

TESIS



Aplicación de Analytics en la Gestión Pública

Caso de Estudio: Fondo Nacional de Recursos

Guillermo Kaplan

Tutor: Ramiro Gálvez

MiM + Analytics

Universidad Torcuato Di Tella

Septiembre 2020

Aplicación de Analytics en la Gestión Pública

Caso de Estudio: Fondo Nacional de Recursos

RESUMEN

El presente trabajo tiene como objetivo analizar los desafíos y oportunidades de la aplicación de analytics en la esfera pública, lo cual se ejemplifica a través de un caso de estudio. Concretamente, se estudiará cómo distintas técnicas de predicción podrían ayudar en la operatoria del Fondo Nacional de Recursos (FNR), institución uruguaya de carácter público dedicada a brindar coberturas financieras vinculadas a la salud.

Los datos utilizados a lo largo de este trabajo son información pública de carácter administrativo que detalla las solicitudes de coberturas financieras recibidas por el FNR en el período 2016/17. A partir de estos datos, utilizados actualmente por la institución meramente como registros, se evaluó la viabilidad de entrenar modelos predictivos que puedan asistir a la toma de decisiones. Concretamente, se evaluaron los siguientes dos modelos:

El **Modelo I** consiste en la predicción de la autorización o no autorización de una prestación, tomando como input variables tales como el tipo de prestación solicitada, la edad o el sexo de la persona, entre otras.

El **Modelo II** busca predecir si la demora en las autorizaciones será mayor o menor a cierta cantidad de días, entendiendo a esta demora como la cantidad de días que transcurren entre las fechas de solicitud y de autorización.

La realización de los **Modelos I y II** sirvió no solo para intentar predecir la autorización (o el rechazo) de una solicitud o la demora de la misma a partir del aprendizaje de información de índole administrativa, sino también para mostrar que es factible la realización de este tipo de modelos y la automatización de ciertos procesos críticos en la órbita pública. Los resultados obtenidos a partir de estos modelos dan lugar al análisis respecto a las consecuencias que la aplicación de analytics podría tener en una organización como la mencionada en lo que respecta a la toma de decisiones, la estructura organizacional, la justicia o la transparencia, entre otros aspectos relevantes. Asimismo, se busca generalizar ciertos conceptos observados en el caso de estudio para otras ramas del ámbito público.

Application of Analytics in Public Management

Case Study: Fondo Nacional de Recursos

ABSTRACT

The objective of the work at present is to analyze the challenges and opportunities of applied analytics that the public sector may face, exemplified through a case study of Fondo Nacional de Recursos (FNR). In particular, different prediction techniques that may be helpful in FNR's performance will be studied. FNR is a public institution from Uruguay, whose purpose is to grant financial support for some specific medicines and medical treatments.

The dataset used alongside this work is open data that provides details of the requests for treatment that FNR received during the period 2016/17. Based on that information, used nowadays by the organization just as administrative records, I evaluated the viability of training predictive models capable of supporting the decision-making process. Specifically these two models were evaluated:

Model I consists on predicting whether a request would be accepted or rejected, considering variables such as the type of treatment requested, the age or the gender of the applicant, among others.

Model II tries to predict if a delay in authorization would be higher or lower than a specific number of days, defining that delay as the days that pass between an application and its acceptance.

Beyond demonstrating the feasibility of using this data as an input for complex decision-making, the results obtained from these models gives rise to analysis regarding the consequences that the application of analytics could have on an organization such as the one mentioned in regards to decision-making, organizational structure or transparency, among other relevant aspects.

Índice

1. INTRODUCCIÓN	5
2. FONDO NACIONAL DE RECURSOS	8
2.1. Presentación	8
2.2. Estructura Organizacional	10
3. CONJUNTOS DE DATOS E INGENIERÍA DE ATRIBUTOS	11
4. ANÁLISIS EXPLORATORIO DE DATOS	13
5. MODELOS PREDICTIVOS	24
5.1. Modelo I - Objetivo y Selección de Variables	24
5.2. Modelo II - Objetivo y Selección de Variables	25
5.3. Metodologías utilizadas	28
5.4. Resultados e Interpretaciones	30
6. CONCLUSIONES	36
6.1. ¿Qué impacto tendrían el uso de estos modelos en el funcionamiento del FNR?	36
6.2. Posibles Mejoras y Ampliaciones	38
6.3. Palabras finales	42
7. BIBLIOGRAFÍA	44
Referencias	44
Marco Jurídico (Fondo Nacional de Recursos)	48
Otras fuentes de información	49
8. ANEXOS	50
Anexo I	50
Técnicas (Actos Médicos)	50
Tratamientos con Medicamentos	51
Dispositivos	52
Anexo II	53
Actos Médicos	53
Tratamiento con Medicamentos	54
Anexo III	55
Anexo IV	56
Anexo V	61

1. INTRODUCCIÓN

En los últimos años, la cantidad y la importancia de los datos ha crecido de forma exponencial. Diversas fuentes hacen menciones tales como que en los últimos dos años se han generado el 90% de los datos existentes^[1], o que la cantidad de datos prevista a generarse en 2019 superaría la generada durante los anteriores 5.000 años^[2]. A partir de esta revolución que la cantidad de datos está generando, van ganando terreno diversas técnicas y disciplinas para su aprovechamiento, siendo una de ellas el *Business Analytics*; a grandes rasgos “*analytics*” podría definirse como una forma de trabajo basada en la explotación de datos para la toma de decisiones. Muchas empresas y organizaciones están usando estas herramientas para mejorar su performance. Por mencionar algunos ejemplos^[3], organizaciones como Amazon, Google y Facebook tienen a la explotación de datos como un elemento clave en sus respectivas estrategias y modelos de negocios.

Los gobiernos e instituciones públicas son grandes generadores de datos, muy variados entre ellos y procedentes de diversas fuentes. Aun cuando existe un gran potencial para transformar estos datos públicos en información útil para la toma de decisiones en la esfera pública, poder llevar adelante esta tarea presenta grandes desafíos^[4]. Algunos obstáculos que podrían dificultar la adopción de la toma de decisiones basadas en datos^[5] en entes públicos son: la burocracia de los procesos, los “silos” de información, la privacidad y la variedad de los datos. Los “silos” refieren a que cada institución dependiente del estado suele tener su propio almacenamiento, organizado de una forma tal que no es sencillo de comprender por alguien ajeno a ese ente; otro problema frecuente, y asociado a los silos, es que cada institución considere a la información que genera como propia y tenga cierto recelo a la hora de compartirla. También puede ocurrir que cada institución ni siquiera tenga del todo claro cómo se deben compartir sus datos. En cuanto a la privacidad, los gobiernos deben garantizar la seguridad y el cumplimiento de las leyes al usar los datos. Entre el cumplimiento de la privacidad y confidencialidad de los ciudadanos y la realización de predicciones y soluciones personalizadas hay, para los gobiernos, una estrecha línea que no pueden ni deben traspasar. A modo de ejemplo, el Coronavirus Covid-19 ha despertado opiniones dispares en cuanto al mencionado trade-off entre la conveniencia y la privacidad de los datos^[4] (p.ej en aspectos tales como la geolocalización de las personas infectadas), habiendo importantes discusiones respecto de hasta dónde y hasta cuándo es ético y oportuno compartir información^[6-7].

Más allá de las dificultades antedichas, el uso de datos por parte de los gobiernos podría mejorar aspectos tales como la comprensión de la opinión pública ante ciertos temas, la eficiencia operativa, la seguridad^[8], el crecimiento económico, la transparencia, solo por citar algunos de ellos. Esto podría resultar en un mayor bienestar por parte de los ciudadanos. Por citar un caso^[9], hasta hace poco tiempo en India había un problema recurrente que era la dificultad de acceso de muchos pueblos y aldeas a energías limpias para cocinar. La contaminación generada en una hora por las técnicas que utilizaban los habitantes de estos asentamientos para cocinar equivalía a fumar 400 cigarrillos, lo cual causaba cientos de miles de muertes al año. Para solucionar esta problemática se resolvió la apertura de 10 mil nuevos centros de Gas Licuado de Petróleo (LPG). Para esto, el Gobierno de India, las

compañías petroleras y “Socialcops”¹ utilizaron datos geográficos de estaciones LPG ya existentes y de cada pueblo del país, de modo de definir la ubicación óptima de los nuevos centros tal que ningún ciudadano del país deba trasladarse más de 10 kilómetros para obtener energías limpias para poder cocinar. Otro ejemplo más operativo podría ser el uso de analytics predictivo por parte de los recaudadores de impuestos. Cada vez con mayor frecuencia las agencias impositivas utilizan las grandes cantidades de datos que manejan en pos de detectar evasiones o fraudes fiscales^[10-11].

Hoy en día, una práctica que es bastante aceptada y fomentada a nivel de los gobiernos (mayormente de países desarrollados) es la apertura de datos. *Open Data* es definida como aquellos datos que están disponibles online para su uso y acceso sin restricciones ni límites de ningún tipo.^[12] Es visto como una forma de aumentar la eficiencia, la participación ciudadana, la transparencia y la innovación para la sociedad. A nivel de datos del gobierno, el objetivo puede ser la búsqueda de sinergias y el hecho de empoderar a sus ciudadanos que, por un lado podrían aportar posibles ideas o soluciones, y por el otro tendrían un espacio en el cual sentir que su opinión es valorada. Este fomento a la participación ciudadana y a la transparencia, sumado a las tecnologías y a la alta penetración de internet, son generadores de nuevos conceptos de Democracia y representatividad, como los que manejan (entre otros) el Partido Digital^[13-14] en Uruguay o el Partido de la Red^[15] en la ciudad de Buenos Aires. Siguiendo esta práctica, Uruguay actualmente preside el D9^[16] (antes D5 y D7), una red intergubernamental de países que son considerados avanzados en términos de avances digitales (a nivel de gobiernos). A raíz de esto, Uruguay comenzó a promover el Open Government Data a través de un Catálogo de Datos en el cual *“Cualquier persona puede utilizar los datos publicados libremente para contar historias, desarrollar investigaciones, visualizaciones, aplicaciones cívicas y emprendimientos.”*². Este catálogo da acceso a datos abiertos principalmente de organismos públicos, aunque también hay algunos Datasets de Sociedades civiles, la academia y empresas privadas.

