



Informe Final

ESTUDIO DE DEMANDA DE LOS PROGRAMAS AMBULATORIOS PARA EL SERVICIO NACIONAL DE PROTECCIÓN ESPECIALIZADA A LA NIÑEZ Y ADOLESCENCIA.

Elaborado por:
Centro de Microdatos, Universidad de Chile.



Diciembre 2023

ESTUDIO DE DEMANDA DE LOS PROGRAMAS AMBULATORIOS PARA EL SERVICIO NACIONAL DE PROTECCIÓN ESPECIALIZADA A LA NIÑEZ Y ADOLESCENCIA.

Diciembre 2023

Elaborado por:

Centro de Microdatos, Universidad de Chile.

Contraparte institucional:

Unidad de Estudios,

Departamento de Estudios y Gestión de la Información,

División de Estudios y Asistencia Técnica,

Servicio Nacional de Protección Especializada a la Niñez y Adolescencia.



CENTRO MICRODATOS
Departamento de Economía

Informe Final

Servicio de estudio de demanda de los programas
ambulatorios para el servicio nacional de
protección especializada a la niñez y adolescencia

Servicio Nacional de Protección Especializada a la Niñez y
Adolescencia

Santiago, diciembre de 2023

Contenido

Introducción.....	3
1. Aspectos generales de la modelación de la demanda	5
1.1 Aspectos generales del modelo.....	5
1.2 Alcances sobre la modelación	6
1.3 Elección de covariables	8
1.4 Escenarios para la proyección de la demanda de reparaciones	10
2. Resultados econométricos (modelación)	11
2.1 Región Metropolitana	11
2.2 Región de Atacama.....	11
2.3 Región de Coquimbo	12
2.4 Región de Valparaíso.....	12
2.5 Región del Biobío.....	13
2.6 Región de La Araucanía.....	14
2.7 Región de Arica y Parinacota.....	14
2.8 Región de Los Lagos	15
2.9 Región del Maule.....	16
2.10 Región del Magallanes	16
2.11 Región de Antofagasta	17
2.12 Región de Ñuble.....	17
2.13 Región de O'Higgins.....	18
2.14 Región de Tarapacá.....	19
2.15 Región de Aysén	19
2.16 Región de Los Ríos.....	20
3. Resultados de la proyección	21
3.1 Resultados de proyecciones totales por región	21
3.2 Imputación de resultados totales a nivel de comunas	21
3.3 Imputación de proyección comunal anual a cada programa.....	24
3.4 Imputaciones regionales mensuales	25

Introducción

Este informe reporta los resultados de las proyecciones de demanda nacional, regional y comunal para los próximos 10 años, bajo distintos escenarios, de la oferta ambulatoria del Servicio de Protección Especializada, considerando los siguientes programas ambulatorios agrupados según se indica: (i) Acompañamiento Familiar Territorial (AFT); (ii) Programa Reparación del Maltrato (PRM); (iii) Programa Intervención Especializada (PIE); y (iv) oferta total ambulatoria del Servicio (AMB), vale decir, la agregación de todos los programas especificados en los puntos (i) a (iii).

Para lo anterior se analizan diversos modelos (especificaciones) para proyectar resultados regionales de la demanda total ambulatoria del Servicio, todos los cuales utilizan información mensual sobre los programas ambulatorios. La especificación que se emplea para la proyección varía según los predictores que se utilicen y la estructura del modelo. La elección del modelo que finalmente se emplea para proyectar se basa en el uso de criterios de información estadísticos (BIC).

La definición de los escenarios (sobre la base del comportamiento de los regresores, es decir, población regional, tasa de desempleo y migración) supone porcentajes exógenos de crecimiento que fácilmente pueden ser modificados por la contraparte (eso cuando el regresor en cuestión es parte de la especificación que se utiliza para proyectar).

A partir de las proyecciones de la demanda total de los programas ambulatorios a nivel regional, este informe se complementa con una imputación de la demanda para (i) Acompañamiento Familiar Territorial (AFT); (ii) Programa Reparación del Maltrato (PRM); y (iii) Programa Intervención Especializada (PIE) a partir de *indicadores de participación histórica* de programas ambulatorios similares que estaban vigentes en la oferta programática pasada del Servicio.

Para la estimación de la participación de cada uno de los programas de la oferta programática ambulatoria nueva, realizamos lo siguiente:

- Para AFT usamos la suma de los datos históricos del Programa Prevención Focalizada (PPF) y del Programa para Discapacidad (PAD).
- Para PRM usamos registros pasados del Programa Reparación del Maltrato en la oferta

programática antigua del Servicio.

- Para PIE usamos registros pasados del Programa Intervención Especializada en la oferta programática antigua del Servicio.

La organización del informe es la siguiente. En la Sección 1 se explica el modelo econométrico utilizado para obtener las proyecciones totales regionales a partir de información mensual disponible. En la Sección 2 se explican los resultados de esta modelación, mostrando la elección del mejor modelo que aplica para proyectar demanda total para la región en particular. A partir de estos resultados, la Sección 3 muestra los resultados numéricos de las proyecciones para el periodo 2023 – 2033, distinguiendo por demanda total y mensual regional, demanda comunal anual, todas las que, a su vez, se desagregan por programa. Estos resultados son reportados in extenso en el archivo *Excel Proyecciones hasta 2033_Mejor Ninez (30Nov2023).xlsx* que acompaña este documento.

Por último, se adjuntan todos los códigos de R que se usaron y que respaldan los resultados obtenidos.

