

# Ayoyando la formulación de políticas públicas y toma de decisiones en educación utilizando técnicas de análisis de datos masivos: el caso de Chile<sup>1</sup>

Patricio Rodríguez<sup>a,b\*</sup>, Ricardo Truffello<sup>b</sup>, Karol Suchan<sup>b,c</sup>, Francisca Varela<sup>a</sup>, Manuel Matas<sup>a,c</sup>, Javier Mondaca<sup>a</sup>, Javiera Céspedes<sup>c</sup>, Luis Valenzuela<sup>c</sup>, Juan Pablo Valenzuela<sup>a</sup> y Claudio Allende<sup>a</sup>

## CHILE

Centro de Investigación Avanzada en Educación, Universidad de Chile  
Periodista José Carrasco Tapia 75, Santiago, Santiago, Chile

Centro de Inteligencia Territorial — DesignLab, Universidad Adolfo Ibáñez  
Av. Presidente Errázuriz 3471, Las Condes, Santiago, Chile

Facultad de Ingeniería y Ciencias, Universidad Adolfo Ibáñez  
Diagonal Las Torres 2640, Peñalolén, Santiago, Chile

**Resumen**— Chile está impulsando una reforma educativa, siendo uno de los cambios más sustantivos la creación de los Servicios Locales de Educación Pública (SLE), que sustituirán a los municipios en la administración de la educación pública.

Pero, la diversidad geográfica y socio-demográfica de Chile conlleva desafíos invisibles al diseño e implementación de políticas públicas en educación, que deben tomarse en cuenta, ya que el desempeño del sistema escolar también depende de otros factores no educativos.

Usando técnicas de Ciencia de Datos, empleando como insumos en su mayoría datos abiertos provistos por el gobierno, se generó evidencia para medir aspectos del sistema educativo previamente invisibles como la falta de equidad espacial en el acceso a oferta educativa y que además cumpla estándares mínimos de aprendizaje, o la posibilidad de predecir y prevenir fenómenos de alto impacto social como son la deserción y el abandono escolar.

Así, es posible evidenciar la necesaria coordinación y diálogo inter-agencias en el diseño de políticas públicas y toma de decisiones. El uso de indicadores espaciales permite visualizar la inequidad de los territorios, dando origen a una nueva generación de políticas públicas que supere la lógica y limitaciones de las divisiones político-administrativas de los territorios.

**Palabras clave:** Educación, políticas públicas, diversidad territorial, modelos explicativos y predictivos, aprendizaje automático, datos abiertos, inteligencia de valor público, computación elástica, visualización analítica, Ciencia de datos.

---

<sup>1</sup> Esta investigación es financiada por la Comisión Nacional de Ciencia y Tecnología (CONICYT) bajo proyectos FONDEF CA13I10023 y el Programa de Investigación Asociativa para Centros de Excelencia FB0003, el Ministerio de Educación a través del Fondo de Investigación y Desarrollo en Educación (FONIDE) con el Proyecto F911435 y Microsoft Research, gracias al programa Azure for Research.

# 1 Los desafíos y oportunidades del uso de 'Big Data' en educación en Chile

## 1.1 Complejidad de los sistemas educativos y producción de información

La educación determina el futuro de un niño, porque genera mayores ingresos, una mejor salud e incluso una mayor esperanza de vida (OECD, 2010a), contribuyendo al crecimiento económico de la sociedad (Fazekas and Burns, 2012; OECD, 2010a).

El progreso tecnológico y económico, presiona a los sistemas educativos para proveer educación de alta calidad, equitativa, innovadora, atendiendo las necesidades individuales de los estudiantes (Fazekas and Burns, 2012). Para lograrlo, los países desarrollados han aumentado la autonomía escolar, estimulando la sensibilidad de la demanda y, a veces, incluso la competencia entre los colegios (Fazekas and Burns, 2012). No obstante, los ministerios de educación continúan siendo responsables de garantizar la calidad de los sistemas educativos (Fazekas and Burns, 2012). Pero, dicha calidad no es homogénea y las brechas inter colegios e inter países se manifiestan periódicamente en resultados de pruebas de aprendizaje estandarizadas (Anderson et al., 2007; OECD, 2013).

Una causa del aumento de la complejidad está en los datos que el sistema produce (Fazekas and Burns, 2012), y que debieran usarse en todos los niveles del sistema educativo: desde el gobierno nacional hasta los municipios, escuelas e incluso la sala de clases (Means et al., 2009). El rol de la información en la toma de decisiones se vuelve crítico para el logro de los aprendizajes, la planificación escolar y el desarrollo de estrategias, políticas y prácticas en todos los niveles del sistema educativo (Faubert, 2012).

## 1.2 La reforma educacional en Chile

El sistema educativo chileno muestra avances en la última década (OECD, 2010b), pero todavía debemos mejorar significativamente la calidad y equidad de la educación (OECD, 2010b). Estamos bajo el promedio de la OECD y muy por debajo de los sistemas educativos de mayor rendimiento (OECD, 2011, 2010b).

Hoy, Chile está embarcado en una reforma educativa cuyos principales objetivos son (Gobierno de Chile, 2015): **(1)** Priorizar y fortalecer la educación pública, sustituyendo la administración municipal de los establecimientos públicos hacia **Servicios Locales de Educación (SLE) Pública**; **(2)** Regular la oferta del sector particular subvencionado, y **(3)** Fortalecer la profesión docente, atrayendo a los mejores estudiantes a estudiar pedagogía, certificando sus competencias docentes y creando una carrera docente que retribuya adecuadamente su trabajo.