Otro sector que se caracteriza por generar cuantiosos datos heterogéneos es el vinculado a la salud y sus cuidados. A modo de ejemplo, puede pensarse en reportes oficiales, notas a mano de doctores y enfermeros, autorizaciones de alta médica, papeles administrativos, imágenes, entre otros. Nótese que estos datos tienen potencial de ser transformados en información que al ser estudiada de manera agregada pueda brindar información útil para la toma de decisiones (ya sea en la atención de un paciente en particular o en decisiones que atañen al sistema de salud en su conjunto). El potencial del uso de analytics en esta industria es altamente significativo. Algunos beneficios podrían ser la detección temprana de síntomas y enfermedades (que posibilite tratamientos más fáciles y efectivos),^[17-18] la predicción de la duración de (p.ej.) una operación o los días de internación, la mejor comprensión de patrones o la posibilidad de hacer tratamientos más personalizados. Para ejemplificar también haré mención al Coronavirus Covid-19, que mantiene en vilo al mundo al momento de escribir estas líneas. Numerosos científicos de datos han hecho análisis y estudios en base a los datos que esta pandemia está dejando (p.ej. prediciendo el número de infectados por país o explicando el efecto de la cuarentena en el número de fallecidos por esta causa).^[19-20] Un claro ejemplo del uso de datos con fines de mantener una mejor

¹ <https://socialcops.com/>

² <https://catalogodatos.gub.uy/>

situación sanitaria durante dicha pandemia fue el que aplicó Corea del Sur (luego replicado por otras naciones), donde a través de diferentes Apps^[21-22] se informa la localización de aquellas personas infectadas por el virus; obviamente la utilidad de esta información es mucha, pero a costas de una discutible pérdida de la privacidad por parte de los ciudadanos.

A lo largo de esta sección he mencionado la inmensa cantidad de datos que generan los gobiernos y la salud, ambos teniendo muchos desafíos y dificultades para su utilización, pero con un potencial capaz de lograr mejoras considerables para las personas.

Una institución uruguaya de carácter público vinculada a la salud es el Fondo Nacional de Recursos (FNR). A lo largo de este trabajo tomaré a esta organización como caso de estudio, utilizando información que la misma publica³ con el fin de analizar el impacto que el uso de analytics podría tener en su funcionamiento. Concretamente, a partir de datos de índole administrativa, se entrenarán dos modelos predictivos cuyos objetivos son automatizar la autorización de solicitudes de la entidad (**Modelo I**) y detectar excesos de demoras en las autorizaciones (**Modelo II**). A partir de este ejemplo concreto, en que se desarrollan modelos predictivos a partir de información que actualmente no es utilizada con tales fines, analizaré el impacto que la aplicación de este tipo de técnicas podría tener en la gestión del FNR en particular y en el sector público en general.

Lo que resta de este documento se encuentra estructurado de la siguiente manera. En la Sección 2 se proveerá información que permitirá el entendimiento del FNR, su funcionamiento y estructura organizacional, entre otros aspectos relevantes. En la Sección 3 se presentarán los conjuntos de datos utilizados en el trabajo, así como ciertas variables que se han añadido a la información original para el análisis posterior. En la Sección 4 reflejaré algunos de los principales patrones a partir de los datos del FNR. En la Sección 5 presentaré los objetivos, metodología utilizada, resultados e interpretaciones de dos modelos predictivos que he desarrollado a partir de la información presentada en la Sección 3. Finalmente, en la Sección 6 a modo de cierre presento algunas implicancias a nivel de gestión y funcionamiento que modelos como los propuestos en la Sección 5 podrían tener en el FNR, así como la posibilidad de mejoras y ampliaciones.

Al término de este documento se encuentran la bibliografía y los anexos, en donde detallo las fuentes utilizadas a lo largo del trabajo y presento cierta información de forma más pormenorizada.

³ Extraída de: <https://catalogodatos.gub.uy/organization/fondo-nacional-de-recursos>

2. FONDO NACIONAL DE RECURSOS

2.1. Presentación

El Fondo Nacional de Recursos es una institución pública no estatal, cuyo propósito es la financiación de actos médicos (operaciones), medicamentos y dispositivos cuya complejidad y/o costo sean elevados. Pueden solicitar prestaciones todos los residentes de Uruguay, usuarios del Sistema Nacional Integrado de Salud (es decir, que cuenten con una cobertura formal de salud). Es administrado por una comisión honoraria conformada por nueve miembros, representantes del Banco de Previsión Social (BPS), los Institutos de Medicina Altamente Especializada (IMAE), el Ministerio de Economía y Finanzas (MEF) y el Ministerio de Salud Pública (MSP).

El FNR se creó en el año 1981 con la finalidad de cubrir algunas intervenciones médicas especializadas. En el año 2005 se agregó al alcance de este organismo la cobertura de medicamentos que, dado su elevado costo, no son alcanzados por las canastas básicas de los prestadores de salud. Desde entonces esta institución ha tenido un rol social muy importante, permitiendo a los estratos inferiores de la sociedad a acceder a dispositivos, medicamentos y actos médicos que posiblemente de otra forma no podrían. De acuerdo al Diario El Observador^[23] a diciembre de 2018 el presupuesto anual rondaba los U\$D 250 millones anuales. Sus principales fuentes de financiación provienen del Fondo Nacional de Salud (FONASA), las mutualistas y los seguros privados, que aportan un monto fijo mensual (U\$D 5.84 aprox.) por cada trabajador en el país.

Los actos médicos que cubrió el FNR en el período que analizaremos corresponden a las siguientes categorías: Cardiología, Nefrología, Traumatología, Trasplantes y “Otras áreas”. Los mismos son realizados en los Institutos de Medicina Altamente Especializados (IMAE) y en Centros especializados; en contadas ocasiones se ha derivado pacientes a realizarse actos médicos al exterior. El rol del FNR es el de “reasegurar a los prestadores integrales”⁴. Los medicamentos cubiertos en el mismo período se dividen en estas áreas: Cardiología, Endocrinología, Gastroenterología, Infectología, Inmunología, Neumología, Neurología, Oncología y Reumatología. Con la finalidad de alcanzar economías de escala, la compra de ellos suele darse en conjunto con otros 31 países de la región a través del “Fondo Estratégico de la Organización Panamericana de la Salud” o a través de acuerdos de riesgos compartidos con los laboratorios (se paga una cuota fija mensual al laboratorio independientemente de la demanda que se tenga).^[23] La distribución de los medicamentos normalmente se da a través de la farmacia que designe el prestador de salud de cada paciente. A noviembre 2019^[24] eran 27 procedimientos, 56 medicamentos y 2 dispositivos, los aprobados por el FNR para su cobertura⁵. Adicionalmente, hoy día cuenta con programas de prevención asociados al tabaquismo, la obesidad, la salud renal y la salud cardiovascular, dirigido a aquellas personas que reciben o han recibido coberturas de algún tipo. Desde su creación la cantidad de coberturas financieras autorizadas ha ido en

⁴ “¿Qué es el Fondo Nacional de Recursos?”. Extraído de: http://www.fnr.gub.uy/que_es_fnr

⁵ Detalladas en “Anexo I”.

aumento, llegando a ser alrededor de 30 mil en 2018^[25] (respecto a poco menos de 22 mil en 2016 y a casi 23 mil en 2017).

De acuerdo a la Cra. María Ana Porcelli⁶ Directora del Fondo Nacional de Recursos desde el 26 de marzo de 2020^[26-27], los procesos entre la solicitud de cierta cobertura y la resolución respecto a si autorizarla o no, difieren en el caso de actos médicos y de tratamientos con medicamentos. Los actos médicos, una vez solicitados por parte del médico tratante del paciente, pasan a una fase de evaluación presencial por parte de médicos evaluadores que son contratados por el FNR para la ocasión. El rol de estos es realizar una visita al paciente para informarse respecto a la existencia de comorbilidades⁷, definir la oportunidad de la operación y las posibilidades de rehabilitación que el paciente tendría. La información recabada por el médico que visita a los pacientes, al igual que la que envía el médico solicitante de la prestación⁸, es luego enviada a los médicos del FNR, quienes proceden a analizar la misma y solicitar información o estudios adicionales, de ser necesarios. En base a los datos recibidos y a las normativas de cobertura que cada prestación cubre, consideran si corresponde autorizar o no la solicitud en cuestión. En situaciones cuyas decisiones son más complejas existen los ateneos^[28] donde expertos en cada tema aportan su asesoramiento pertinente. Estos transcurren una o dos veces a la semana, según la cantidad de casos a discutir. Los participantes de los ateneos, normalmente médicos de reconocida trayectoria académica y profesional, deben firmar una declaración de conflicto de intereses. Los tratamientos con medicamentos no requieren evaluación presencial (salvo para el tratamiento del asma) sino que un equipo médico compuesto por (al menos) un médico del FNR y un especialista referente en el área correspondiente se reúne ante cada solicitud para analizar la pertinencia de la cobertura. Una vez definida la autorización de un tratamiento con medicamentos, se define la periodicidad (mensual, trimestral, semestral o anual) de las dosis periódicas posteriores, para la continuación del tratamiento. Otro elemento que se define es la duración de la cobertura; por ejemplo, en los casos oncológicos usualmente se define que la cobertura será “hasta la progresión del paciente”, pasando luego a suspenderse la misma.

Un elemento muy importante en lo que respecta al proceso de solicitudes y autorizaciones del FNR son las “normativas de coberturas financieras”⁹. Estas no son guías de práctica clínica, sino que son una generalización de conceptos y protocolos por tipo de prestación, que explica en detalle en qué consiste cada acto médico o medicamento, y quienes están incluidos o excluidos de acceder al mismo. Estas “guías” o “protocolos” de Coberturas son hechas por profesionales especializados de acuerdo a una serie de criterios que dispone la Comisión Técnico Asesora, la cual se basa en evidencia científica. Periódicamente se revisan las normativas de coberturas, con el fin que estén actualizadas tanto a nivel científico como al contexto del país y sus posibilidades económicas. Cada tipo de prestación presenta en “su” normativa características distintas, pero elementos tales como la edad, las condiciones generales de salud, la existencia de otras enfermedades, las posibilidades de

⁶ En entrevista realizada el 15 de abril de 2020.

⁷ “Coexistencia de dos o más enfermedades en un mismo individuo, generalmente relacionadas.”, según la Real Academia Española.

⁸ Cuando completa el “Formulario de Solicitud”, conforme a la normativa vigente de cada prestación.

⁹ Extraídas de: <http://www.fnr.gub.uy/formulario-normativa>

rehabilitación y la expectativa de vida remanente, suelen ser algunos factores repetidos en las normativas de coberturas como factores importantes a la hora de definir la inclusión o exclusión del paciente ante la solicitud de una prestación. Igualmente, en el diálogo mantenido con la Directora General del Fondo Nacional de Recursos, la entrevistada fue enfática en aclarar que estos son algunos lineamientos importantes pero que la decisión final depende del juicio de los Médicos participantes, los cuáles son todos profesionales de vasta experiencia y referentes en diferentes áreas de la medicina.