1. Aspectos generales de la modelación de la demanda

1.1 Aspectos generales del modelo

Sobre la base de información administrativa (registros pasados) provista por el Servicio, definamos la variable $D_{r,t}$ como el número de atenciones ambulatorias totales realizadas en la región r en el mes t . Dado lo anterior, es importante destacar que:

- Los registros históricos de la oferta ambulatoria total corresponden a la suma de los datos observados de las atenciones en los siguientes programas: PAD, PAS, PEC, PPF, PEE, PIE, PIB y PRM.
- Como existen 16 regiones en Chile, $r = 1, 2, \dots, 16$, los resultados regionales se pueden desagregar a nivel comunal.
- El Servicio cuenta con información en frecuencia mensual desde enero 2007 hasta diciembre 2022, entonces:
 $t = \text{enero 2007, febrero 2007, } \dots, \text{agosto 2022, diciembre 2022.}$
- Notar que $D_{r,t}$ es un flujo mensual, ya que es el número de atenciones realizadas en la región r , en el mes t .
- Para una región y mes dado, el número de atenciones ambulatoria totales corresponde a los ingresos a la red más los ingresos a la lista de espera (restando los que salen de la lista de espera entrando a la red).

Sobre la base de lo anterior, el modelo que se estima es el siguiente:

$$\log(D_{r,t}) = c + \beta \log(X_{r,t}) + v_{r,t} \quad (1)$$

$$\Phi(L)\Phi_E(L^m)(1-L)^d(1-L^m)^D v_{r,t} = \delta + \Theta(L)\Theta_E(L^m)u_{r,t} \quad (2)$$

donde

- $D_{r,t}$ es el número de atenciones ambulatorias totales realizadas en la región r , en el mes

t ;

- $X_{r,t}$ es un **vector** de predictores que son relevantes para explicar las reparaciones $D_{r,t}$;
- β es un vector de parámetros a estimar; $u_{r,t}$ es un ruido blanco.

En (2) anterior, L es el operador de rezago estándar, $Ly_t = y_{t-1}$, y además se entiende que

$$\Phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$$

$$\Phi_E(L^m) = 1 - \phi_{E1} L^m - \phi_{E2} L^{2m} - \dots - \phi_{EP} L^{Pm}$$

$$\Theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q$$

$$\Theta_E(L^m) = 1 - \theta_{E1} L^m - \theta_{E2} L^{2m} - \dots - \theta_{EQ} L^{Qm}$$

son los operadores de rezagos autorregresivos (AR) y de media móvil (MA) que se supone son estacionarios e invertibles, respectivamente.

De lo anterior, $v_{r,t}$ puede escribirse, de manera equivalente, como $ARIMA(p, d, q)(P, D, Q)_m$ donde m representa la frecuencia estacional de la serie (en nuestro caso $m = 12$, asumiendo que los datos son mensuales). Cabe señalar que las ecuaciones (1) y (2) se ajustan, de forma separada, al número de reparaciones según región, considerando las series de tiempo en frecuencia mensual.

1.2 Alcances sobre la modelación

Sobre el modelo y método que se usa para estimar se tienen los siguientes comentarios y alcances:

- El modelo dado por las ecuaciones (1) y (2) es uno de series de tiempo que incluye predictores exógenos. Es decir, además de considerar los patrones tendenciales y estacionales que presenta la información histórica (mensual), también contempla la inclusión de variables explicativas exógenas que sean relevantes para predecir las variables de resultado (endógenas) de interés.
- La elección de los rezagos en las especificaciones (1) y (2) se obtienen de **manera óptima** de tal forma de equilibrar el ajuste de los datos dentro de muestra y el poder predictivo del modelo fuera de muestra.

- c. Todas las rutinas serán programas en R, quedando a disposición de la contraparte de modo de ser auditables en caso de ser necesario.
- d. Se propone realizar diversos ejercicios de proyección fuera de muestra para verificar la calidad de las proyecciones que se obtienen.
- e. Importantemente, para seleccionar el mejor modelo en términos de inclusión de rezagos en las partes AR y MA de la ecuación (2), se usa el Criterio de Información Bayesiano (*BIC*). Además de seleccionar modelos más parsimoniosos, el *BIC* tiene la ventaja de ser un criterio de selección de modelos que es consistente, es decir, selecciona el modelo correcto con probabilidad uno cuando contamos con un número suficientemente grande de observaciones en la muestra. En la práctica, se opta por el modelo con el menor *BIC* (es decir, el mayor *BIC* en valor absoluto puesto que dicho indicador es negativo).
- f. Para el análisis de modelación de $D_{r,t}$ se debe aplicar la prueba de raíz unitaria estacional de Wang, Smith y Hyndman (2006) a la serie de tiempo $\log(D_{r,t})$, para estudiar si corresponde diferenciar la serie en doce meses para que sea estacionaria. Si se rechaza la hipótesis de estacionariedad estacional, se recomienda trabajar con la serie de tiempo $\log(D_{r,t}) - \log(D_{r,t-12})$, que es una aproximación a la variación porcentual en doce meses del número de reparaciones.
- g. Luego, al implementar las pruebas de raíz unitaria estándar (prueba de Dickey-Fuller Aumentada, ADF) a la serie $\log(D_{r,t}) - \log(D_{r,t-12})$, se debe estudiar si es estacionaria a los niveles de significancia estándar. En caso de corresponder, la serie se debe diferenciar las veces que sea necesario hasta no poder rechazar la hipótesis de estacionariedad de la prueba ADF. Este ejercicio se repite para las series de datos de número de reparaciones según comuna, tipo de ingreso, rango etario.
- h. Para cada modelo estimado, se debe evaluar si los residuos estimados son un ruido blanco o no. Para este propósito, se aplica la prueba de Ljung-Box. El modelo seleccionado debe cumplir con el rechazo de la hipótesis que los residuos estimados no son ruido blanco.