Uno de los cambios más sustantivos que plantea la reforma en curso es la creación de los SLE, que se harán cargo de la administración de los establecimientos públicos en lugar de las municipalidades. Esta modificación devolverá el control de la educación pública al Ministerio de Educación a través de un sistema de administración desconcentrado.

## 1.3 La diversidad territorial como contexto donde opera el sistema educativo

Chile tiene casi 17,8 millones de habitantes (OECD, 2016), que se concentran principalmente en **10** ciudades y se distribuyen en un territorio de 4.329 km de Norte a Sur y con sólo 180 km de

Este a Oeste en promedio. Chile tiene un ingreso per cápita de USD 21.980 (OECD, 2016), pero con un alto nivel de inequidad en su distribución<sup>2</sup>.

Esta diversidad geográfica y socio-demográfica de Chile afecta al sistema educativo, porque este opera en un contexto de relaciones funcionales entre territorios. Estas relaciones no son evidentes y posiblemente se ignoren en el nuevo diseño institucional porque son invisibles.

Las preguntas que surge es **¿Cómo se puede visibilizar dicha información y combinarla con relaciones territoriales para integrarlas en el diseño y evaluación de políticas públicas de educación?**

## 2 Metodología de investigación aplicada

Con las tecnologías de información, los datos pasaron de ser escasos a superabundantes (Manyika et al., 2011; Staff Science, 2011; The Economist, 2010). Como un factor esencial para la producción, mucha de la actividad económica moderna necesita de datos como insumo para funcionar (Manyika et al., 2011; Staff Science, 2011).

El uso de datos para tomar decisiones no es nuevo, las empresas usan cálculos complejos sobre el historial de sus clientes para descubrir patrones y tendencias que predigan el comportamiento futuro de los consumidores (Bienkowski et al., 2012). Estos 'datos escapan al tamaño que puede manejar el software actual para procesarlo, razón porque se le denomina *'Big Data'* (Manyika et al., 2011). Este término también refleja la necesidad de generar nuevas formas de pensamiento, capital humano e infraestructura necesarios para este su uso (UNESCO, 2012).

La Ciencia de Datos (*'Data Science'*) se refiere a un amplio conjunto de técnicas provenientes de múltiples disciplinas como Ciencias de la Computación, Matemáticas, Estadísticas, Econometría e Investigación Operativa para extraer información útil del *'Big Data'* (Bienkowski et al., 2012) y apoyar la toma de decisiones (Marsh et al., 2006; UNESCO, 2012). El análisis de datos considera 6 pasos: **1) Explorar datos, 2) Preparar datos, 3) Planificar un modelo, 4) Elaborar el modelo, 5) Comunicar resultados y 6) Utilizar los hallazgos para la toma de decisiones** (Figura 1).

---

<sup>2</sup> Chile tiene un índice Gini de 0,508 (2011) siendo el más alto de los países de la OCDE, mientras que el promedio de la organización es 0,32 (OECD, 2015).

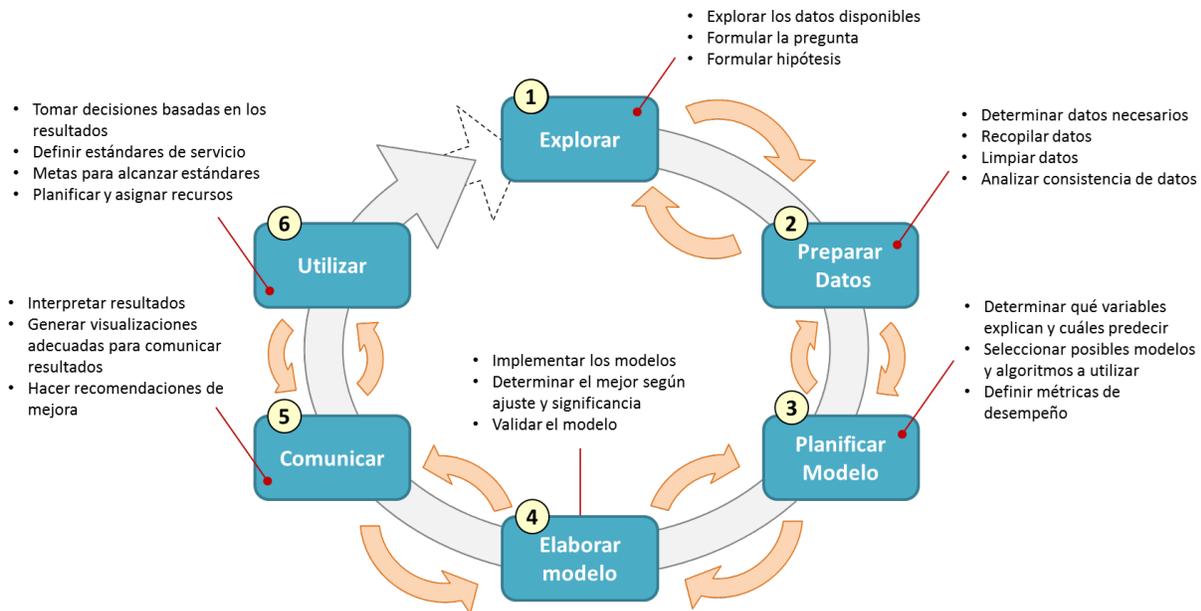


Figura 1: Ciclo de vida del análisis de datos (Schmarzo, 2013)

Como muestra la Figura 1, el proceso de la Ciencia de Datos es un proceso iterativo en que se puede retroceder a etapas previas.

