

Dirección de Desarrollo Digital

Unidad De Científicos De Datos



**DEPARTAMENTO
NACIONAL DE PLANEACIÓN**



**Pronóstico de la demanda y el costo para el
componente de salud de las atenciones
relacionadas con el cuidado**

INFORME FINAL

Dependencias y entidades involucradas	Departamento Nacional de Planeación • Unidad de Científicos de Datos
Sector	Salud y protección social
Fuentes de datos	RIPS

Contenido

1. Presentación	2
2. Objetivos del proyecto	2
3. Metodología	2
4. Resultados	3
5. Conclusiones y recomendaciones	13
Contacto	14



1. Presentación

El proyecto busca generar un mejor entendimiento de la demanda de servicios de cuidado por parte de la población colombiana, pronosticando la demanda y el costo para el componente de salud de las atenciones relacionadas con el cuidado para la población cuyo diagnóstico requiere de cuidado permanente. A continuación, se presentan los objetivos específicos abordados en el proyecto.

The project seeks to generate a better understanding of the demand for care services by of the Colombian population, forecasting the demand and cost for the health component of care related to care for the population whose diagnosis requires permanent care.

2. Objetivos del proyecto

2.1. General

Actualizar dashboard generado por caoba a partir de las fuentes suministradas, pronosticar la demanda y el costo para el componente de salud de las atenciones relacionadas con el cuidado para la población cuyo diagnóstico requiere de cuidado 2023.

2.2. Específicos

1. Actualizar el tablero de diagnóstico y análisis descriptivo de la prestación de servicios, la demanda y el costo de las labores de cuidado en el componente de salud con datos hasta 2019, el tablero deberá contener la descripción y comparación de los costos y la demanda de los servicios de cuidado diferenciados por régimen (subsidiado y contributivo), la descripción de los costos y la demanda de las atenciones relacionadas con el cuidado por regiones a nivel de municipio.
2. Realización, evaluación, selección del mejor modelo y generación del pronóstico de la demanda y el costo del cuidado de las poblaciones caracterizadas con predicción a Diciembre de 2023, con periodicidad mensual. .

3. Metodología

1. *Generación de los códigos de preprocesamiento y actualización de tablero de visualización con el diagnóstico y análisis descriptivo de la prestación de servicios, la demanda y el costo de las labores de cuidado en el componente de salud con datos hasta 2019, el tablero deberá contener la descripción y comparación de los costos y la demanda de los servicios de cuidado diferenciados por régimen (subsidiado y contributivo), la descripción de los costos y la demanda de las atenciones relacionadas con el cuidado por regiones a nivel de municipio. Para la generación de este tablero podrá usarse el tablero realizado previamente en el marco del proyecto de CAOBA y realizar la actualización hasta el año 2019.*
2. *Revisión y posibles mejoras de la metodología estadística propuesta en los modelos generados en el marco del proyecto de CAOBA para pronosticar la demanda y el costo demanda de las atenciones relacionadas con el cuidado en el componente de salud.*
3. *Generación, exploración y propuesta de modelos, que se ajusten a las características encontradas en los datos suministrados, evaluación y comparación a través de métricas de precisión, selección del mejor modelo y cálculo del pronóstico de la demanda y costo de los servicios de cuidado para el año 2023 (con periodicidad mensual)*
4. *Realización de un análisis descriptivo del comportamiento entre los componentes y variables del pronóstico de la demanda y costo para el componente de salud en Colombia hasta el 2019, a través de análisis*



estadísticos (por ejemplo: componentes estacionales, gráficos de auto correlación y auto correlación parcial entre otros.).

5. Generación de mejoras al tablero, según ajustes acordados con la Subdirección de Salud.
6. Incorporación de la predicción de la demanda y costo para el componente de salud en Colombia para 2023 en el tablero de visualización.

4. Resultados

- 1- Se genera actualización del tablero de control a 2019: análisis de RIPS, teniendo en cuenta: el régimen, tipo de enfermedad, Vulnerabilidad por Covid y sexo.




Imagen 1: Análisis RIPS

- 2- Actualización análisis de costos 2019. Para un mejor entendimiento, se contemplan las variables: Régimen, Tipo de enfermedad, Vulnerabilidad por COVID, además de esto se actualizó el menú de filtros a 2019.




Imagen 2; Análisis costos RIPS.