- i. En la medida que nuevos datos administrativos van apareciendo, el modelo se puede volver a estimar de modo de actualizar las proyecciones.

La pretensión del ejercicio según lo indicado es obtener proyecciones de $D_{r,t}$ que satisfagan todas las condiciones de *robustez* estadística para obtener resultados confiables, replicables y auditables. Este es un ejercicio complejo que requiere la prueba y estudio de diversas especificaciones, además del desarrollo de ejercicios de proyección fuera de muestra para analizar la bondad de los resultados obtenidos.

1.3 Elección de covariables

Un tema relevante en el modelo dado por las ecuaciones (1) y (2) está dado por la elección del vector de variables explicativas $X_{r,t}$ en la ecuación (1). Naturalmente, esta elección dependerá de la calidad y cantidad de información que haya. En principio, consideramos *tres variables explicativas* para realizar el análisis.

En *primer lugar*, variables relacionadas al *crecimiento poblacional* que proyecta el Instituto Nacional de Estadísticas (INE) a nivel regional. La justificación teórica de estas variables está dada por el hecho de que, si la población de niños, niñas y adolescentes aumenta, uno esperaría una demanda mayor por reparaciones. Esta información histórica y proyecciones a 2035 está disponibles en el INE en frecuencia mensual. Para introducir este predictor en el modelo, mensualizamos los datos anuales de modo que la serie mensual resultante es consistente con el nivel y tasas de crecimientos anuales de los datos del INE.

En *segundo lugar*, consideramos la tasa de desempleo como predictores económicos exógenos a incluir en la ecuación (1). Las series de tiempo mensual de la *tasa de desempleo regional* se puede construir a partir de los datos de empleo que publica el INE. La justificación teórica de estas variables radica en el hecho de que, si el nivel socioeconómico es menor (medido por la tasa de desempleo), uno esperaría que el nivel de desprotección de los niños, niñas y adolescentes sea mayor y, por tanto, la demanda de reparaciones sea más alta. Para proyectar la tasa de desempleo de cada región en el horizonte de proyección, consideramos la tasa de desempleo de los meses de 2019. Este escenario se puede sensibilizar con la contraparte técnica del estudio.

Destaca el hecho que usar índices de actividad económica (IMACEC) tiene el inconveniente de, primero, no conocer cifras regionales y, segundo, es muy complejo proyectar esas variables a nivel regional (incluso nacional).

En *tercer lugar*, consideramos la inclusión de variables relacionadas con la *migración internacional* en cada región como predictores exógenos del modelo dado por la ecuación (1). La justificación teórica de estas variables está dada por el hecho que, si una zona recibe más familias migrantes, naturalmente éstas presionarán el sistema de protección de menores porque muchas de esas familias son muy vulnerables y, por tanto, la demanda por reparaciones será mayor.

Para construir las series de tiempo mensual de las variables relacionadas con la migración internacional, usamos datos de INE de migración anual para cada región para los años 2018-2021. Para construir los datos del período 2010-2017, se usan las tasas de crecimiento del número de permisos temporales para migrantes a nivel regional (disponibles en <https://serviciomigraciones.cl/>) de modo de hacer el empalme. Para introducir este predictor en el modelo, mensualizamos los datos anuales de modo que la serie mensual resultante es consistente con el nivel y tasas de crecimientos anuales.

Para evaluar la significancia estadística de las variables exógenas ($X_{r,t}$) que se considera incluir en el modelo (1) y (2), nuestra propuesta técnica considera llevar a cabo la prueba estadística estándar, basada en aproximaciones normales, donde de manera individual se testea la hipótesis nula que el coeficiente (el β correspondiente) que acompaña al predictor bajo análisis es igual a cero contra la hipótesis alternativa de que dicho coeficiente es distinto de cero. Una vez que se estima el modelo, podemos calcular el valor-p del test y comparar dicho valor con el nivel de significancia de modo de concluir: si el valor-p es menor o igual que 5%, rechazamos la hipótesis nula y, por tanto, el predictor bajo análisis es significativo; mientras que si el valor-p es mayor que 5%, no podemos rechazar la hipótesis nula y, por tanto, el predictor bajo análisis no es significativo. De forma complementaria, evaluamos si el signo del coeficiente estimado es el esperado.

Sobre la base de lo anterior, una vez que estimamos el modelo dado por las ecuaciones (1) y (2) para las series de tiempo de reparaciones realizadas en la región r , podemos estimar (proyectar) las reparaciones en la región r , es decir, $\hat{D}_{r,t}$, para cada uno de los meses contemplados en el horizonte de proyección (50 años, por ejemplo). Luego, notar que es posible

agregar $\hat{D}_{r,t}$ de modo de proyectar la demanda “agregada” que se desee, sumando en las dimensiones (sub-índices) correspondientes.

Los intervalos de confianza de las proyecciones que surgen una vez que se estima el modelo dado por las ecuaciones (1) y (2) se basan en aproximaciones normales. Por último, es importante destacar que mientras más alejado es el horizonte de proyección, la incertidumbre es mayor y por tanto el intervalo de confianza correspondiente es más ancho (más largo).