Como las aplicaciones de 'Big Data' pueden beneficiar no solo a las empresas privadas, sino también al sector público (Manyika et al., 2011), nuestra investigación se concentró en buscar a partir de los datos disponibles de forma pública<sup>3</sup> y la metodología de Ciencia de Datos en generar evidencia que permitiera informar la toma de decisiones para la reforma educacional en curso.

### 3 Generación de evidencia para transformar datos en acción

En el sistema educacional chileno, existen diferentes fenómenos que están interrelacionados: el fracaso escolar, el desarrollo territorial y la oferta educativa. Estos se manifiestan en indicadores cuya evolución es necesaria interpretar en contexto en que ocurren. La evaluación de escenarios como los cambios en la oferta educativa, y su potencial consecuencia en el sistema escolar, serán muy útiles para los tomadores de decisiones. Así, las autoridades podrán diseñar y comparar cuantitativa y cualitativamente el impacto de distintas opciones de política pública a nivel micro, meso y macro. A continuación ilustraremos esta potencialidad con ejemplos prácticos.

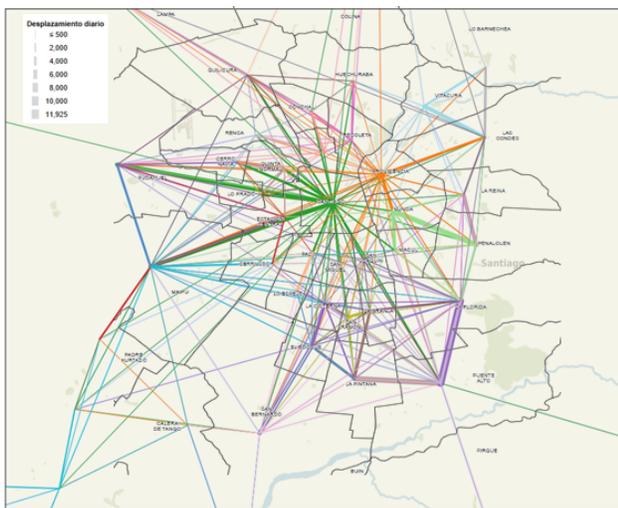
#### 3.1 Desplazamiento diario de estudiantes

Al analizar los datos abiertos de matrícula disponibles en Santiago (Mineduc, 2016), descubrimos que existe una gran cantidad de desplazamientos diarios de estudiantes en todos los niveles y dependencias siendo el volumen de algunos de gran magnitud (Figura 2). Por ejemplo, diariamente viajan desde la comuna de Puente Alto a La Florida, más de **11.000** estudiantes. La pregunta obvia que surge es: **¿Por qué se desplazan?**

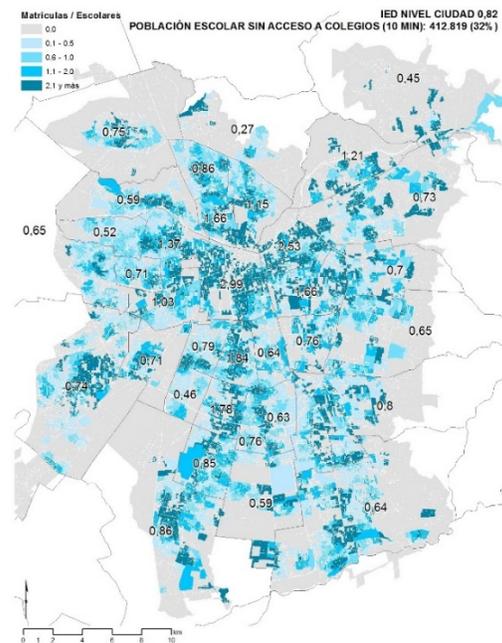
<sup>3</sup> A través de la iniciativa de Gobierno abierto del Estado de Chile, y otras fuentes.

Para explicar este hallazgo, generamos un modelo de cobertura de matrícula para todos los niveles educativos considerando la accesibilidad urbana. Esta se estimó usando un modelo de transporte considerando una distancia dada a cada establecimiento: 10 minutos caminando. Así, calculamos un **Índice de Servicio Escolar (ISE)** para cada manzana de la ciudad, como la relación entre la **oferta** (capacidad disponible en todo establecimiento dentro de una isócrona de 10 minutos caminando desde la manzana) y la **demanda** (población estudiantes de cada manzana según el censo) (Comber et al., 2008; Figueroa, 2008; Hillsdon et al., 2006; Oh and Jeong, 2007; Reyes and Figueroa, 2010).

El ISE visualiza y cuantifica el problema de la brecha de oferta cercana<sup>4</sup> en comunas específicas, que contribuye al desplazamiento de estudiantes (Figura 3).



**Figura 2:** Flujos de estudiantes desde las comunas donde viven a donde estudian. Los colores de las líneas representan viajes a una misma comuna y su grosor el volumen de estudiantes que viaja (sólo se muestran flujos mayores a 100 estudiantes).