2.2. Estructura Organizacional

A nivel organizacional, el FNR presenta la estructura que se puede observar en la Figura 1.¹⁰ Más allá de ilustrar visualmente algunos aspectos presentes en el apartado previo, la estructura organizacional es un elemento importante al que me referiré en las conclusiones del documento.

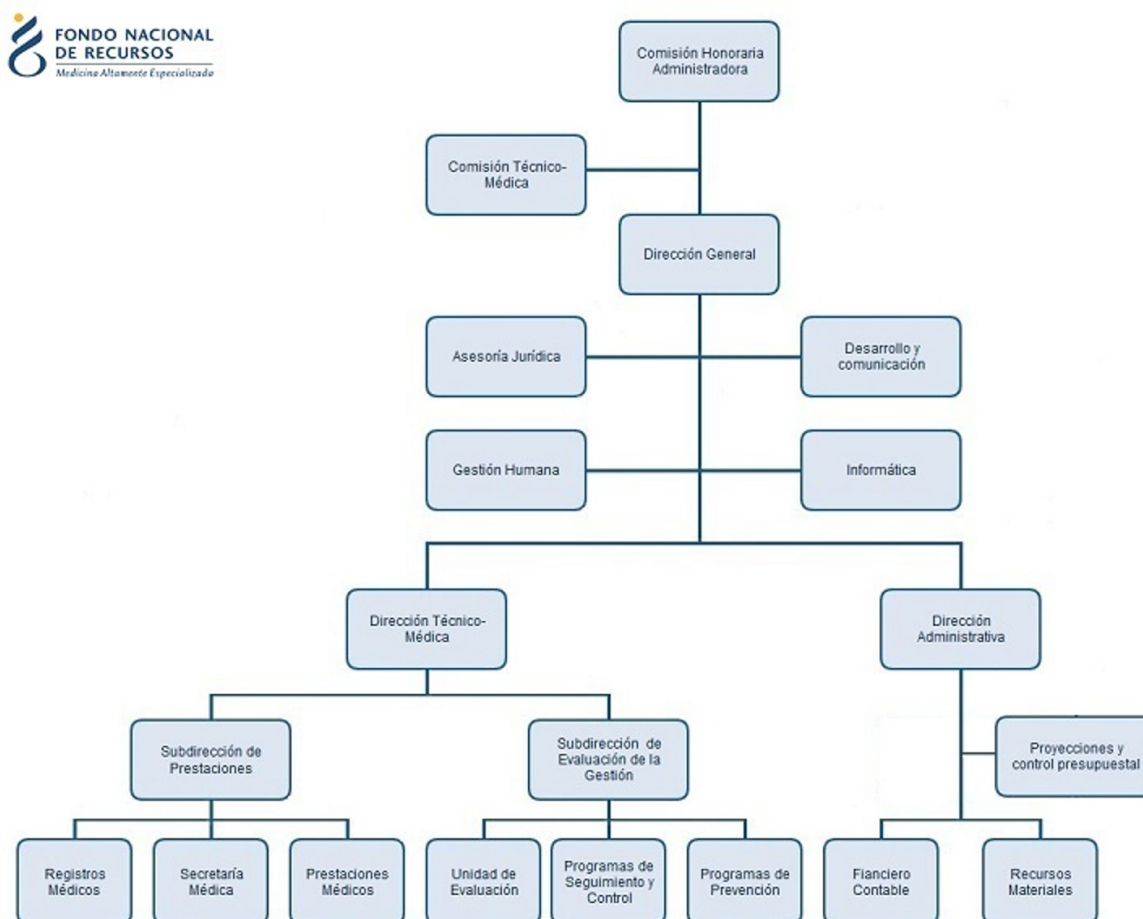


Figura 1. Organigrama del Fondo Nacional de Recursos

Tal como puede observarse, la estructura del FNR es de tipo funcional, en donde la departamentalización se da por área de conocimiento, en lugar de darse p.ej. por tipo de prestación o por región. De acuerdo a los “Arquetipos” de Mintzberg^[29] el FNR presenta características que lo caracterizarían como “Burocracia Profesional” pues se trata de una

¹⁰ Extraído de: http://www.fnr.gub.uy/organizacion_institucional

organización operando en un contexto complejo y estable, y el “core” de la organización se encuentra en los niveles operativos.

De acuerdo a información presentada por esta institución en septiembre de 2019¹¹ tienen un equipo de trabajo compuesto por 84 funcionarios remunerados (no se incluyen los miembros de la *Comisión Honoraria Administradora*) los cuales poseen posiciones y cargos dedicados a:

Dirección General	Jefe de Gestión Humana	Asistentes Sociales	Contadores	Técnico en Informática
Dirección Técnica	Asesor Letrado	Lic. en Enfermería	Técnicos en Administración	Abogados
Dirección de Administración	Médicos	Lic. en Nutrición	Administrativos	Recepcionistas / Telefonistas
Sub Director Técnico Prestaciones	Químico Farmacéutico	Lic. en Psicología	Ingenieros de Sistemas	Auxiliares de Servicio
Sub Director Técnico Programas	Estadísticos	Lic. en Registros Médicos	Informático Analista	Cadete

Figura 2. Posiciones y cargos del Fondo Nacional de Recursos

3. CONJUNTOS DE DATOS E INGENIERÍA DE ATRIBUTOS

Los datos a ser utilizados para este proyecto han sido extraídos del Catálogo de Datos Abiertos, herramienta gestionada por el gobierno uruguayo a través de AGESIC (Agencia de Gobierno Electrónico y Sociedad de la Información y del Conocimiento).¹² La información publicada por parte del Fondo Nacional de Recursos en el Catálogo de Datos Abiertos es principalmente de carácter administrativa. Incluye un listado de las solicitudes de coberturas, el gasto por los actos médicos y por medicamentos (para los casos autorizados), un detalle de la estructura de la organización, de los gastos administrativos y del marco regulatorio del organismo. Para una mejor comprensión de cierta información, al final del trabajo incluiré un “*Glosario de Términos, Conceptos y Abreviaturas*” elaborado por el FNR.¹³

Entre la información provista se encuentra el dataset de las solicitudes de prestaciones (24.138 registros en 2016 y 24.989 registros en 2017), el cual tiene las siguientes variables:

Nombre Del Atributo	Descripción
anio	Año de solicitud
tipo_prestacion	Tipo de prestación
area	Área de la prestación
prestacion_cod	Código de la prestación

¹¹ Extraído de:

https://catalogodatos.gub.uy/dataset/fondo-nacional-de-recursos-remuneraciones_fondo-nacional-de-recursos/resource/eeb4b736-aced-44c9-98e7-abf673d4811f

¹² Datos extraídos desde: <https://catalogodatos.gub.uy/organization/fondo-nacional-de-recursos>

¹³ “Anexo IV”

prestacion_desc	Descripción de la prestación
fecha_solicitud	Fecha de solicitud
estado_solicitud	Estado de la solicitud
fecha_autorizacion	Fecha de autorización
paciente	Número de paciente
edad_anios	Edad en años
sexo	Sexo
departamento_residencia	Departamento de residencia del paciente
prestador_salud	Prestador de salud
prestador_tipo	Tipo de prestador
medico_solicitante	Médico solicitante

Figura 3: Variables del conjunto de datos

Partiendo de esos datos originales, resolví agregar la siguiente variable para trabajar en el **Modelo II** (que más adelante describiré):

Nombre Del Atributo	descripción
demora_aut	Días transcurridos entre la fecha de solicitud y la fecha de autorización

Figura 4: Variable añadida al dataset

Más allá del conjunto de datos que brinda información sobre las solicitudes presentadas en este período (cuyas variables fueron presentadas en la tabla contenida en la Figura 3), el Catálogo de Datos Abiertos del cual extraje la información también contiene datos respecto a los desembolsos (en \$ Uruguayos) hechos por parte del FNR, por concepto de coberturas de “*Actos Médicos*” y “*Tratamientos con Medicamentos*” autorizados. Considerando que el monto a desembolsar podía ser un insumo importante para poder predecir una aceptación o rechazo de la cobertura financiera, trabajé en base a ciertos supuestos y criterios¹⁴ en la unificación de estos conjuntos de datos. La variable “paciente”, presente tanto en los datos de las solicitudes como en el desglose de los gastos, permitió a través del número identificador de cada paciente la unificación de los distintos registros. Este dataset “unificado” concluyó en un conjunto de datos con 40.015 registros, en el cual sumada a las variables detalladas en las tablas contenidas en las Figuras 3 y 4, se agregó la siguiente:

Nombre Del Atributo	descripción
Importe	Importe de la prestación solicitada, en Pesos Uruguayos (\$U)

Figura 5: Variable añadida al dataset en un principio, luego eliminada

A raíz de la importante distorsión que la inclusión del importe causaba en la métrica para medir cuán bien clasificaba el modelo (al que me referiré en la Sección 5.4), resolví dar “marcha atrás” y volver a trabajar con los datos originales de las solicitudes (aunque manteniendo la variable que mide la demora en las autorizaciones).

¹⁴ Detallados en “*Anexo II*”.

4. ANÁLISIS EXPLORATORIO DE DATOS

A continuación procederé a mostrar algunos datos y gráficos que creo son de interés para una mejor comprensión del funcionamiento del FNR, durante el período 2016/17. Más allá de estos “highlights”, en el *Anexo V* expondré la información en forma más detallada. Concretamente, iré mencionando diferentes patrones que surgen de la exploración de los datos.

- En la Figura 6 se puede vislumbrar el ascenso de las solicitudes de actos médicos y tratamientos con medicamentos durante el período analizado y en los años posteriores.

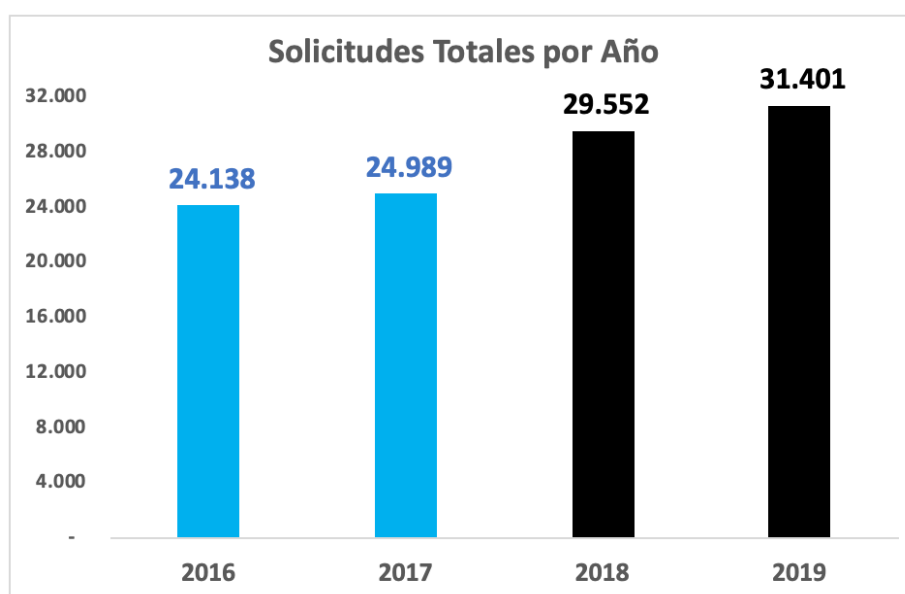


Figura 6. Cantidad de solicitudes por año.