1.4 Escenarios para la proyección de la demanda de reparaciones

A continuación, se presentan los resultados de las estimaciones de los modelos y las proyecciones. Los resultados se presentan para cada región del país. En caso de que el modelo seleccionado incluya como predictor al número de migrantes (y-o población), los *escenarios de proyección* de demanda que consideramos son los siguientes:

- *Escenario central:* Migración sigue evolucionando a las tasas de crecimiento actuales que evidencia cada región. Mientras que la población sigue evolucionando a partir de la proyectada por el INE.
- *Escenario de demanda baja:* Migración se desacelera, evolucionando a la mitad de las tasas de crecimiento actuales que evidencia cada región, mientras que la población sigue evolucionando como la mitad de las tasas de crecimiento proyectadas por el INE.
- *Escenario de demanda alta:* Migración se acelera, evolucionando a 1,5 veces las tasas de crecimiento actuales que evidencia cada región, mientras que la población sigue evolucionando como 1,5 veces las tasas de crecimiento proyectadas por el INE.

2. Resultados econométricos (modelación)

2.1 Región Metropolitana

La Tabla 1 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región Metropolitana en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo.

Como se puede apreciar en la Tabla 1, todos los modelos son competitivos en base al BIC. Ahora bien, en el modelo SARIMAX con predictores dados por los *migrantes* y la *población*, el coeficiente estimado para la población es negativo en dicho modelo, por lo cual se descarta debido a que el resultado es contrario a lo esperado. Asimismo, el modelo con desempleo también se descarta porque el coeficiente que acompaña al desempleo no estadísticamente distinto de cero. El modelo de serie de tiempo no logra recuperar la tendencia de los datos, especialmente al proyectar fuera de muestra. Sobre la base de lo anterior, la especificación con el predictor dado por *población* es el modelo seleccionado para hacer la proyección.

Tabla 1: selección de modelo de serie de tiempo para la Región Metropolitana

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-45,72	-44,07	-42,83	-41,33	-43,64

El modelo con predictor dado por *población* que es finalmente seccionado es uno donde los errores siguen un $ARIMA(0,1,1)(0,0,0)_{12}$ y el coeficiente que acompaña a la variable población es positiva y estadísticamente distinta de cero.

2.2 Región de Atacama

La Tabla 2 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Atacama en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 2, el modelo que presenta el menor valor del BIC es el SARIMAX con predictor dado por la población (y el signo

de su coeficiente estimado es positivo, en línea con esperado), por lo cual este es el modelo seleccionado para hacer la proyección.

Tabla 2: selección de modelo de serie de tiempo para la Región de Atacama

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-6,06	-6,93	-8,57	-7,07	-3,12

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(0,0,2)(1,0,0)_{12}$.

2.3 Región de Coquimbo

La Tabla 3 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de esta región, en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 3, el modelo que presenta el menor valor del BIC es el SARIMAX con predictor dado por la población (y el signo de su coeficiente estimado es positivo, en línea con esperado), por lo cual este es el modelo seleccionado para hacer la proyección.

Tabla 3: selección de modelo de serie de tiempo para la Región de Coquimbo

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-21,22	-27,45	-32,92	-28,59	-17,72

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un ruido blanco.

2.4 Región de Valparaíso

La Tabla 4 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Valparaíso en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 4, el modelo que

tiene el menor valor del BIC es el SARIMAX con predictores dados por los *migrantes* y la *población*; sin embargo, el coeficiente estimado para los migrantes es negativo en dicho modelo, por lo cual se descarta debido a que el resultado es contrario a lo esperado. El modelo de serie de tiempo puro también se descarta porque sus proyecciones no logran rescatar el patón tendencial de los datos. Por lo tanto, la especificación con el predictor dado por *población* es el modelo seleccionado para hacer la proyección, ya que presenta el tercer BIC más bajo (y el coeficiente de población es positivo y significativo).

Tabla 4: selección de modelo de serie de tiempo para la Región de Valparaíso

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-118,99	-110,04	-114,06	-127,63	-112,08

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(1,0,0)(0,0,0)_{12}$.

2.5 Región del Biobío

La Tabla 5 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región del Biobío en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 5, el modelo que tiene el menor valor del BIC es el SARIMAX con predictores dado por el *desempleo*; sin embargo, el coeficiente estimado para el desempleo es negativo en dicho modelo, por lo cual se descarta debido a que el resultado es contrario a lo esperado. El modelo que presenta el segundo menor valor del BIC es el SARIMAX puro, pero no se considera porque su proyección no recupera la tendencia histórica de los datos. El modelo que finalmente se selecciona para proyectar es aquella especificación con predictor dado por la población (aunque el modelo con migrantes también es competitivo).

Tabla 5: selección de modelo de serie de tiempo para la Región del Biobío

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-66,57	-62,47	-61,08	-57,39	-66,25

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(1,0,1)(1,0,0)_{12}$ y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.6 Región de La Araucanía

La Tabla 6 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de La Araucanía en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 6, el modelo que presenta el menor valor del BIC es el SARIMAX con predictor dado por la población (y el signo de su coeficiente estimado es positivo, en línea con esperado), por lo cual este es el modelo seleccionado para hacer la proyección.