- 3- Análisis de edad por año y mes a 2019: El objetivo de esta actualización es describir la pirámide poblacional por grupo etareo y sexo de la población que necesita cuidado permanente. La estructura poblacional se puede filtrar por año y por entidad territorial

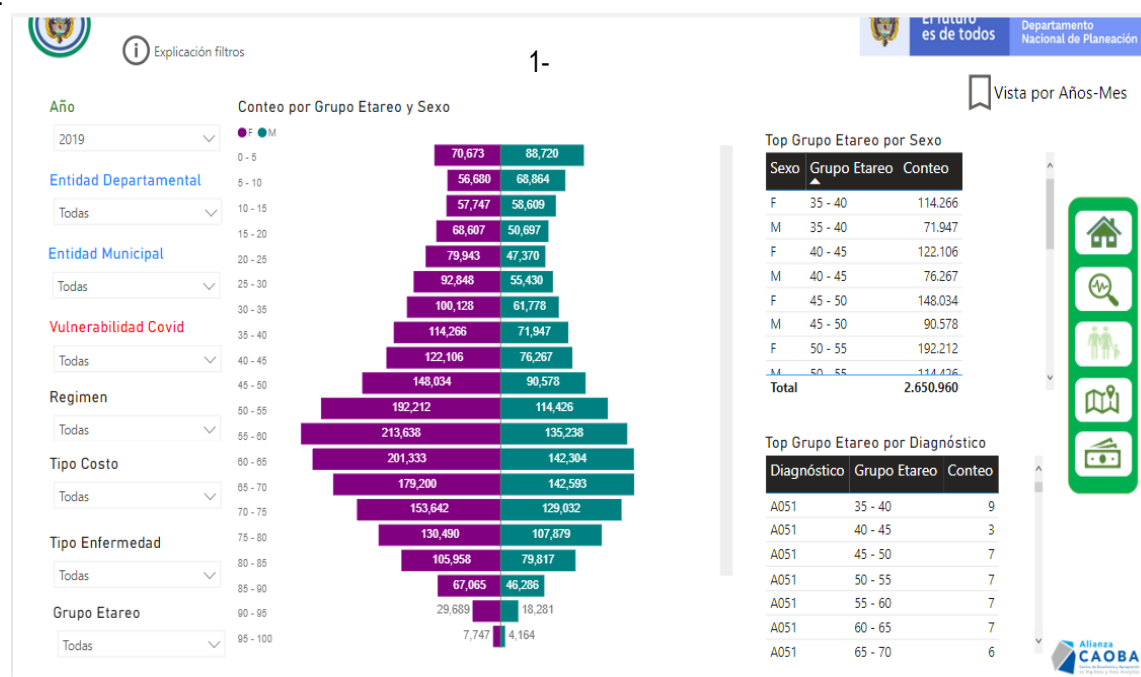


Imagen 3: Análisis Edad por año.