Datos de 2018 y 2019 extraídos de: <http://www.fnr.gub.uy/estadisticas>

❑ Tal como se ve en la Figura 7, en 2016/17 los actos médicos han superado ampliamente a los tratamientos con medicamentos, tanto en solicitudes como a nivel de esfuerzo presupuestario (promedio y total).

❑ De las autorizaciones, un 13% corresponde a Medicamentos y un 87% a actos médicos, siendo el importe promedio de este último muy superior al del primero (\$210 vs \$77 mil).

Por tanto: *¿Cuál es la explicación lógica a que los medicamentos representen un (casi) 16% del gasto total?* El ya mencionado 13% representa las solicitudes autorizadas, no así las renovaciones de medicamentos que alguna vez fueron solicitados. Esos gastos cuya solicitud no fue realizada en 2016/17 son los que explican ese comportamiento.

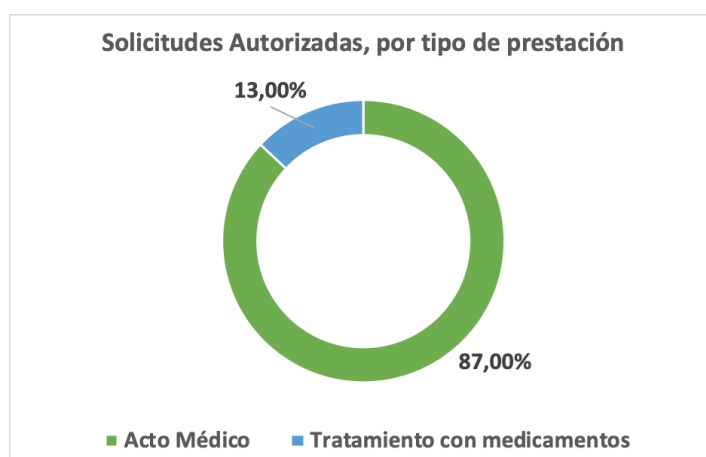
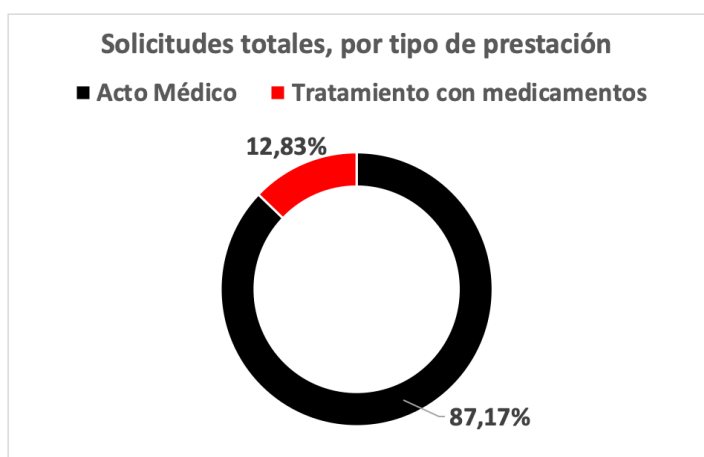


Figura 7. Solicitudes totales, por tipo de prestación

Figura 8. Autorizaciones, por tipo de prestación

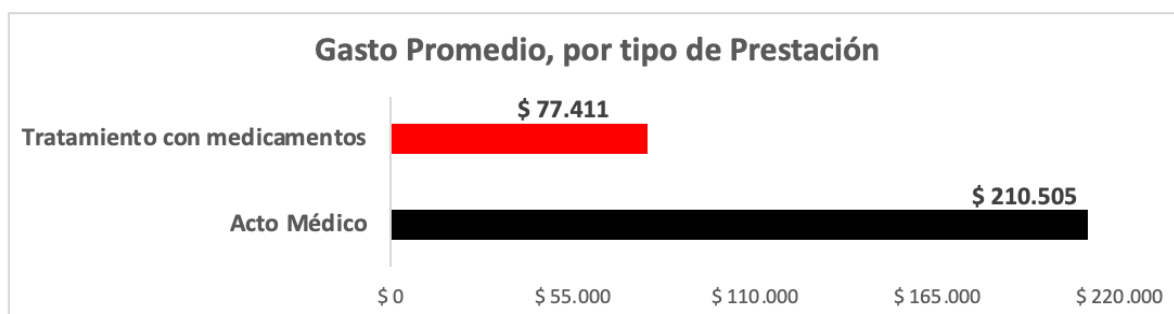


Figura 9. Gasto promedio, por tipo de prestación

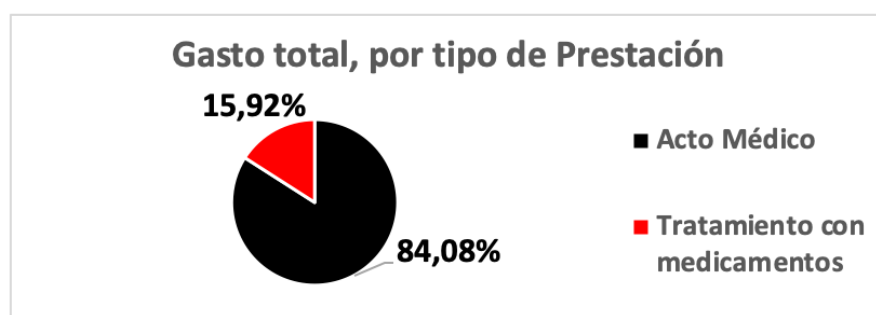


Figura 10. Peso de cada tipo de prestación, sobre el gasto total

- Las autorizaciones representan poco menos del 91% del total de solicitudes, siendo poca la diferencia de esta relación para cada tipo de prestación. Se puede apreciar un desbalance entre las solicitudes autorizadas y no autorizadas, tanto en actos médicos como en tratamientos con medicamentos.

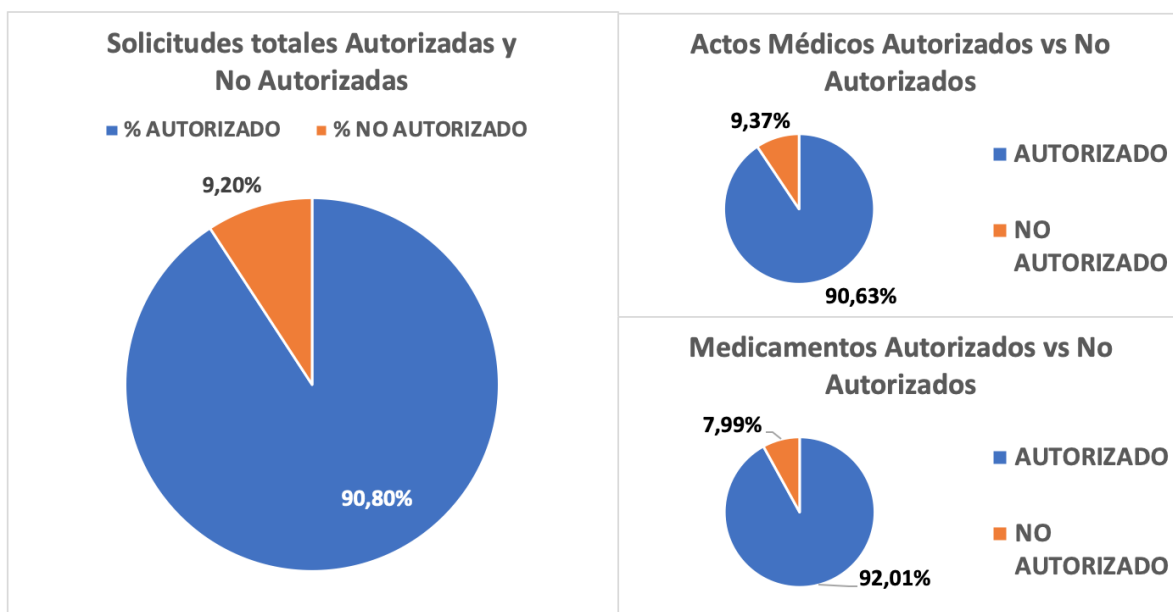


Figura 11. Solicitudes autorizadas y no autorizadas, totales y por tipo de prestación.

- Los tratamientos con medicamentos son más solicitados por mujeres que por hombres, mientras que en los actos médicos el patrón es el opuesto. En ambos casos la relación ronda el 53,5% - 46,5%.
- A nivel general, son más las solicitudes realizadas por hombres que por mujeres. Los hombres presentaron 25.889 solicitudes (52,70%) mientras que las mujeres solicitaron 23.238 coberturas (47,30%).

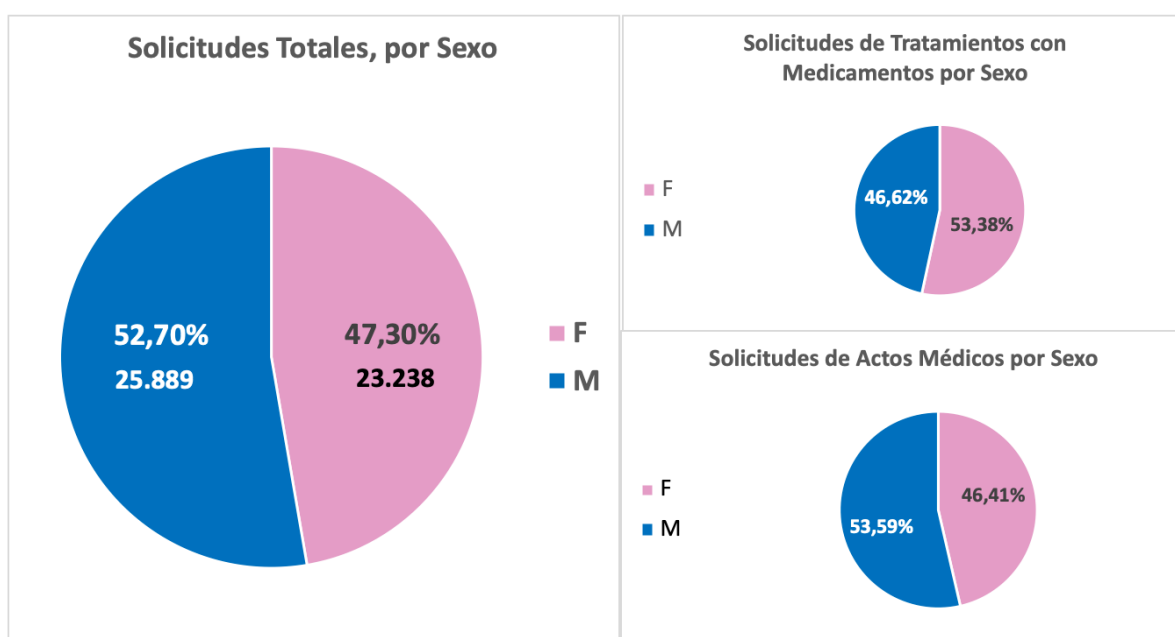


Figura 12. Solicitudes por sexo, totales y por tipo de prestación.