Tabla 6: selección de modelo de serie de tiempo para la Región de La Araucanía

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-7,49	-4,41	-15,46	-11,23	-3,22

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(0,0,0)(1,0,0)_{12}$ y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.7 Región de Arica y Parinacota

La Tabla 7 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Arica y Parinacota en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 7, el modelo que tiene el menor valor del BIC es el SARIMAX con desempleo, pero se descarta porque el signo del coeficiente de la variable desempleo no es consistente con lo esperado. El modelo con el siguiente BIC más bajo es aquel con predictores dados por los *migrantes* y la *población*; sin embargo, el coeficiente estimado para los migrantes es negativo en dicho modelo, por lo cual se

descarta debido a que el resultado es contrario a lo esperado. El modelo de serie de tiempo puro también se descarta porque sus proyecciones no logran rescatar el patrón tendencial de los datos. Por lo tanto, la especificación con el predictor dado por *población* es el modelo seleccionado para hacer la proyección, ya que presenta el siguiente BIC más bajo (y el coeficiente de población es positivo y significativo).

Tabla 7: selección de modelo de serie de tiempo para la Región de Arica y Parinacota

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	70,33	73,13	72,98	69,48	69,14

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(0,0,0)(0,0,1)_{12}$ y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.8 Región de Los Lagos

La Tabla 8 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Los Lagos en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 8, el modelo que tiene el menor valor del BIC es el SARIMAX con el predictor dado por *población* es el modelo seleccionado para hacer la proyección (además, presenta un coeficiente de población es positivo y significativo).

Tabla 8: selección de modelo de serie de tiempo para la Región de Los Lagos

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-38,77	-31,86	-47,24	-46,56	-34,21

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(0,0,0)(1,0,0)_{12}$ y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.9 Región del Maule

La Tabla 9 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región del Maule en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 9, el modelo que tiene el menor valor del BIC es el SARIMAX con predictores dados por los *migrantes* y la *población*; sin embargo, el coeficiente estimado para los migrantes es negativo en dicho modelo, por lo cual se descarta debido a que el resultado es contrario a lo esperado. Aunque el modelo de serie de tiempo puro es competitivo, también se descarta porque sus proyecciones no logran rescatar el patrón tendencial de los datos. Por lo tanto, la especificación con el predictor dado por *población* es el modelo seleccionado para hacer la proyección, ya que presenta el siguiente BIC más bajo (y el coeficiente de población es positivo y significativo).

Tabla 9: selección de modelo de serie de tiempo para la Región del Maule

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	4,33	12,21	5,94	-2,25	9,59

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un proceso de ruido blanco y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.10 Región del Magallanes

La Tabla 10 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Magallanes en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 10, el modelo que presenta el menor valor del BIC es el SARIMAX con predictor dado por la población (y su coeficiente es positivo y significativo). Por este motivo nos quedamos con ese modelo para hacer la proyección.

Tabla 10: selección de modelo de serie de tiempo para la Región de Magallanes

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	76,13	74,28	69,08	72,27	77,71

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un ruido blanco y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.11 Región de Antofagasta

La Tabla 11 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Antofagasta en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 11, todos los modelos parecen ser competitivos en base al BIC. Ahora bien, el modelo SARIMAX con predictor dado por la tasa de desempleo presenta un el coeficiente estimado que no es significativo. Para proyectar, nos quedamos con el modelo dado por el SARIMAX con la población (con coeficiente positivo y significativo) como regresor.

Tabla 11: selección de modelo de serie de tiempo para la Región de Antofagasta

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-10,97	-9,41	-7,07	-9,99	-7,05

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(1,0,0)(0,0,0)_{12}$ y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.12 Región de Ñuble

La Tabla 12 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Ñuble en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con

predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 12, el modelo que tiene el menor valor del BIC es el SARIMAX con predictores dados por los *migrantes* y la *población*; sin embargo, el coeficiente estimado para los migrantes es negativo en dicho modelo, por lo cual se descarta debido a que el resultado es contrario a lo esperado. Aunque el modelo de serie de tiempo puro es competitivo, también se descarta porque sus proyecciones no logran rescatar el patrón tendencial de los datos, especialmente en su proyección futura. Por lo tanto, la especificación con el predictor dado por *población* es el modelo seleccionado para hacer la proyección, ya que presenta el siguiente BIC más bajo (y el coeficiente de población es positivo y significativo).

Tabla 12: selección de modelo de serie de tiempo para la Región de Ñuble

SARIMAX					
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	46,37	50,32	47,77	43,58	50,58

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un proceso de ruido blanco y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.13 Región de O'Higgins

La Tabla 13 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de O'Higgins en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo.

Como se puede apreciar en la Tabla 13, el modelo que tiene el menor valor del BIC es el SARIMAX con predictores dados por los *migrantes* y la *población*; sin embargo, el coeficiente estimado para los migrantes es negativo en dicho modelo, por lo cual se descarta debido a que el resultado es contrario a lo esperado. Por lo tanto, la especificación con el predictor dado por *población* es el modelo seleccionado para hacer la proyección, ya que presenta el siguiente BIC más bajo (y el coeficiente de población es positivo y significativo).

Tabla 13: selección de modelo de serie de tiempo para la Región de O'Higgins

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	-8,13	-5,95	-8,36	-9,18	-5,67

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(1,0,0)(0,0,0)_{12}$ y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.14 Región de Tarapacá

La Tabla 14 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Tarapacá en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 14, el modelo con predictor exógeno que presenta el menor valor del BIC es el SARIMAX con predictor dado por la población (con signo positivo y significativo). Por este motivo nos quedamos con el modelo para hacer la proyección.