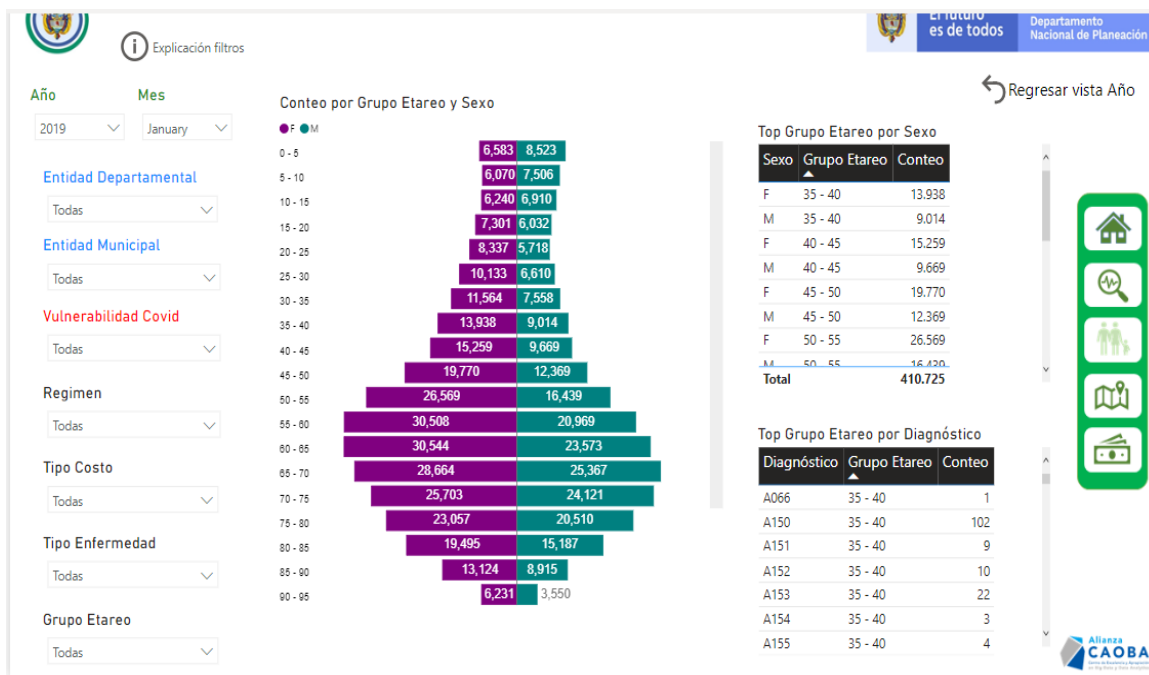


Imagen 4: Análisis edad Año - Mes

- 4- Análisis Geográfico por año a 2019: El objetivo de esta vista es realizar un análisis comparativo sobre la prevalencia de diagnósticos que requieren cuidado permanente en una entidad territorial.

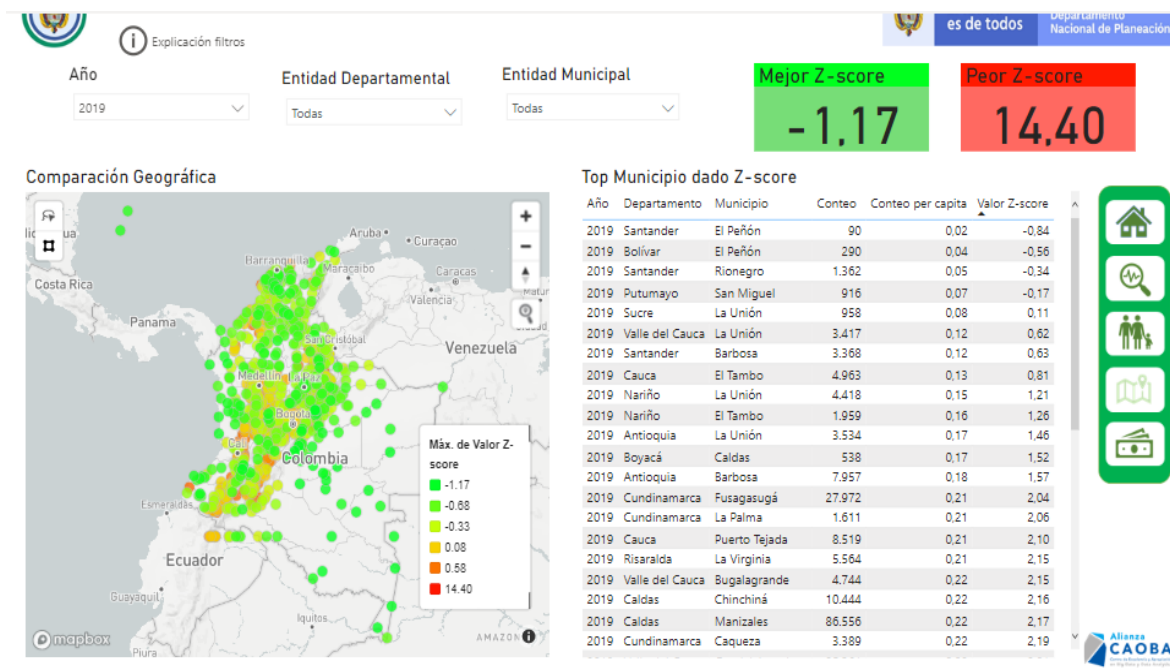


Imagen 5: Análisis geográfico por año.



Análisis de la demanda de servicios que requieren cuidador




Figura 1: Serie de tiempo de personas únicas por mes con patologías que requieren servicios de cuidado que han tomado servicios de salud durante el periodo 2011-2019

Modelos propuestos para análisis de predicción a 2023.

ARIMA

-Un modelo autorregresivo integrado de promedio móvil o ARIMA es un modelo estadístico que utiliza variaciones y regresiones de datos estadísticos con el fin de encontrar patrones para una predicción hacia el futuro. Se trata de un modelo dinámico de series temporales, es decir, las estimaciones futuras vienen explicadas por los datos del pasado y no por variables independientes.

ETS:

Especialmente útil para conjuntos de datos con estacionalidad y otras suposiciones previas sobre los datos. ETS calcula un promedio ponderado sobre todas las observaciones en el conjunto de datos de las series temporales de entrada como su predicción. Las ponderaciones disminuyen exponencialmente con el tiempo, en lugar de las ponderaciones constantes en los métodos de promedio móvil simple. Las ponderaciones dependen de un parámetro constante, conocido como parámetro de suavizamiento.