- En relación al sexo femenino, el sexo masculino goza de un mayor grado de autorización. De cada solicitud que las mujeres han hecho en 2016/17 alrededor del 88% fue autorizada, mientras que en el caso de los hombres ese ratio asciende a 93,46%.

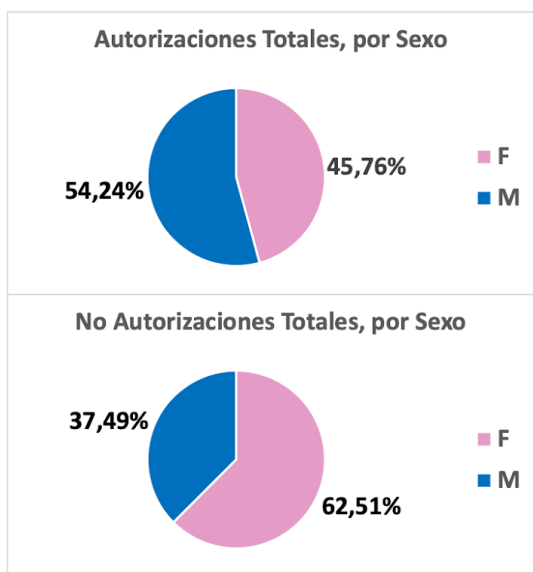


Figura 13. Proporción de cada sexo en el total de solicitudes autorizadas y no autorizadas

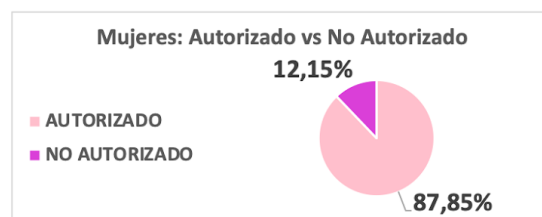


Figura 14. De las solicitudes hechas por mujeres, proporción autorizada y no autorizada

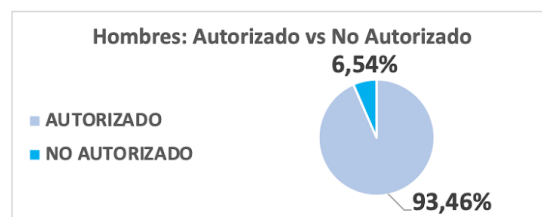


Figura 15. De las solicitudes hechas por hombres, proporción autorizada y no autorizada

- La proporción de tratamientos con medicamentos autorizada y no autorizada, al clasificarse por sexo, sigue una tendencia similar a las solicitudes de ese tipo de prestación. Como contracara, los actos médicos tienen una fuerte inclinación a otorgar más coberturas al sexo masculino que al femenino. De las 38.809 autorizaciones de actos médicos, el 55,39% corresponde a hombres y el 44,61% a mujeres. Al analizar los actos médicos no autorizados parece llamativo que el 63,75% se corresponda al sexo femenino y 36,25% al masculino.

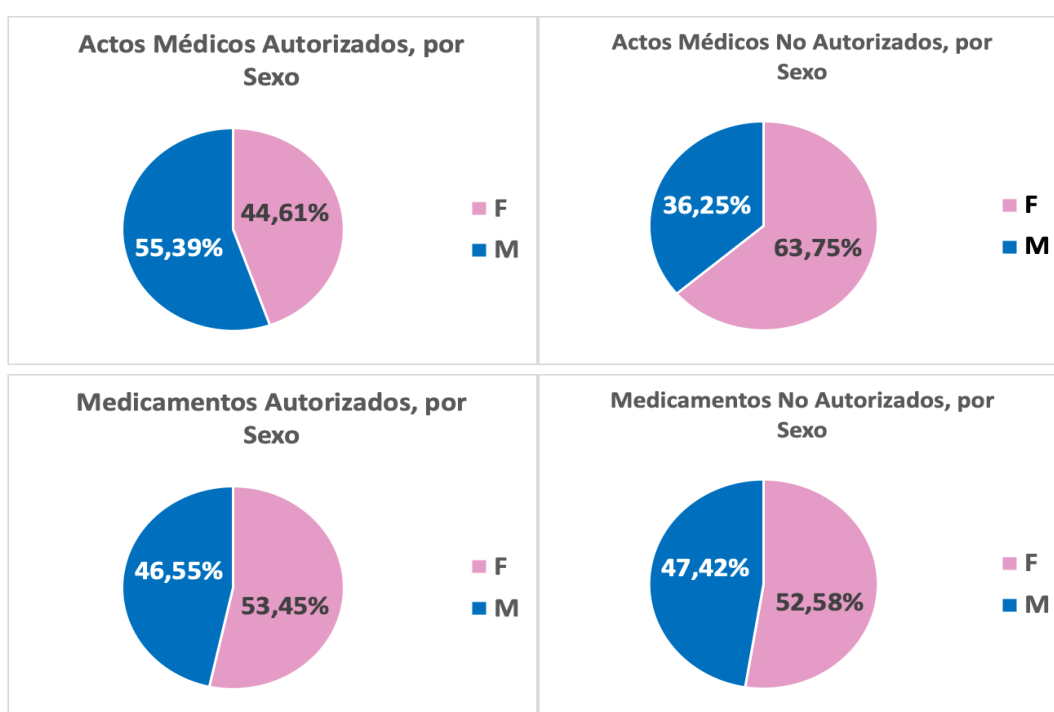


Figura 16. Solicitudes autorizadas y no autorizadas por sexo y tipo de prestación

- Los hombres, en promedio, reciben prestaciones más costosas que las mujeres. Esto es concordante con que los hombres suelen ser quienes solicitan más actos médicos y las mujeres quienes solicitan más tratamientos con medicamentos, siendo los actos médicos más costosos promedialmente que los Medicamentos.

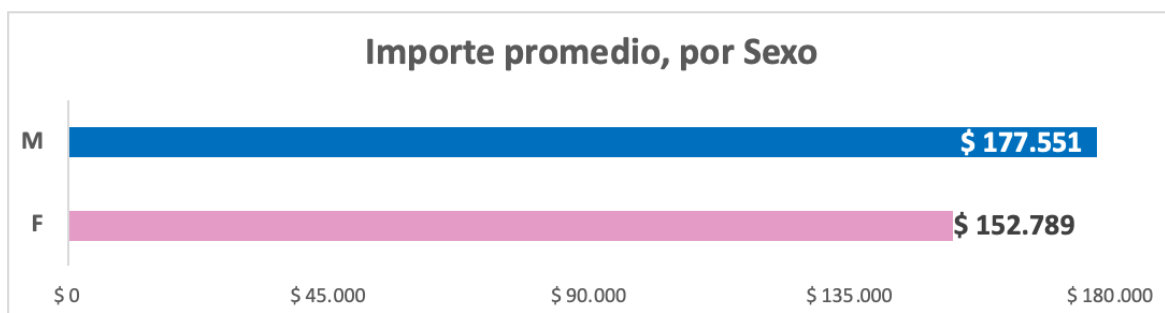


Figura 17. Importe promedio de las coberturas, por sexo

- En cuanto a los tratamientos que se solicitan, se puede observar claramente que algunos son más requeridos por hombres y otros por mujeres. Un claro ejemplo de desproporción en las solicitudes es para el tratamiento con medicamentos vinculado al cáncer de mama, en el cual 746 de las 751 solicitudes fueron hechas por mujeres.