Tabla 14: selección de modelo de serie de tiempo para la Región de Tarapacá

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	72,44	76,57	68,35	70,77	75,52

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un $ARIMA(1,0,0)(0,0,0)_{12}$ y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.15 Región de Aysén

La Tabla 15 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Aysén en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 15, el modelo con

predictor exógeno que presenta el menor valor del BIC es el SARIMAX con predictor dado por la población (con signo positivo y significativo). Por este motivo nos quedamos con el modelo para hacer la proyección.

Tabla 15: Selección de modelo de serie de tiempo para la Región de Aysén

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	57,15	60,31	54,22	54,58	58,60

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un ruido blanco y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

2.16 Región de Los Ríos

La Tabla 16 presenta los valores del BIC para distintos modelos de series de tiempo que se estiman con datos de la Región de Los Ríos en frecuencia mensual: SARIMA puro (sin predictores); SARIMAX con predictor dado por los migrantes; SARIMAX con predictor dado por la población; SARIMAX con predictores dados por los migrantes y la población; y SARIMAX con predictor dado por la tasa de desempleo. Como se puede apreciar en la Tabla 16, el modelo con predictor exógeno que presenta el menor valor del BIC es el SARIMAX con predictor dado por la población (con signo positivo y significativo). Por este motivo nos quedamos con el modelo para hacer la proyección.

Tabla 16: selección de modelo de serie de tiempo para la Región de Los Ríos

	SARIMAX				
	Puro	Migrantes	Población	Migrantes y Población	Desempleo
BIC	34,83	38,12	28,69	32,24	37,21

El modelo con predictor dado por *población* que es el finalmente seccionado es uno donde los errores siguen un blanco y donde el coeficiente del predictor dado por la variable población es positivo (consistente con lo esperado) y estadísticamente significativo.

3. Resultados de la proyección

3.1 Resultados de proyecciones totales por región

La tabla a continuación presenta las proyecciones totales, a nivel regional, *escenario central*, que resultan del mejor modelo según lo anterior, para el periodo 2023 – 2033. Los resultados de las proyecciones para escenarios *bajo* y *alto* se encuentran en el archivo *Proyecciones hasta 2033_Mejor Ninez (30Nov2023).xlsx*, adjunto a este informe.

Tabla 17: proyecciones regionales anuales de los totales

Región	2023	2024	2025	2026	2027	2028	2029	2030	2031	2032	2033
Antofagasta	5.671	5.909	6.138	6.363	6.586	6.804	7.017	7.224	7.432	7.646	7.865
Araucanía	3.340	3.553	3.765	3.977	4.186	4.391	4.589	4.778	4.967	5.162	5.366
Arica y Parinacota	2.323	2.478	2.635	2.795	2.957	3.121	3.288	3.456	3.629	3.810	4.001
Aysén	621	627	634	641	648	656	663	670	677	685	693
Biobío	7.672	8.084	8.464	8.815	9.135	9.423	9.675	9.890	10.089	10.292	10.498
Coquimbo	3.506	3.719	3.937	4.163	4.395	4.634	4.879	5.130	5.391	5.666	5.954
Los Lagos	4.596	4.969	5.352	5.745	6.147	6.555	6.967	7.380	7.804	8.253	8.728
Los Ríos	1.832	1.976	2.123	2.272	2.422	2.573	2.723	2.869	3.018	3.174	3.339
Magallanes	1.042	1.081	1.121	1.163	1.207	1.253	1.300	1.348	1.399	1.452	1.506
Maule	6.743	7.444	8.190	8.981	9.814	10.686	11.594	12.537	13.535	14.613	15.776
Metropolitana	18.074	18.710	19.326	19.930	20.520	21.093	21.646	22.174	22.698	23.234	23.783
Ñuble	3.651	4.084	4.544	5.026	5.524	6.035	6.551	7.065	7.595	8.166	8.779
O'Higgins	6.340	6.925	7.538	8.179	8.846	9.535	10.242	10.964	11.717	12.522	13.382
Tarapacá	2.335	2.508	2.687	2.872	3.065	3.265	3.473	3.686	3.910	4.148	4.400
Valparaíso	14.317	15.382	16.484	17.626	18.803	20.011	21.246	22.503	23.808	25.188	26.648
Atacama	2.425	2.469	2.509	2.546	2.580	2.611	2.639	2.664	2.688	2.711	2.735
Total	84.489	89.916	95.447	101.093	106.835	112.645	118.492	124.341	130.358	136.722	143.453

3.2 Imputación de resultados totales a nivel de comunas

Usando las observaciones comunales del periodo 2015 – 2022 se obtiene la participación promedio de cada una de ellas dentro de la región correspondiente. Este *factor comunal* de demanda se normaliza al interior de las comunas de cada región para obtener un indicador de participación de la comuna dentro de la región (dentro de cada región, el factor comunal suma 100%). De esta manera, manteniendo constante las proporciones (según lo anterior) durante el periodo de proyección, se obtiene entonces una imputación de la demanda comunal total a partir de las proyecciones regionales que se reportaron.

Los resultados del factor comunal que aplican a cada comuna dentro de cierta región se encuentran en la hoja **Factor Comunal Anual** del archivo *Proyecciones hasta 2033_Mejor Ninez (30Nov2023).xlsx*, adjunto a este informe. A este respecto, el cuadro a continuación muestra las tres comunas con mayor proporción de demanda dentro de cada región, lo que corresponde a decir las tres comunas con mayor factor comunal anual por cada región.