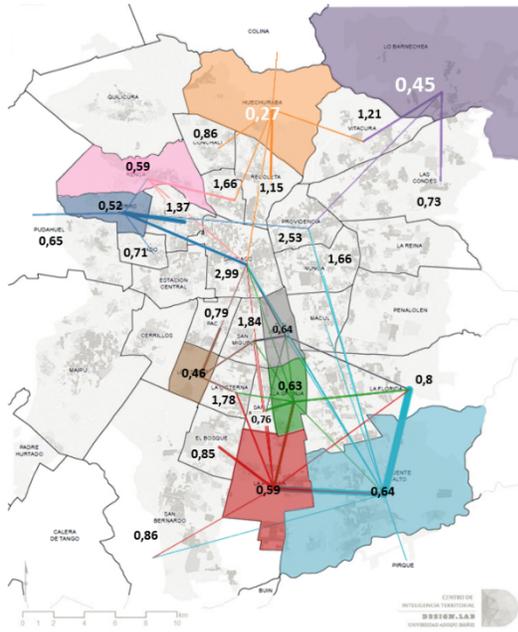
**Figura 3:** ISE para cada manzana del Gran Santiago. Las áreas en gris muestran que no hay vacantes para los estudiantes que viven en dichas manzanas, considerando los colegios a una distancia menor a 10 minutos.

Las áreas grises en la Figura 3 indican que no hay vacantes en 10 minutos caminando (32% de los estudiantes) concentrándose en la periferia de la ciudad. Las áreas azul oscuro tienen superávit de vacantes. Siendo la media a nivel ciudad de **0,82** vacantes por estudiante<sup>5</sup> (Figura 4).

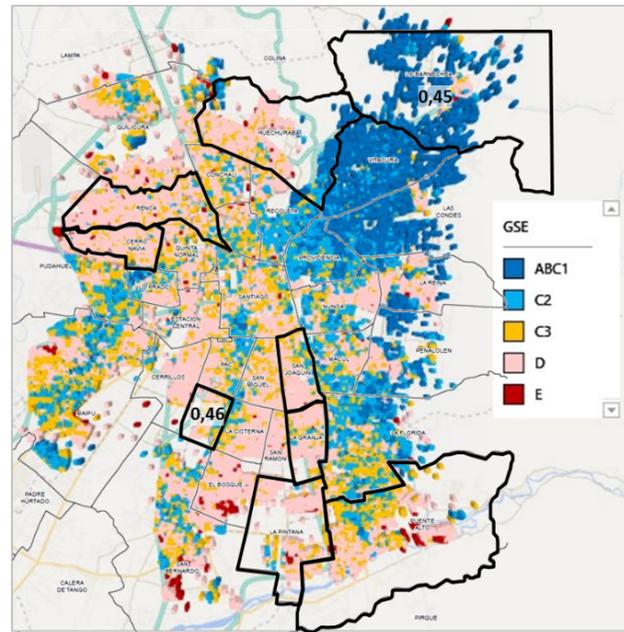
Tomando el mapa de densidad de la Figura 3, la Figura 4 superpone los flujos desde comunas con menores valores de ISE, y muestra que los estudiantes se desplazan a comunas con mayor valor de ISE, lo que puede atribuirse a las brechas oferta-demanda entre comunas. Esto explica, por ejemplo el desplazamiento diario desde Puente Alto (0,64) a La Florida (0,8).

<sup>4</sup> En una isócrona arbitraria de 10 minutos caminando. Este valor puede actualizarse tomando el valor factual del desplazamiento de los estudiantes, por ejemplo, la distancia que hace que el 75% de los estudiantes de un establecimiento se encuentre dentro de la isócrona.

<sup>5</sup> Comunas como Huechuraba, Lo Barnechea, Lo Espejo, Cerro Navia, La Pintana, La Granja y Puente Alto están muy por debajo de la media, mientras otras, tienen índices muy superiores a la media: Santiago, Providencia, San Miguel, La Cisterna, Ñuñoa e Independencia.



**Figura 4:** Flujos de aquellas comunas con mayor exportación de estudiantes (menor ISE), superpuesto con el mapa de la Figura 3 (sólo se muestran flujos mayores a 100 estudiantes). Los estudiantes se desplazan hacia comunas con mejores valores de ISE.



**Figura 5:** Comunas de Lo Espejo y Lo Barnechea en el contexto de la distribución socioeconómica espacial del Gran Santiago. Lo Espejo es una comuna pobre, mientras que Lo Barnechea tiene una alta concentración de familias más adineradas.

Con el nuevo sistema, los establecimientos públicos serán asignados a un SLE según criterios de economías de escala, que la mayoría de las comunas actualmente no cumplen (Paredes et al., 2009). Nuestros resultados muestran que cada establecimiento sirve a una población más amplia a la de su correspondiente comuna. Al visibilizar este fenómeno, se explicita la integración específica entre diferentes comunas, entregando evidencia directa para la asignación territorial o la necesaria coordinación entre los futuros SLE.

El ISE hace tangible diferencias sustantivas entre los territorios que serán parte de los SLE, y se requiere definir un estándar de servicio para cada uno. Teniendo dicho estándar este indicador espacial establece dónde y en cuánto mejorar la cobertura. Esto además tendrá externalidades positivas al reducir viajes, disminuyendo la contaminación ambiental, la congestión vehicular y el subsidio al transporte público.

Pero estos indicadores espaciales deben ser interpretados en su contexto. Por ejemplo, Lo Barnechea y Lo Espejo son comunas con valores similares de ISE (Figura 4), pero con características socioeconómicas de sus habitantes totalmente diferentes (Figura 5). Dada esta evidencia, la política pública debe priorizar mejorar los índices en Lo Espejo.