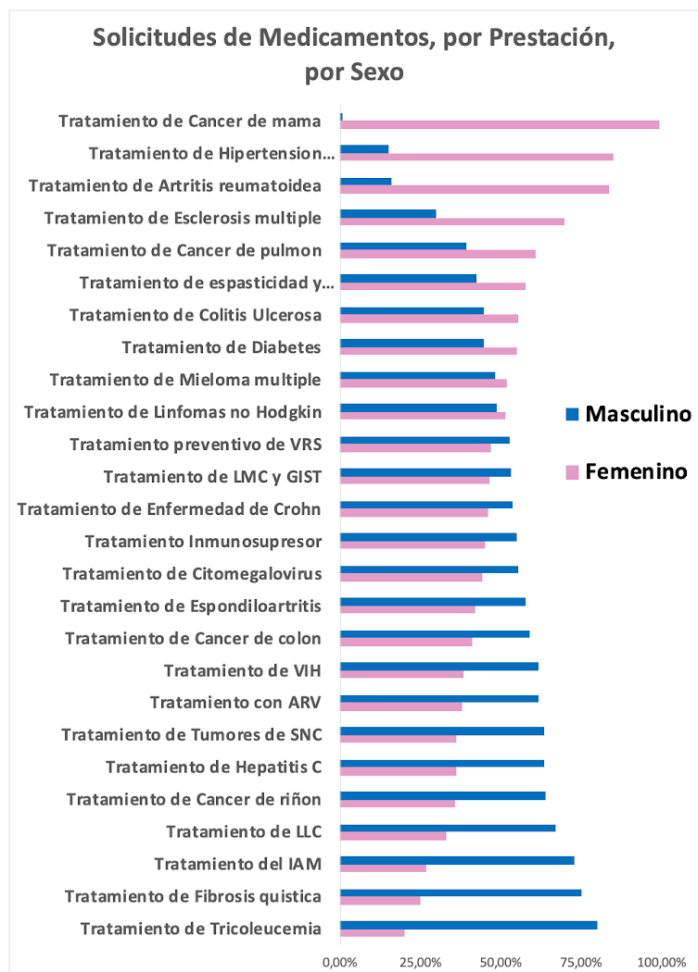


Figura 18. Solicitudes de Medicamentos, por prestación, por sexo

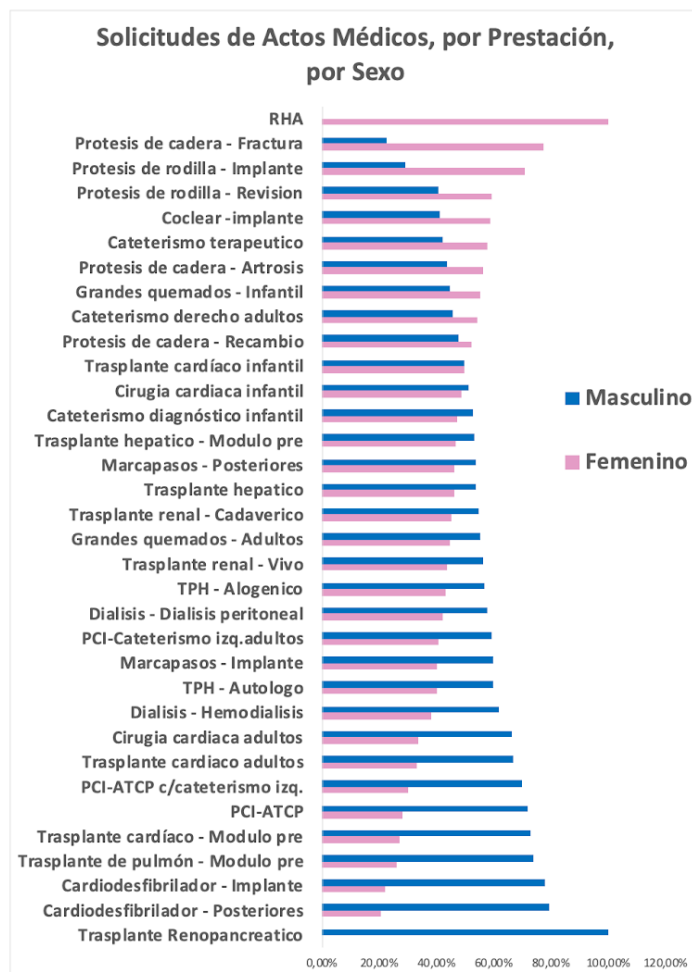


Figura 19. Solicitudes de Actos Médicos, por prestación, por sexo

- Al evaluar las prestaciones autorizadas y no autorizadas por edad del solicitante, se puede observar una distribución similar a la normal con un pico en torno a los 70 años para los actos médicos y para los Medicamentos aproximadamente a los 60 años. Una excepción a esta distribución es para los recién nacidos (0 años), que requieren de una parte considerable de las prestaciones (especialmente de medicamentos, solicitando poco más del 10% del total).

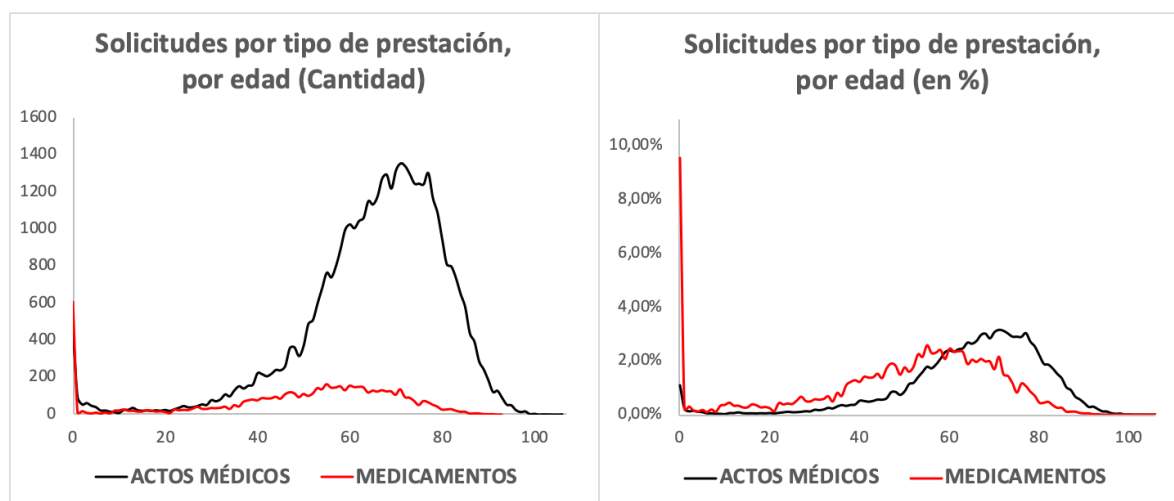


Figura 20. Solicitudes por edad, por tipo de prestación.

- Los actos médicos reflejan en sus solicitudes y autorizaciones cierta “estabilidad” para personas de hasta (aprox.) 35 años, viéndose muy incrementadas las solicitudes recibidas para personas mayores a la mencionada edad. Los tratamientos con medicamentos tienen una distribución más horizontal, siendo menor la volatilidad de las solicitudes y autorizaciones, en función de la edad. Las coberturas de medicamentos no autorizadas presentan una tendencia similar que sus autorizaciones, mientras que los actos médicos presentan una distribución distinta, reflejando un aumento de rechazos para el segmento desde los 20 a los 40 años, pasando luego por una recaída cuyo mínimo se da alrededor de la edad de 50, para luego volver a incrementarse, retomando con una tendencia similar a la de las solicitudes de este tipo de prestación. Los actos médicos no autorizados del año 2016 son los que dan esta forma de “M” a la distribución, ya que en 2017 los rechazos de actos médicos (y totales) adoptan una distribución cuasi idéntica a las solicitudes recibidas.
- Previamente en el trabajo mencioné las normativas de cobertura, las cuales indican ciertos criterios de inclusión o exclusión de un paciente para un tratamiento. Siendo la expectativa de vida remanente un factor importante en la evaluación de la autorización, me sorprendió que se hayan autorizado 680 coberturas a pacientes de entre 90 y 99 años, y 11 coberturas a personas de entre 100 y 106 años, siendo las anteriores edades que exceden la esperanza de vida en el país.^[30]

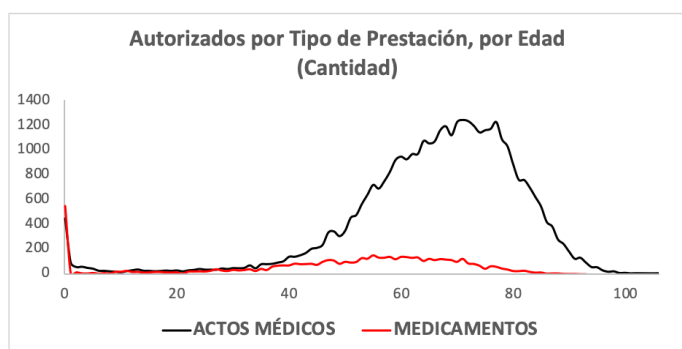


Figura 21. Autorizaciones por edad, por tipo de prestación.

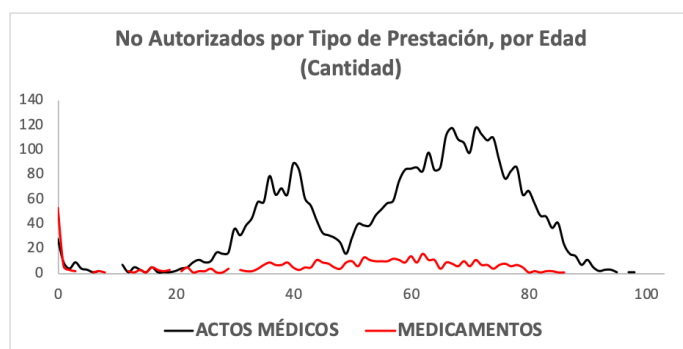


Figura 22. No autorizaciones por edad, por tipo de prestación.

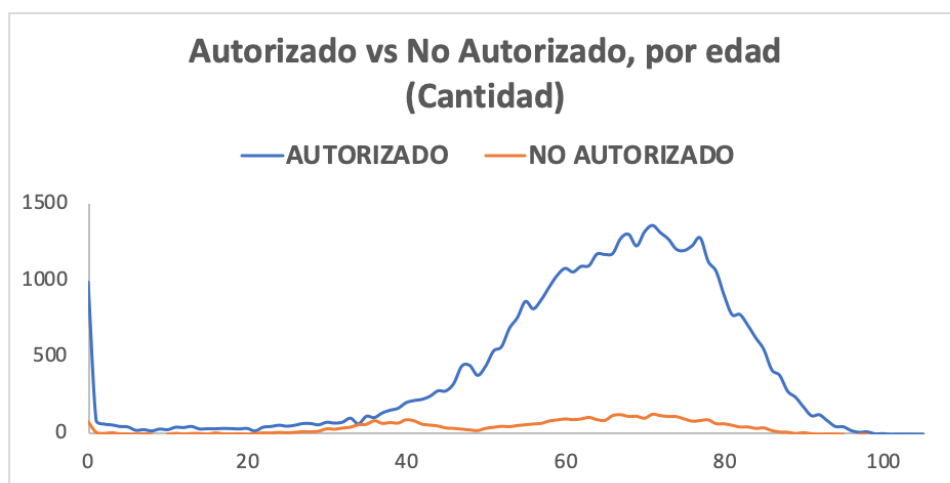


Figura 23. Distribución por edad de solicitudes Autorizadas y No Autorizadas

- ❑ Al distribuir el gasto del FNR de este período por edades, se puede evidenciar una distribución con forma muy similar a las solicitudes. Los actos médicos y el total general alcanzan un pico a los 68 años, mientras que los tratamientos con medicamentos tuvieron a las personas de 58 años como punto máximo.

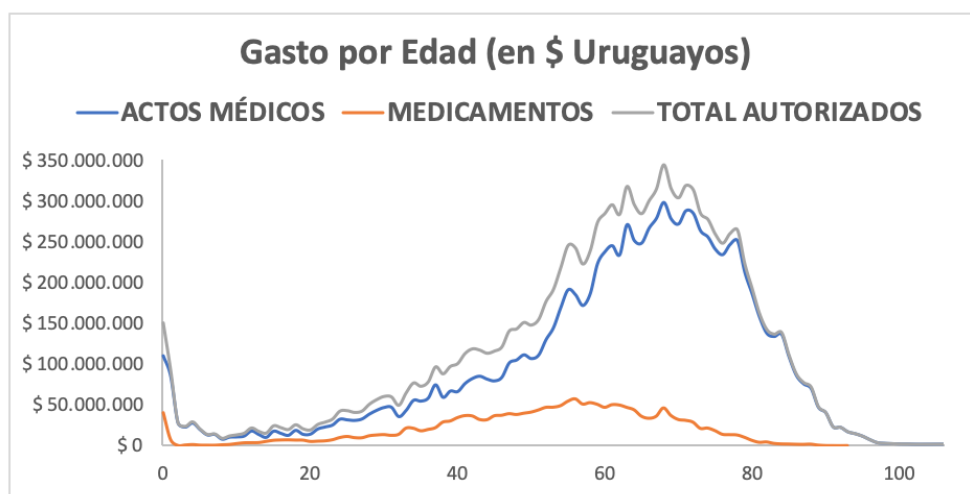


Figura 24. Distribución del dinero gastado por edad, por concepto de Actos Médicos, Medicamentos y en Total

- Tanto los tratamientos con medicamentos como los actos médicos concentran la mayoría de sus solicitudes en unas pocas prestaciones, mientras que hay muchas otras que están por debajo del 5%. Por citar algún ejemplo, las solicitudes de actos cardiológicos representan el 64% del total de actos médicos y las de medicamentos oncológicos son casi el 42% del total de las solicitudes de Medicamentos.