Tabla 18: factores comunales de las tres comunas con mayor indicador según región

Región	Comuna	Factor comunal (promedio 2015/2022)
Antofagasta	ANTOFAGASTA	59,70%
	CALAMA	22,11%
	TOCOPILLA	7,04%
Araucanía	TEMUCO	17,26%
	ANGOL	9,78%
	VILLARRICA	6,18%
Arica y Parinacota	ARICA	99,51%
	PUTRE	0,26%
	CAMARONES	0,22%
Atacama	COPIAPÓ	46,55%
	VALLENAR	19,74%
	CALDERA	7,91%
Aysén	COYHAIQUE	45,43%
	AYSÉN	32,77%
	CHILE CHICO	7,67%
Biobío	LOS ÁNGELES	12,41%
	CONCEPCIÓN	10,69%
	SAN PEDRO DE LA PAZ	8,29%
Coquimbo	COQUIMBO	32,66%
	LA SERENA	23,89%
	OVALLE	16,79%
Los Lagos	PUERTO MONTT	28,81%
	OSORNO	26,81%
	ANCUD	8,71%
Los Ríos	VALDIVIA	24,88%
	PANGUIPULLI	11,24%
	PAILLACO	10,11%
Magallanes	PUNTA ARENAS	75,92%
	NATALES	15,04%
	PORVENIR	6,11%
Maule	TALCA	17,04%
	CURICÓ	12,31%
	LINARES	10,92%
	PUENTE ALTO	8,43%

Región	Comuna	Factor comunal (promedio 2015/2022)
Metropolitana	MAIPÚ	6,46%
	LA FLORIDA	5,35%
Ñuble	CHILLÁN	31,43%
	SAN CARLOS	12,05%
	BULNES	6,27%
O'Higgins	RANCAGUA	20,91%
	RENGO	9,54%
	SAN FERNANDO	9,47%
Tarapacá	ALTO HOSPICIO	44,73%
	IQUIQUE	41,27%
	POZO ALMONTE	9,58%
Valparaíso	VALPARAÍSO	17,23%
	VIÑA DEL MAR	12,78%
	VILLA ALEMANA	7,53%

Lo anterior combinado con las proyecciones regionales permite obtener imputaciones de demanda para cada comuna del país. Como se indicó, esto corresponde a multiplicar la correspondiente proyección que hay para cada año – escenario por el factor constante que se explicó. Los resultados de este ejercicio se reportan en la hoja **Comunal Total Anual** del archivo *Proyecciones hasta 2033_Mejor Ninez (30Nov2023).xlsx*. A modo de resumen, el cuadro a continuación muestra las proyecciones de las comunas de la tabla anterior, esto para el escenario central y el periodo.

Tabla 19: proyecciones comunales de las tres comunas con mayor indicador según región, escenario central, periodo 2023 – 2030

Región	Comuna	2023	2024	2025	2026	2027	2028	2029	2030
Antofagasta	ANTOFAGASTA	3.386	3.528	3.665	3.799	3.932	4.062	4.189	4.313
	CALAMA	1.254	1.307	1.357	1.407	1.456	1.504	1.552	1.597
	TOCOPILLA	399	416	432	448	463	479	494	508
Araucanía	TEMUCO	576	613	650	686	722	758	792	825
	ANGOL	327	347	368	389	409	429	449	467
	VILLARRICA	206	220	233	246	259	271	284	295
Arica y Parinacota	ARICA	2.312	2.466	2.622	2.781	2.942	3.106	3.272	3.439
	PUTRE	6	6	7	7	8	8	8	9
	CAMARONES	5	5	6	6	6	7	7	8
Atacama	COPIAPÓ	1.129	1.149	1.168	1.185	1.201	1.215	1.229	1.240
	VALLENAR	479	487	495	503	509	515	521	526
	CALDERA	192	195	198	201	204	206	209	211
Aysén	COYHAIQUE	282	285	288	291	295	298	301	304
	AYSÉN	203	206	208	210	212	215	217	220
	CHILE CHICO	48	48	49	49	50	50	51	51