### 3.2 Acceso a colegios con ciertos estándares de calidad

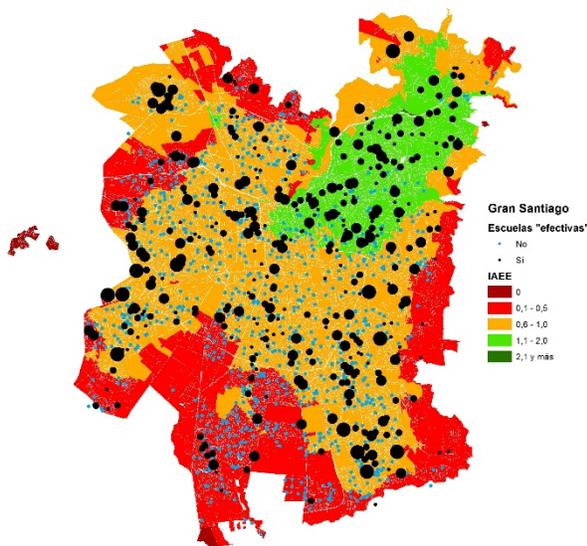
En los primeros años de escolaridad, la cercanía al establecimiento educacional es crítica para los estudiantes de menor GSE, porque si solo tienen acceso a escuelas de baja calidad incrementarán sus probabilidades de fracaso escolar. Entonces existe una “**geografía de las oportunidades educativas**”, oculta a la toma de decisiones en educación. Conocer las brechas de acceso a este tipo de establecimientos permitirá identificar aquellas zonas donde es urgente

mejorar la gestión de algunos establecimientos para asegurar un acceso más equitativo en todo el territorio.

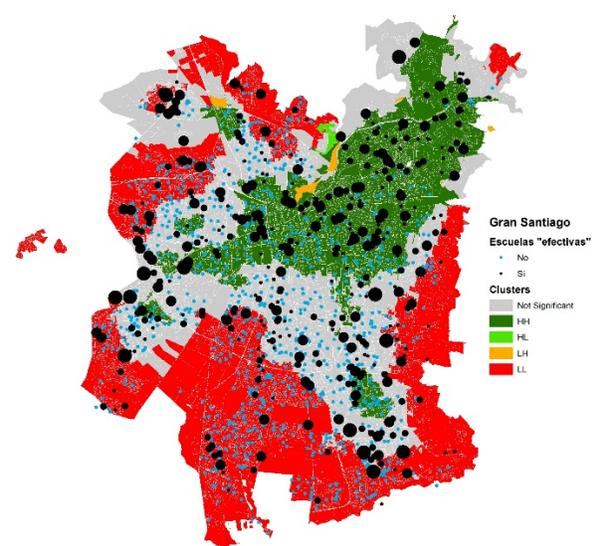
Esto también se puede visualizar construyendo un indicador espacial. A diferencia del ISE, aquí solo se consideran las capacidades de los colegios que cumplan con el estándar definido. Por otro lado, en lugar de elegir una isócrona arbitraria, esta se escoge en función de la disposición a desplazarse de los estudiantes según su edad y grupo socioeconómico (GSE)<sup>6</sup>.

Como estándar de calidad mínimo para un establecimiento se consideró que al menos el 30% de sus estudiantes alcancen un nivel adecuado tanto en los resultados del SIMCE de Lenguaje y Matemáticas de 4 grado de primaria<sup>7</sup>. Así el indicador propuesto restringe la oferta a las capacidades de los establecimientos que cumplan con el estándar. La demanda se corrige según la distancia a la escuela que cumple el estándar más cercano dado la propensión a desplazarse de los estudiantes según su GSE.

Los resultados de este indicador para Gran Santiago considerando los estudiantes de primero a cuarto básico se muestran en la Figura 6. Este análisis también lo hemos repetido para las 22 ciudades más importantes del país<sup>8</sup>.



**Figura 6:** Mapa de Santiago de acceso a escuelas con estándares de calidad a nivel de manzana. En negro se muestran las escuelas efectivas, y en azul las que no. El tamaño relativo de los puntos negros representan las capacidades de las escuelas efectivas. Existen áreas donde si bien hay cobertura de establecimientos, estos no



**Figura 7:** Mapa de Santiago mostrando las agrupaciones HH, HL, LH y LL del indicador. El mapa muestra dos áreas extremas de alto acceso a escuelas que cumplen el estándar y de bajo acceso, la primera hacia el centro y sector oriente de la capital y la otra en la periferia.

<sup>6</sup> En este caso, el tamaño de la isócrona es la distancia que hace 0 la probabilidad de desplazamiento del GSE con mayor propensión a desplazarse. Esta se estimó en base a una muestra de alumnos geolocalizada en la ciudad, utilizando un modelo de transporte para calcular la distancia real hogar-escuela donde estudia. Naturalmente, para diferenciar la propensión a desplazarse por cada GSE se requiere imputar a cada manzana un GSE predominante (en base a datos censales u otros como los permisos de edificación) y conocer la cantidad de estudiantes que viven en cada manzana.

<sup>7</sup> Esto a falta de mediciones más cualitativas más exactas de calidad a nivel censal. Aun así, solo el 29,9% de los establecimientos públicos y particulares subvencionados cumplen con esta definición. Evidentemente estos mapas pueden rehacerse en la medida que esta definición se refine, y este ejercicio tiene más bien un carácter demostrativo.