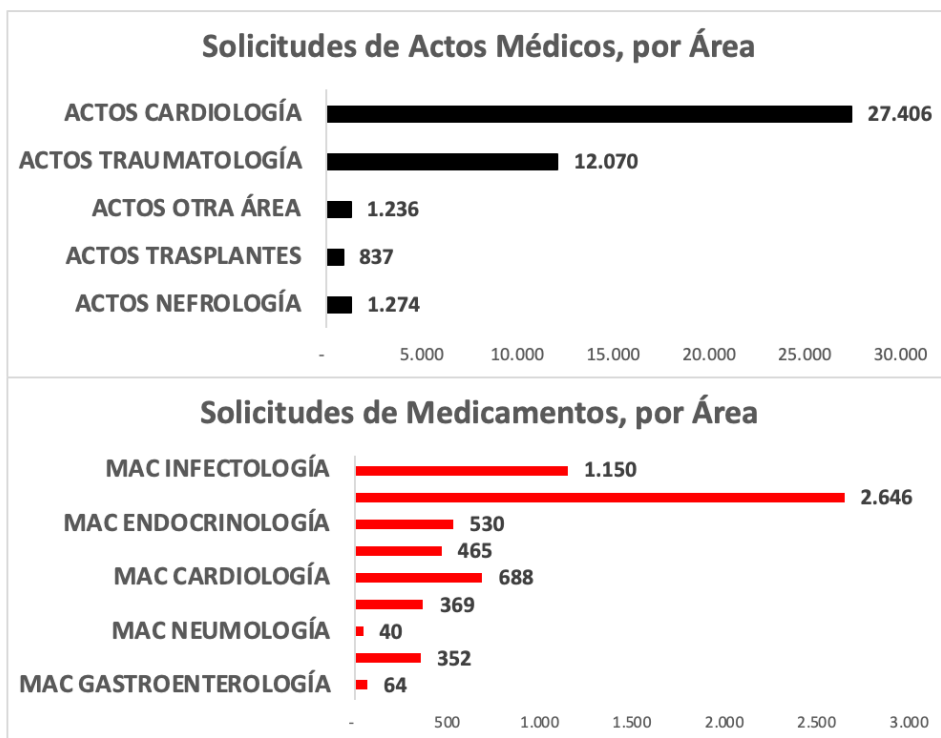


Figura 25. Cantidad de solicitudes por área

- El “tiempo de demora entre las autorizaciones” es aquel que transcurre entre la solicitud de una prestación y la autorización efectiva de la misma. La media de este tiempo para actos médicos es de 30,88 días, mientras que para los tratamientos con medicamentos es de 17,18 días. De todas formas la variabilidad entre las distintas prestaciones es bastante importante (por ejemplo, “Prótesis de Rodilla - Implante” tiene una demora media de 158,61 días, mientras que para el “Trasplante cardíaco infantil” la misma es de 0,50 días).

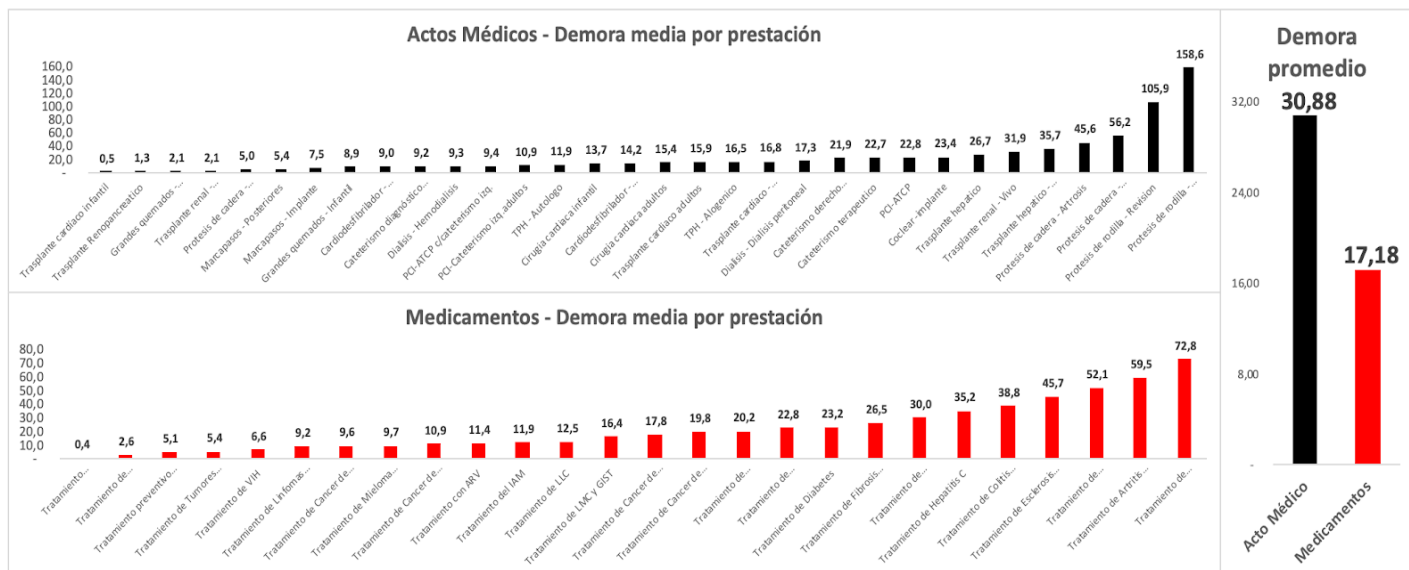


Figura 26. Demora promedio en la autorización (en días), por prestación

- Temporalmente hablando, la cantidad de solicitudes presentadas suelen presentar cierta estabilidad a lo largo de todo el período, aunque es visible una leve baja entre los meses de noviembre y febrero. Los medicamentos solicitados presentan una estabilidad mayor.

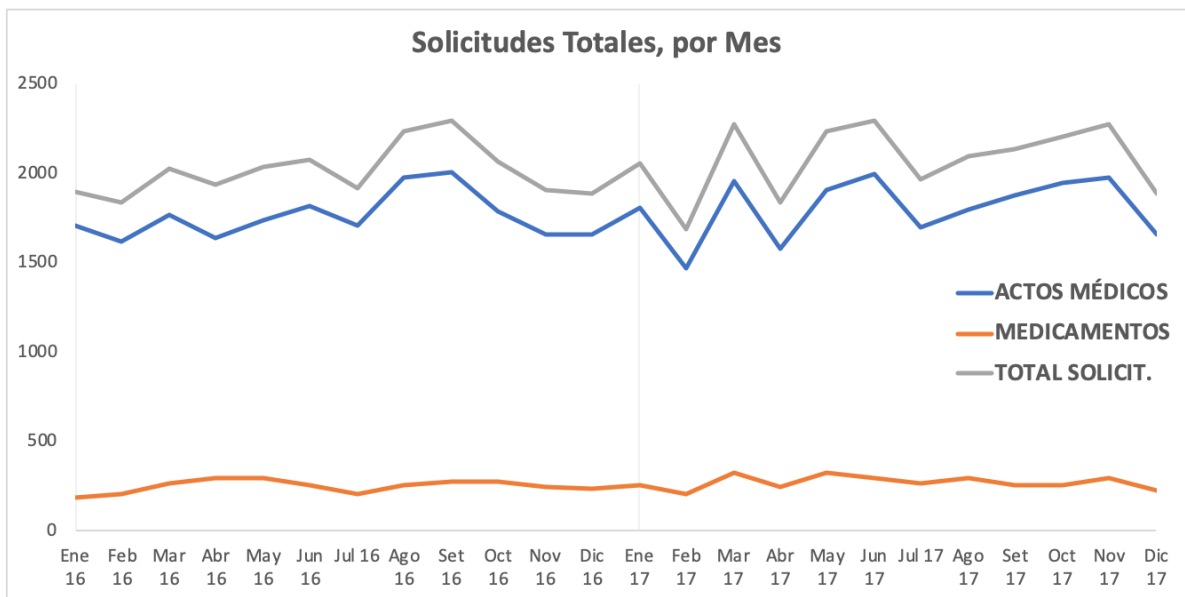


Figura 27. Solicitudes de coberturas financieras presentadas por mes

- En la figura 28 se puede observar el ratio de autorizados - no autorizados, por mes. Si bien hay algunas fluctuaciones, la materialidad de las mismas es muy menor.

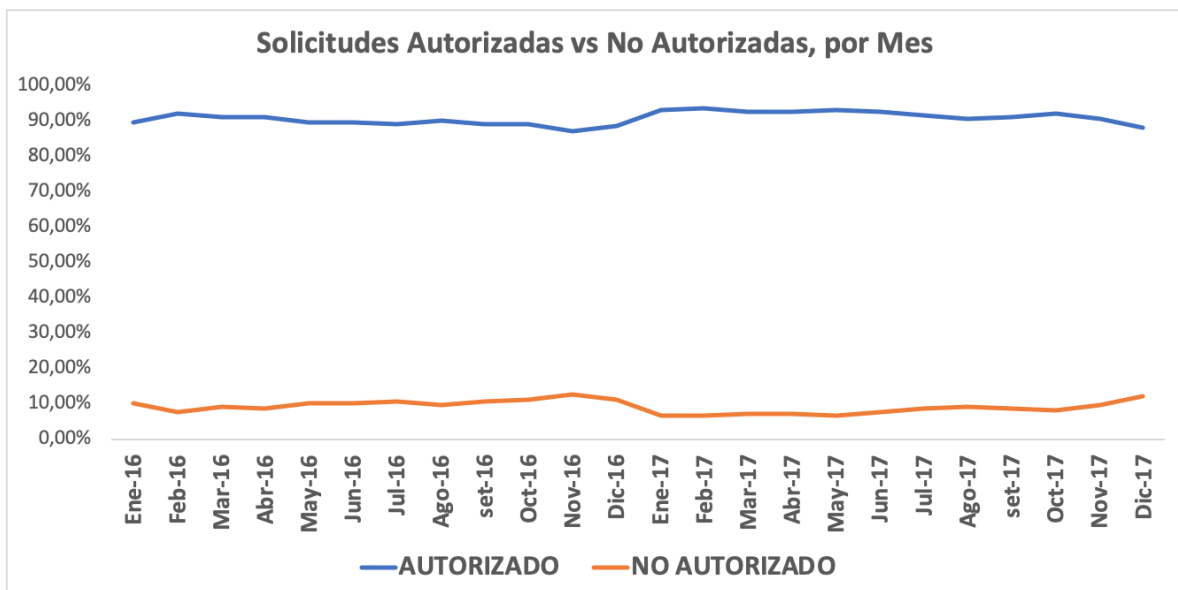


Figura 28. Solicitudes autorizadas y no autorizadas por mes

- ❑ La distribución territorial de las solicitudes lógicamente tiene relación con los habitantes de cada ciudad, aunque esta no es lineal. Por citar un caso importante, la población de Montevideo representa un 40% de la población del país^[31], pero las solicitudes hechas por residentes en dicho departamento superan el 46% del total.