SUAVIZADO EXPONENCIAL(HOLT-WINTERS)

-El método se basa en un algoritmo iterativo que a cada tiempo realiza un pronóstico sobre el comportamiento de la serie en base a promedios debidamente ponderados de los datos obtenidos anteriormente.

-A este particular hay que reseñar los 2 diferentes tipos de estacionalidad que se pueden dar en las graficas, que son estacionalidad aditiva o estacionalidad multiplicativa.

-Escogeremos el modelo multiplicativo cuando la magnitud del patrón estacional en los datos depende de la magnitud de los datos. En otras palabras, la magnitud del patrón estacional aumenta a medida que los valores de los datos se incrementan y disminuye a medida que los valores de los datos decrecen.



REDES NEURONALES DE RETROALIMENTACION (nntear)

- Son redes con una sola capa oculta y entradas retrasadas para pronosticar series de tiempo univariadas.
- Vamos a elaborar entonces el modelo de red neuronal con nuestros datos:




Figura 2: Descomposición serie de tiempo 2011-2019

Teniendo en cuenta la gráfica anterior, se puede notar que la serie presenta tendencia de tipo funcional como se había analizado en primera instancia y además, se puede notar que la tendencia es de tipo funcional. Por otro lado, se puede notar un claro componente de tipo estacional que puede obedecer al comportamiento de la tendencia de manera anual. Estos resultados se analizarán con mayor detalle más adelante.

Como la serie presenta tendencia es importante diferenciar la serie para poder ajustar algunos de los modelos ARIMA. Esto se hace para hacer que la serie sea estacionaria en el sentido débil y usar correctamente el modelo ARIMA.




Figura 3: serie diferenciada 1 vez 2011-2019

Según el resultado de la serie de tiempo en la figura 3, se puede apreciar que la serie tiene tendencia posiblemente de tipo funcional. Es decir, que la tendencia se trata de alguna función de variable real. Por otro lado, se puede notar que la serie no es estacionaria en el sentido débil.

Hallazgos encontrados en Modelo ARIMA

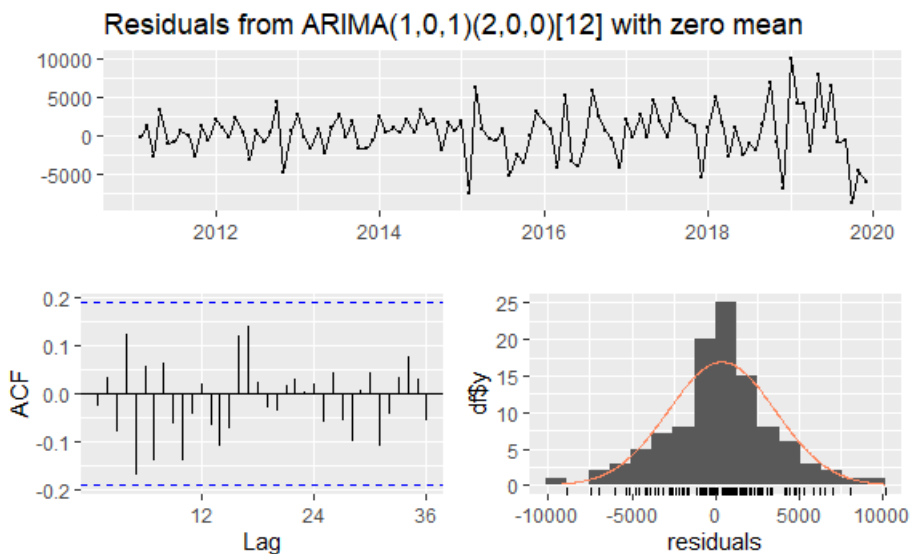


Figura 4: Comportamiento residuales ARIMA



- Vemos en los residuos que los valores perdidos en general están dentro del límite de significancia (gráfica ACF).
- También vemos que la distribución de los residuos (residuals), tiende a centrarse en 0 y van teniendo una distribución normal.

Realizaremos la estimación de este modelo, haciendo un forecast en el que vamos la demanda de cuidador para los próximos 48 meses con un nivel de significancia de un 95%.




Figura 5: comportamiento predicción modelo ARIMA



Hallazgos encontrados en Modelo SUAVIZADO EXPONENCIAL(ETS)




Figura 6: comportamiento residuales ETS

Visiblemente la representación de los residuos del mismo y vemos que se encuentran prácticamente todos dentro de los límites de significancia del 2%, a excepción de uno de los niveles (grafica ACF), y en general tienden a centrarse en 0, y van teniendo una distribución normal (Figura 6).