<sup>8</sup> Arica, Iquique, Antofagasta, Calama, Copiapó, Coquimbo/La Serena, San Antonio, Valparaíso/Viña, Quillota/La Calera, Santiago, Rancagua, Curicó, Talca, Chillán, Los Ángeles, Gran Concepción, Temuco, Valdivia, Osorno, Puerto Montt, Coyhaique y Punta Arenas.

cumplen el estándar definido.

En Santiago, hay una gran diferencia las zonas de ingresos altos (incluso con sobreoferta) y el resto de la ciudad<sup>9</sup> (Figura 6). Parte importante de la ciudad tiene valores bajo 0,5 (26,7%), es decir, la mitad de la capacidad del total requerido para proveer oferta de calidad. De este porcentaje, hay 59.023 niños (72%), pertenecientes a los GSE más bajos y concentrados en la periferia<sup>10</sup>.

Adicionalmente, un análisis de clúster (Anselin, 1995; Moran, 1950) puede identificar espacialmente agrupaciones que presentan una alta concentración de valores altos de la variable analizada rodeados de otros valores igualmente altos (*High-High cluster, HH*), de valores altos rodeados de otros bajos (*High-Low clusters, HL*), de valores bajos rodeados de altos (*Low-High cluster, LH*) y de valores bajos, rodeados de valores igualmente bajos (*Low-Low cluster, LL*).

Así, en Santiago, el Clúster LL equivale a un 40% de la población total de niños del área Metropolitana de Santiago, donde más del 70% son de los grupos D y E, y concentrados en zonas periféricas de alta segregación socioeconómica (Figura 7).

### 3.3 Predicción de la deserción y abandono escolar

Los costos sociales de la **deserción**<sup>11</sup> y el **abandono**<sup>12</sup> son extremadamente altos e incluyen una mayor tasa de criminalidad, menores tasas de crecimiento económico, mayor gasto en servicios públicos<sup>13</sup>, mayor desempleo, menor cohesión social, aumento de la brecha en los ingresos de las personas, menor productividad nacional y menores ingresos por concepto de impuestos (Belfield and Levin, 2007; Mineduc, 2013; OECD, 2010a; Psacharopoulos, 2007). En los países de la OECD, uno de cada tres adultos tiene educación secundaria incompleta y de esta proporción, solo el 50% tiene empleo regular versus el 74% de los que si completaron sus estudios (OECD, 2010a). En EE.UU. se estima que el costo económico de la deserción escolar secundaria alcanza al 1,6% de su PIB (Rouse, 2005).

Una necesaria política pública en este ámbito es identificar a los potenciales afectados para intervenir tempranamente, evitando así la amplificación del problema siendo más eficiente en términos económicos (OECD, 2010a). Así, un sistema de alerta temprana debe hacer seguimiento individual de la asistencia, desempeño escolar u otros factores (OECD, 2010a).

Se construyó modelo para predecir la deserción que inicialmente usó 127 atributos de los estudiantes, establecimientos y las manzanas donde viven o se ubican, para alimentar un algoritmo de aprendizaje automático. Estos atributos se redujeron a 31, entre los cuales aparecen como significativos variables como la vulnerabilidad del colegio, la convivencia, participación, autoestima y motivación de los estudiantes.

---

<sup>9</sup> Ver distribución espacial del GSE en Figura 5.

<sup>10</sup> Principalmente en El Bosque, San Bernardo, Puente Alto, Pudahuel, Huechuraba y Quilicura.

<sup>11</sup> Se considerará desertor al niño o joven que no retorna al sistema escolar luego de haber estado matriculado en el periodo académico anterior, sin que durante este periodo se hayan graduado del sistema escolar (Mineduc, 2013)

<sup>12</sup> Son los estudiantes que, habiendo comenzado el periodo escolar, se retiran de éste durante el mismo año, sin finalizar el grado correspondiente (Mineduc, 2013).

<sup>13</sup> Especialmente en salud y asistencia social.

Se evaluó el ajuste de 6 modelos estadísticos y de aprendizaje automático<sup>14</sup>, siendo el modelo de mejor ajuste el *Two-Class Decision Forest* con una precisión de 0,937 y una tasa de falsos positivos de 8,92% y de falsos negativos de 0,77% sobre un total de 258.378 casos. Un modelo similar se empleó para el abandono, resultando con una precisión similar.

Aunque los datos que se usaron son de Santiago, los modelos son replicables para otras ciudades del país y demuestran la factibilidad de construir un sistema de alerta temprana para prevenir la deserción y abandono escolar.

## 4 Conclusiones

Los ejemplos previos demuestran que usando los datos abiertos disponibles es posible generar evidencia que ayude a tomar mejores decisiones en educación. Aplicando técnicas de Ciencia de Datos, se hacen visibles problemas previamente ocultos, lo que permite su gestión futura.

La dimensión territorial revela la heterogeneidad del país, evidenciando relaciones con factores no educativos previamente ignorados en la toma de decisiones en educación. Esto explicita la necesaria la coordinación y diálogo inter agencias para este fin. Estos análisis además entregan herramientas concretas para dicha comunicación. Los indicadores espaciales permiten **visualizar la inequidad** territorial, permitiendo políticas públicas que superen las limitaciones de la división territorial político-administrativa.