Región	Comuna	2023	2024	2025	2026	2027	2028	2029	2030
Biobío	LOS ÁNGELES	952	1.003	1.051	1.094	1.134	1.170	1.201	1.228
	CONCEPCIÓN	820	864	905	943	977	1.008	1.035	1.058
	SAN PEDRO DE LA PAZ	636	670	702	731	757	781	802	820
Coquimbo	COQUIMBO	1.145	1.215	1.286	1.360	1.435	1.513	1.593	1.676
	LA SERENA	838	888	941	994	1.050	1.107	1.165	1.226
	OVALLE	589	624	661	699	738	778	819	861
Los Lagos	PUERTO MONTT	1.324	1.432	1.542	1.655	1.771	1.889	2.007	2.126
	OSORNO	1.232	1.332	1.435	1.540	1.648	1.758	1.868	1.979
	ANCUD	400	433	466	500	535	571	607	643
Los Ríos	VALDIVIA	456	492	528	565	603	640	677	714
	PANGUIPULLI	206	222	239	255	272	289	306	323
	PAILLACO	185	200	215	230	245	260	275	290
Magallanes	PUNTA ARENAS	791	820	851	883	917	951	987	1.024
	NATALES	157	162	169	175	182	188	195	203
	PORVENIR	64	66	69	71	74	77	79	82
Maule	TALCA	1.149	1.268	1.395	1.530	1.672	1.820	1.975	2.136
	CURICÓ	830	916	1.008	1.106	1.208	1.315	1.427	1.543
	LINARES	737	813	895	981	1.072	1.167	1.267	1.370
Metropolitana	PUENTE ALTO	1.524	1.578	1.630	1.681	1.730	1.779	1.825	1.870
	MAIPÚ	1.167	1.208	1.248	1.287	1.325	1.362	1.397	1.431
	LA FLORIDA	967	1.001	1.034	1.067	1.098	1.129	1.158	1.187
Ñuble	CHILLÁN	1.147	1.284	1.428	1.580	1.736	1.897	2.059	2.221
	SAN CARLOS	440	492	548	606	666	727	790	851
	BULNES	229	256	285	315	346	378	411	443
O'Higgins	RANCAGUA	1.326	1.448	1.576	1.710	1.850	1.994	2.142	2.292
	RENGO	605	661	719	780	844	910	977	1.046
	SAN FERNANDO	600	656	714	775	838	903	970	1.038
Tarapacá	ALTO HOSPICIO	1.044	1.122	1.202	1.285	1.371	1.460	1.553	1.649
	IQUIQUE	964	1.035	1.109	1.185	1.265	1.348	1.433	1.521
	POZO ALMONTE	224	240	257	275	294	313	333	353
Valparaíso	VALPARAÍSO	2.466	2.650	2.840	3.036	3.239	3.447	3.660	3.877
	VIÑA DEL MAR	1.830	1.966	2.107	2.253	2.404	2.558	2.716	2.877
	VILLA ALEMANA	1.078	1.158	1.241	1.327	1.416	1.507	1.600	1.694

3.3 Imputación de proyección comunal anual a cada programa

La imputación de la proyección comunal a cada programa, es decir, a programa PAD, PAS, PEC, PPF, PEE, PIE, PIB, PRM, se realiza sobre la base de la participación histórica que cada uno de ellos tiene al interior de cada región. Esta *participación* se obtiene de la demanda observada por cada uno de ellos en el periodo 2018 – 2020, dentro de cada región, y la información está en hoja **Observaciones Regionales** del archivo Excel ya indicado, y los *detalles* para construir los factores correspondientes están en la hoja **Porcentajes Region por Programa** del mismo

archivo. El cuadro a continuación muestra las proporciones que se obtienen (ver respaldo en la hoja recién indicada).

Tabla 20: *participación de cada programa en demanda agregada, por región*

Región	PAD	PAS	PEC	PPF	PEE	PIE	PIB	PRM
Antofagasta	1,14%	1,22%	0,00%	48,61%	1,62%	14,93%	0,23%	32,24%
Araucanía	0,83%	1,85%	0,00%	50,82%	0,90%	17,60%	0,03%	27,97%
Arica y Parinacota	0,18%	1,87%	0,00%	37,02%	1,01%	18,35%	1,01%	40,57%
Atacama	0,00%	0,00%	0,00%	53,65%	0,32%	16,20%	0,00%	29,83%
Aysén	0,00%	0,00%	0,00%	51,62%	0,00%	15,77%	0,00%	32,61%
Biobío	0,00%	0,64%	0,00%	60,47%	0,35%	10,05%	0,01%	28,48%
Coquimbo	1,06%	1,40%	0,00%	53,59%	1,50%	13,89%	1,49%	27,06%
Los Lagos	0,00%	2,37%	1,43%	57,68%	1,11%	9,04%	2,26%	26,11%
Los Ríos	0,00%	0,00%	0,00%	53,01%	2,06%	5,29%	3,86%	35,78%
Magallanes	0,00%	0,00%	0,00%	57,63%	1,75%	11,66%	4,33%	24,62%
Maule	0,76%	1,28%	0,50%	47,85%	0,00%	13,11%	0,00%	36,51%
Metropolitana	0,27%	0,84%	0,94%	41,26%	0,60%	16,55%	0,00%	39,55%
Ñuble	0,00%	1,73%	0,00%	58,98%	0,00%	6,57%	0,00%	32,72%
O'Higgins	0,00%	0,85%	0,00%	47,66%	0,00%	9,37%	2,55%	39,56%
Tarapacá	0,00%	0,00%	0,00%	49,20%	2,30%	14,99%	0,00%	33,51%
Valparaíso	0,64%	0,57%	0,00%	53,02%	0,78%	13,80%	0,00%	31,19%

A partir de lo anterior, manteniendo constante la proporción según el cuadro anterior y aplicando el respectivo porcentaje a las proyecciones comunales totales que se indicaron, se obtiene un estimado de la proyección comunal para cada programa. Esto se presenta en la hoja **Comunal Por Programas Anual** del archivo *Proyecciones hasta 2033_Mejor Ninez (30Nov2023).xlsx*, la que está automatizada para obtener proyecciones para cualquier combinación de programas, para cada uno de los escenarios de análisis.

3.4 Imputaciones regionales mensuales

Las proyecciones regionales totales que se informaron previamente se basan en proyecciones regionales mensuales, que se obtienen con el modelo econométrico que se explicó. Los resultados de las primeras (*regionales mensuales totales*) están en la hoja **Regional Total Mensual** del archivo Excel en comento. A partir de estas, usando los coeficientes por programa según lo anterior, se obtienen imputaciones regionales mensuales según programa. Los resultados correspondientes están en la hoja **Regional Programa Mensual** del archivo *Proyecciones hasta 2033_Mejor Ninez (30Nov2023).xlsx*. En dicha hoja es factible escoger el programa para obtener la correspondiente proyección.