Figura 7: comportamiento predicción ETS



Visualizamos en la Figura 7 que la serie del modelo en negra se ajusta bastante bien a la predicción línea roja, y su correspondiente residual que se encuentra entre ambas líneas.

También observamos el pronóstico, con sus márgenes inferior y superior del 95% de valores de grado de certeza (área de color lila)

Hallazgos encontrados en Modelo SUAVIZADO EXPONENCIAL(HOLT-WINTERS)




Figura 8: valores ajustados.

Como la serie de partida es no estacional como pudimos ver anteriormente en el modelo ARIMA, vamos aplicar a holtwinters, seasonal = "multiplicative"

De manera que haremos una grafica donde se vea la serie del modelo (línea negra) y el ajuste con la predicción(línea roja), así mismo aparecerá la descomposición de la grafica para evaluar los datos.




Figura 8: pronóstico modelo HW

- Se observa que la curva se ajusta bastante bien al modelo, y se muestra la predicción a 48 meses con los márgenes del intervalo.

Hallazgos encontrados en Modelo REDES NEURONALES DE RETROALIMENTACION (nntear)

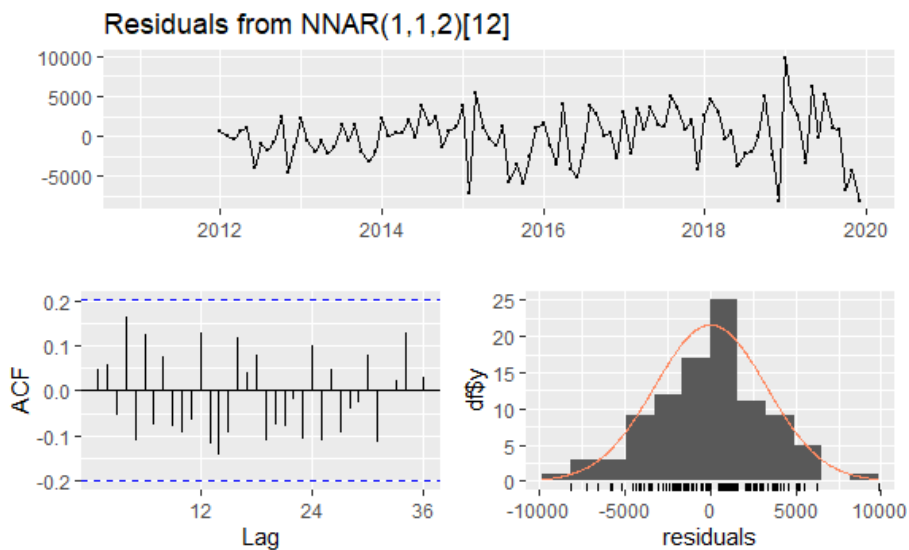


Figura 8: Comportamiento residuales modelo nntear.



-En este caso no hay niveles de residuos que sobrepasan las bandas de confianza al 2% de significancia (Grafica ACF). y en general tienden a centrarse en 0, y van teniendo una distribución normal

Una vez hecho esto realizamos la predicción a 48 meses de los datos, con una significancia del 95% de los mismos.




Figura 8: Ajuste y pronostico modelo nntear.

Se puede observar una buena bondad de ajuste entre los datos reales y lo pronosticado.

Resultados RMSE modelos

MODELO	ME	RMSE	MAE	MPE	MAPE	MASE
ARIMA	358,8658	3192,546	2384,263	62,33846	114,7394	0,8358705
ETS	210,73	3656,696	2651,093	-1,369938	14,88027	0,5530419
HW	2,234328	3395,845	2599,327	-1,751112	13,62384	0,5422431
NNTEAR	-0,2685122	3248,631	2531,683	-3,03038	14,01026	0,5281319

Fuente: Elaboración propia

5. Conclusiones y recomendaciones



- En comparación con el análisis descriptivo del tablero realizado por CAOBA para 2018, se observa que las diferentes series presentadas tienen a disminuir.
- Según resultados obtenidos, de los modelos sometidos a estudio el mejor modelo es ARIMA, debido a que posee el menor RMSE 3192,546

Contacto

Si tiene alguna duda, comentario o sugerencia sobre este proyecto, o si le gustaría conversar con la Unidad de Científicos de Datos sobre la posibilidad de una nueva fase para el mismo, puede comunicarse con nosotros a través del correo electrónico ucd@dnpp.gov.co.