Finalmente, el impacto de estas metodologías depende de las competencias de los usuarios finales. Consecuentemente, la implementación de sistemas de apoyo a la toma de decisiones requiere de un adecuado nivel profesional de los tomadores de decisiones. Es decir, se debe desarrollar “consumidores inteligentes” de información, que identifiquen los problemas que requieren solución, que datos se necesitan y mantener una mente abierta a los resultados que pueden ir en contra de sus concepciones previas (Bienkowski et al., 2012).

De este modo, se puede avanzar hacia una **inteligencia de valor público**, (equivalente social de la inteligencia de negocios) que genere evidencia para las decisiones gubernamentales usando los propios datos que el mismo Estado recopila y genera.

## 5 Trabajo Futuro

Las sofisticadas técnicas necesarias para entender y evaluar los fenómenos previos, son pruebas de la creciente complejidad que las autoridades educativas enfrentan en sus decisiones diarias. Se requieren herramientas que apoyen su labor combinando saber técnico y científico.

Es clave para el uso práctico de la evidencia la forma en que se comunica y cómo los usuarios finales pueden interactuar con ella. Para ello, proponemos, centralizar la información en una plataforma de inteligencia territorial que apoye la gestión de los nuevos SLE, otorgando información oportuna, objetiva, actualizada, y mostrando predicciones sobre ciertas problemáticas de interés. Su esquema de funcionamiento consiste en presentar varias capas de información codificada espacialmente como mapas, cada una de los cuales son indicadores de

---

<sup>14</sup> Se probaron modelos de Logistic regression, Neural networks, Decision jungle, Decision forest, Boosted decision tree y Support vector machines. Los modelos de aprendizaje automático requieren dividir los datos en dos conjuntos, uno que se utiliza para entrenar el modelo y el otro para verificar el ajuste de las predicciones del modelo entrenado. Esto permite contabilizar la tasa de falsos positivos y negativos, y determinar cuan preciso es el modelo en predecir nuevos casos.

elaboración compleja relevantes (como los discutidos en la sección 0). También habrá acceso a otras capas de datos no educacionales externos provistos por otras agencias<sup>15</sup>.

Las capas estarán sincronizadas a la misma escala geográfica, pero cada una tendrá parámetros modificables según el tipo de indicadores<sup>16</sup> (datos). El concepto se ilustra a continuación en la (Figura 8).

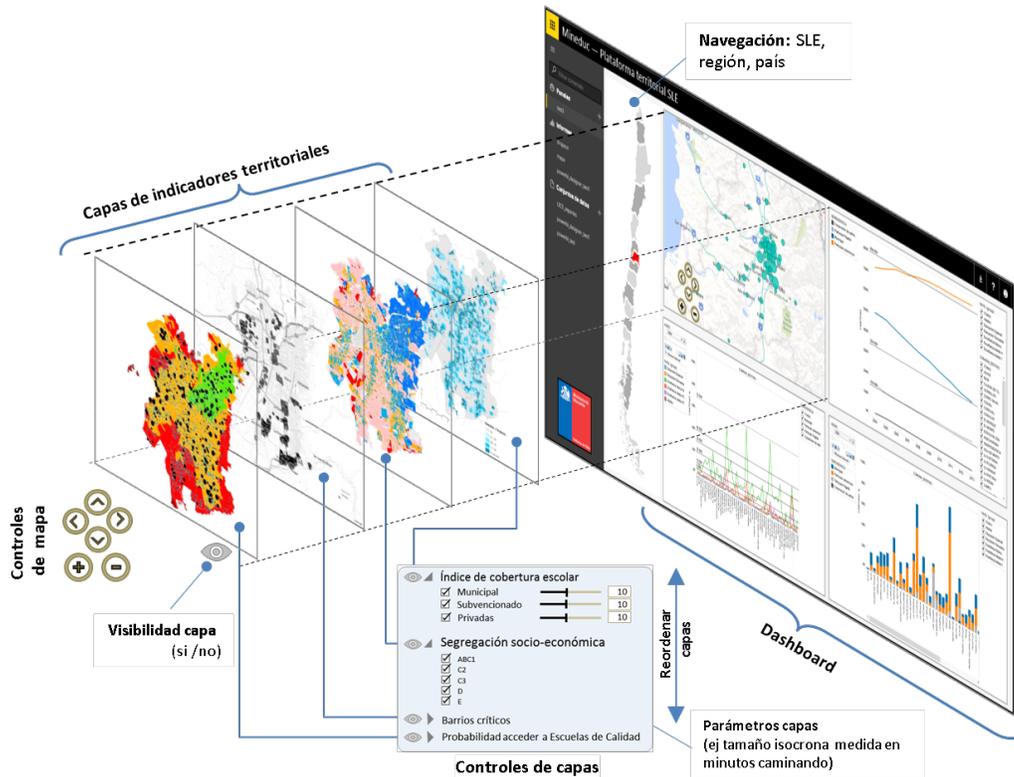


Figura 8: Concepto general de la plataforma territorial propuesta, incluyendo un esquema de *dashboard* y distintas capas de Información en mapas

## 6 Referencias

- Anderson, J.O., Lin, H.-S., Treagust, D.F., Ross, S.P., Yore, L.D., 2007. Using Large-scale Assessment Datasets for Research in Science and Mathematics Education: Programme for International Student Assessment (PISA). *Int J of Sci and Math Educ* 5, 591–614. doi:10.1007/s10763-007-9090-y
- Anselin, L., 1995. Local Indicators of Spatial Association—LISA. *Geographical Analysis* 27, 93–115. doi:10.1111/j.1538-4632.1995.tb00338.x
- Belfield, C.R., Levin, H.M., 2007. *The price we pay: economic and social consequences of inadequate education*. Brookings Institution Press.
- Bienkowski, M., Feng, M., Means, B., 2012. *Enhancing Teaching and Learning through Educational Data Mining and Learning Analytics*.

