258*** (0.006)	54,892	0.12 (0.00)	0.36 (0.01)	-0.24*** (0.01)	54,892
Presencia de universidad con carrera en educación en el distrito	0.07 (0.002)	0.19 (0.004)	-0.119*** (0.004)	54,892	0.06 (0.00)	0.17 (0.00)	-0.11*** (0.00)	54,892
Región natural Costa	0.09 (0.001)	0.35 (0.004)	-0.264*** (0.003)	55,033	0.06 (0.00)	0.31 (0.00)	-0.24*** (0.00)	55,033
Región natural Sierra	0.49 (0.003)	0.48 (0.004)	0.004 (0.005)	55,033	0.47 (0.00)	0.50 (0.00)	-0.03*** (0.00)	55,033
Región natural Selva	0.43 (0.003)	0.17 (0.003)	0.260*** (0.004)	55,033	0.46 (0.00)	0.19 (0.00)	0.27*** (0.00)	55,033
N	37,137	17,896		55,033	30,431	24,602		55,033
Proporción	67.5%	32.5%		100%	55.0%	45.0%		100%

Desviaciones estándar en paréntesis.

Tabla 5

*Características de los Postulantes según su Desempeño en el Concurso de
Nombramiento 2015*

	Todos	No aprobados	Aprobados	Diferencia
Edad	37.1	37.5	34.5	3.00***
Es mujer	66%	65%	72%	-0.07***
Años de experiencia enseñando en escuelas públicas	4.51	4.54	4.24	0.30***
Años de experiencia enseñando en escuelas privadas	2.17	2.01	3.31	-1.30***
Estudió en un instituto	62%	64%	47%	0.17***
Estudió en un instituto público	43%	44%	35%	0.09***
Estudió en un instituto privado	20%	22%	12%	0.10***
Estudió en una universidad	38%	36%	53%	-0.17***
Estudió en una universidad pública	27%	25%	43%	-0.18***
Estudió en una universidad privada	11%	11%	10%	0.01***
Estudió en una universidad o instituto rural	5%	5%	3%	0.02***
Estudió en una de las 15 mejores universidades o institutos	9%	8%	16%	-0.08***
Puntaje obtenido por el docente	99.1	92.3	147.5	-55.20***
N	192,397	168,696	23,701	

No se reportan desviaciones estándar.

Fuente: Bertoni et al. (2019)

Anexo 5

La Tabla 2 del presente documento muestra las características de las escuelas agrupadas en 5 conglomerados ($k=5$). Por otro lado, la **Tabla N° 6** del presente anexo muestra los mismos resultados, pero las diferentes agrupaciones ($k=3$ y $k=4$). Al comparar ambos resultados puede observarse que todos los casos existen un grupo de dispersión muy alta (grupo 1) y un grupo de dispersión alta (grupo 2) con características y número de escuelas muy similares.

Por otro lado, los grupos de dispersión media (grupo 3) y de baja dispersión (grupo 4) del conglomerado $k=5$, se agrupan en un solo grupo al pasar al conglomerado $k=4$. Esto no es sorprendente, pues como se vio en la sección 6.4, los grupos de dispersión media y baja son los más similares en características. Finalmente, al pasar a conglomerados $k=3$, estas escuelas se agrupan con las escuelas de muy baja dispersión (grupo 5).

Tabla 6

Conglomerados de Escuelas con Baja Probabilidad de ser Seleccionadas

	Conglomerados ($k=4$)				Conglomerados ($k=3$)		
	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 1	Grupo 2	Grupo 3
Número de escuelas	638	4,678	16,729	4,845	661	6,639	19,590
Tiempo (en min) al departa.	3913	815	241	78	3849	709	177
Tiempo (en min) a la provincia	1491	530	119	41	1487	451	84
Tiempo (en min) al distrito	698	273	58	21	687	231	41
Tiempo (en min) a la UGEL	1494	501	110	38	1489	425	77
Presencia de IE pedagógico	5.0	8.1	8.0	27.4	5.0	8.1	12.8
Vivienda con pared en buen estado (CCPP)	0.05	0.29	0.48	0.66	0.05	0.33	0.53
Vivienda con techo en buen estado (CCPP)	0.27	0.51	0.63	0.71	0.28	0.54	0.65
Vivienda con acceso a agua (CCPP)	0.06	0.26	0.46	0.65	0.06	0.29	0.52

Vivienda con acceso a luz (CCPP)	0.22	0.36	0.55	0.73	0.22	0.38	0.61
EIB	0.75	0.57	0.41	0.06	0.75	0.54	0.32
Total de alumnos	74.0	36.5	87.3	417.2	73.3	35.6	174.3
Ratio alumno por sección	10.6	6.9	11.9	24.3	10.6	6.7	15.5
Docentes con título pedagógico	2.4	2.6	5.9	20.6	2.4	2.7	9.8
Violencia familiar	266.3	745.3	835.5	904.9	271.3	737.0	865.0
Crimen organizado (denuncias)	2.6	24.6	23.6	181.2	2.9	24.1	62.6
Tráfico de drogas (denuncias)	14.0	38.3	19.8	486.0	16.1	32.3	135.2
Crimen organizado (tasa por 1000 hab.)	0.003	0.031	0.028	0.026	0.004	0.031	0.027
Tráfico de drogas (tasa por 1000 hab.)	0.025	0.056	0.031	0.069	0.029	0.047	0.041

Anexo 6

Tabla 7

Principales Políticas Aplicadas en el Contexto Internacional

Tipo de incentivo	Autores	Año	País	Política	Efectos
Monetarios	Pugatch y Schroeder	2014	Gambia	Subsidios económicos en zonas remotas	Incremento de docentes calificados en zonas rurales.
	De Ree et al.	2018	Indonesia	Incrementos en remuneración (duplicar el salario)	No se encuentra efectos.
	Cabrera y Webbink	2018	Uruguay	Incremento salarial en colegios con mayor desventaja	Incremento de contratación de docentes con experiencia y retención docente.
	Elacqua et al.	2019	Chile	Subvenciones monetarias según el desempeño del docente en las evaluaciones.	Incremento de retención de docentes.
	Brown y Andrabi	2020	Pakistán	Remuneraciones condicionadas	Autoselección de docentes por calidad.
No monetarios	Figuroa et al.	2018	Colombia	Creación del Banco Nacional de Excelencia para centralizar información sobre las vacantes definitivas y contar con un proceso meritocrático para los nombramientos provisionales	No se especifica.
	Drouet y Westh	2020	Ecuador	Centralización de la asignación docente y mejoras en el algoritmo y sistema de información	Incremento de las vacantes cubiertas.
	Mulkeen	2005	Malawi Uganda Mozambique	Construcción de casas para los docentes	Incremento de docentes, especialmente, femeninas.

XI Concurso
Anual de
Investigación
CIES 2019



CIES
consorcio de investigación
económica y social

Construyendo conocimiento para mejores políticas