<sup>15</sup> Ej., delitos, indicadores de salud, ubicación de centros de empleo.

<sup>16</sup> Por ejemplo, en el caso de tener la distribución socioeconómica por manzana será posible mostrar u ocultar grupos específicos (ej. dejando sólo visibles los más vulnerables) o en el caso del índice de servicio escolar, aquellas zonas que tengan menor cobertura

- Comber, A., Brunson, C., Green, E., 2008. Using a GIS-based network analysis to determine urban greenspace accessibility for different ethnic and religious groups. *Landscape and Urban Planning* 86, 103–114. doi:10.1016/j.landurbplan.2008.01.002
- Faubert, B., 2012. A Literature Review of School Practices to Overcome School Failure. OECD Education Working Papers.
- Fazekas, M., Burns, T., 2012. Exploring the Complex Interaction between Governance and Knowledge in Education. OECD Education Working Papers, No. 67.
- Figueroa, I., 2008. Conectividad y accesibilidad de los espacios abiertos urbanos de Santiago. Pontificia Universidad Católica de Chile.
- Gobierno de Chile, 2015. Reforma Educacional - Gobierno de Chile [WWW Document]. URL <http://reformaeducacional.mineduc.cl> (accessed 8.22.15).
- Han, J., Kamber, M., Pei, J., 2011. *Data Mining: Concepts and Techniques*, Third Edition, 3rd ed. Morgan Kaufmann.
- Hilbert, M., López, P., 2011. The World's Technological Capacity to Store, Communicate, and Compute Information. *Science* 332, 60–65. doi:10.1126/science.1200970
- Hillsdon, M., Panter, J., Foster, C., Jones, A., 2006. The relationship between access and quality of urban green space with population physical activity. *Public Health* 120, 1127–1132. doi:10.1016/j.puhe.2006.10.007
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., Hung Byers, A., 2011. Big data: The next frontier for innovation, competition, and productivity.
- Marsh, J.A., Pane, J.F., Hamilton, L.S., 2006. Making Sense of Data-Driven Decision Making in Education [WWW Document]. URL [http://www.rand.org/pubs/occasional\\_papers/OP170.html](http://www.rand.org/pubs/occasional_papers/OP170.html) (accessed 6.18.14).
- Means, B., Padilla, C., DeBarger, A., Bakia, M., 2009. *Implementing Data-Informed Decision Making in Schools*.
- Mineduc, 2016. *Estadísticas del Sistema Educativo*.
- Mineduc, 2013. *Medición de la deserción escolar en Chile (No. 15), Serie Evidencias*. Ministerio de Educación, Chile.
- Moran, P.A.P., 1950. Notes on Continuous Stochastic Phenomena. *Biometrika* 37, 17–23. doi:10.2307/2332142
- OECD, 2016. Chile - OECD Data [WWW Document]. URL <https://data.oecd.org/chile.htm> (accessed 12.14.16).
- OECD, 2015. OECD Income Distribution Database (IDD): Gini, poverty, income, Methods and Concepts [WWW Document]. URL <http://www.oecd.org/social/income-distribution-database.htm> (accessed 8.12.15).
- OECD, 2014. *OECD Rural Policy Reviews: Chile 2014*. Organisation for Economic Co-operation and Development, Paris.
- OECD, 2013. PISA - Organisation for Economic Co-operation and Development [WWW Document]. URL <http://www.oecd.org/pisa/> (accessed 6.18.14).

- OECD, 2011. PISA 2009 key findings [WWW Document]. URL <http://www.oecd.org/pisa/pisaproducts/pisa2009/pisa2009keyfindings.htm> (accessed 5.2.13).
- OECD, 2010a. Overcoming school failure: policies that works.
- OECD, 2010b. Economic Survey of Chile, 2009.
- Oh, K., Jeong, S., 2007. Assessing the spatial distribution of urban parks using GIS. *Landscape and Urban Planning* 82, 25–32. doi:10.1016/j.landurbplan.2007.01.014
- Paredes, R., Maturana, S., Sauma, E., Carrillo, F., García, C., Lagos, F., Stekel, Y., 2009. Configuración nacional de unidades de gestión educativa.
- Psacharopoulos, G., 2007. The Costs of School Failure: A Feasibility Study.
- Reyes, S., Figueroa, I., 2010. Distribución, superficie y accesibilidad de las áreas verdes en Santiago de Chile. *EURE (Santiago)* 36, 89–110. doi:10.4067/S0250-71612010000300004
- Rouse, C.E., 2005. The Labor Market Consequences of an Inadequate Education.
- Schmarzo, B., 2013. *Big Data: Understanding How Data Powers Big Business*. Wiley.
- Staff Science, 2011. Challenges and Opportunities. *Science* 331, 692–693. doi:10.1126/science.331.6018.692
- The Economist, 2010. Data, data everywhere. *The Economist*.
- UNESCO, 2012. Policy brief - Learning Analytics.