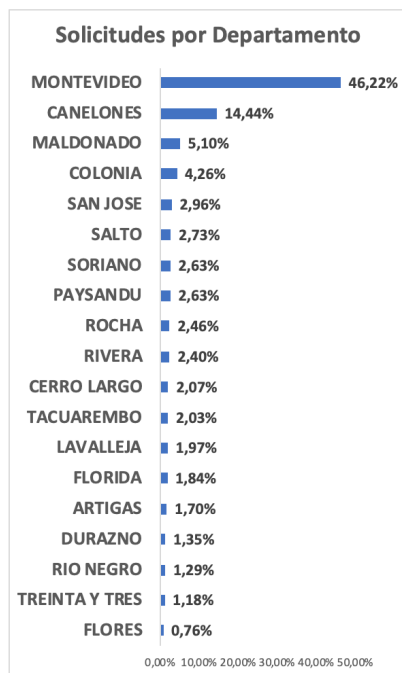


Figura 29. Solicitudes presentadas, por departamento

- ❑ Normalmente el tipo de Prestador es el IAMC (Instituciones de Asistencia Médica Colectiva) o ASSE (Administración de los Servicios de Salud del Estado), con el 69,82% y 26,29% de las solicitudes respectivamente.

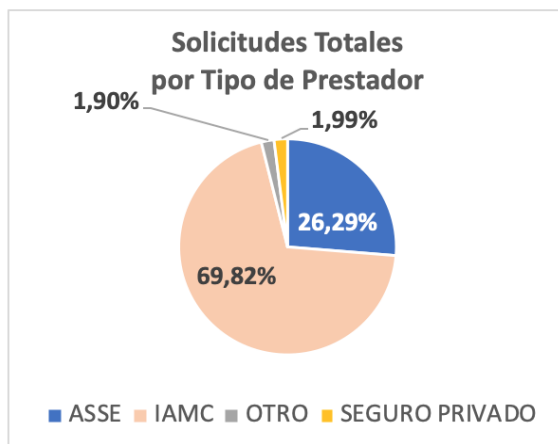


Figura 30. Solicitudes presentadas, por tipo de prestador

- Hay más de 130 prestadores de actos médicos a lo largo del país. Los diez principales concentran más del 44% del total de solicitudes, siendo CASMU el principal centro con un 10,01% del total. Los prestadores de Medicamentos son más de 100, y los principales diez representan poco menos del 40% de las solicitudes totales por este concepto.

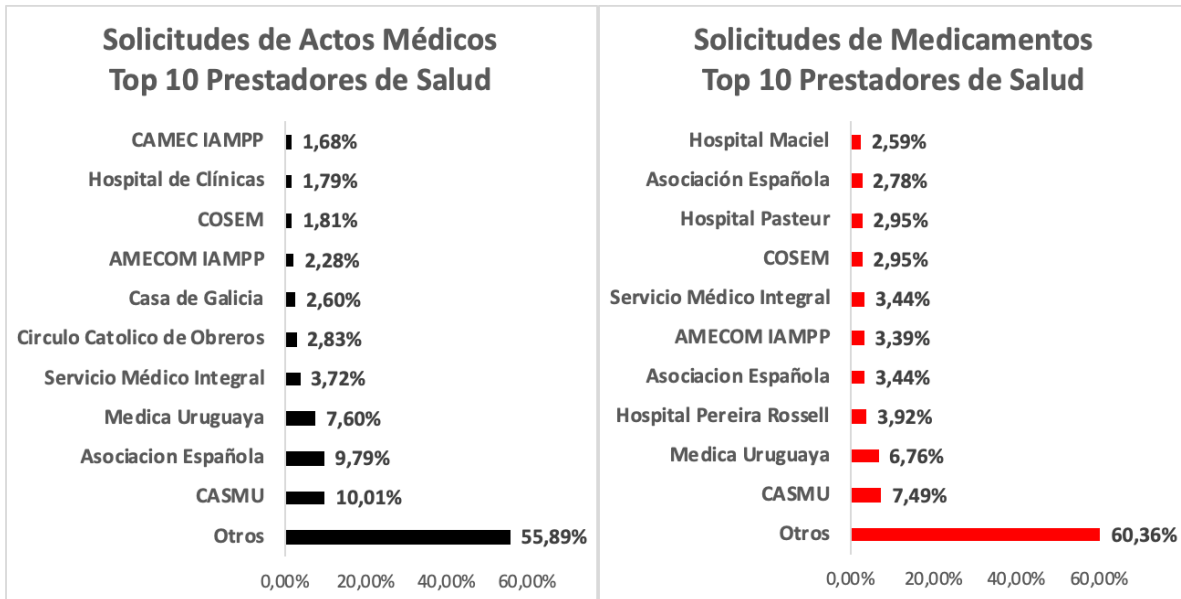


Figura 31. Prestadores de salud con mayor cantidad de solicitudes

- Fueron más de 2100 los médicos que solicitaron prestaciones en el período 2016/17. Los 27 médicos que más solicitudes presentaron representan poco más de un 30% del total de solicitudes.

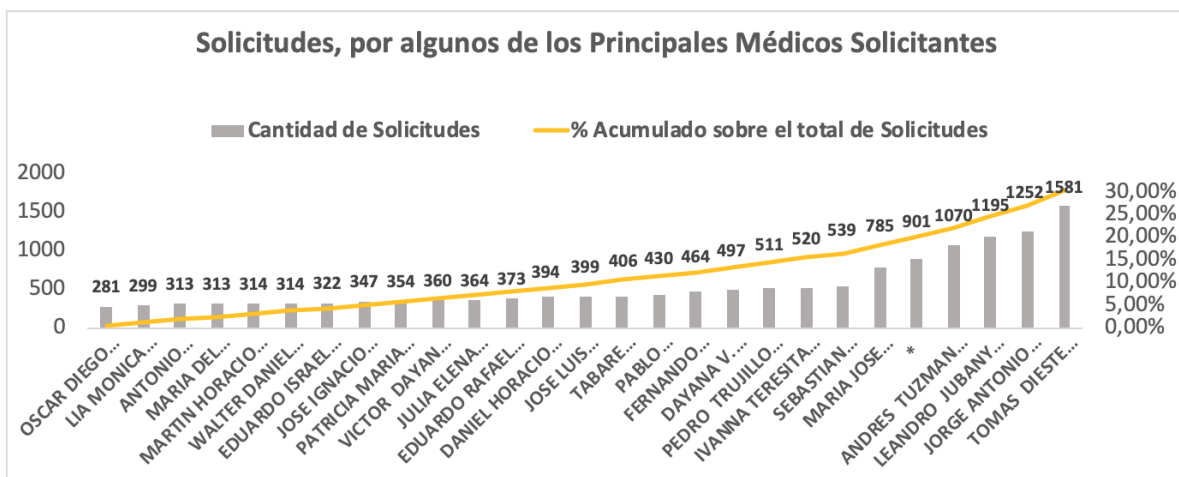


Figura 32. Principales médicos solicitantes, de acuerdo a la cantidad de solicitudes presentadas
* : Médico solicitante sin registro en el dataset

- En el campo “Médico solicitante” hay 901 registros que no presentan ningún nombre. De esas presentaciones “anónimas” el 97,78% se rechazó y tan solo un 2,22% fue autorizado. Creo importante remarcar que 20 prestaciones fueron autorizadas pese a no haberse realizado por un médico, condición necesaria pero no suficiente para ser autorizado, lo cual refleja alguna falla en los controles.



Figura 33. Medico solicitante sin registro (*)

5. MODELOS PREDICTIVOS

En esta sección se presenta el desarrollo de dos modelos predictivos con la finalidad de mostrar la factibilidad de la aplicación de analytics a nivel del FNR. A continuación paso a detallar cada uno de ellos.

5.1. Modelo I - Objetivo y Selección de Variables

El primero de los modelos construidos tiene como objetivo predecir, en base a ciertas características del paciente, si la prestación solicitada será autorizada o no. El nombre de la variable que nos indica lo que queremos predecir es “estado_solicitud”, a la cual asigné valores iguales a 1 para aquellas solicitudes autorizadas y valores iguales a 0 para aquellas rechazadas.

Adicionalmente algunas variables fueron quitadas del modelo, dado que eran redundantes o que no deberían tener poder predictivo. Estas fueron:

- Número de paciente } No debería tener poder predictivo
- Código de prestación } Mantuve la descripción de la prestación, que representa exactamente lo mismo
- Fecha de autorización } Si aparecen es porque se autorizó, que justamente es lo que quiero predecir
- Demora en la autorización }

Para ejemplificar visualmente, el **Modelo I** utiliza información como la siguiente en pos de poder predecir si la solicitud sería autorizada (1) o no autorizada (0):

Año	Tipo de Prestación	Área	Descripción de la Prestación	Fecha de Solicitud	Edad	Sexo	Departamento de Residencia	Prestador de salud	Prestador Tipo	Médico Solicitante	Estado de la Solicitud
2016	Acto Médico	ACTOS TRASPLANTES	TPH - Autologo	4/1/16	57	F	MONTEVIDEO	Universal	IAMC	PATRICIA KOLLAR	VARIABLE A PREDICIR
2016	Acto Médico	ACTOS CARDIOLOGÍA	PCI-Cateterismo izq.adultos	16/2/16	35	M	CANELONES	CASMU	IAMC	SEBASTIAN LLUBERAS	
2016	Acto Médico	ACTOS TRAUMATOLOGÍA	Protesis de rodilla - Implante	19/7/16	58	M	MONTEVIDEO	Universal	IAMC	DANIEL RIENZI	
2016	Tratamiento con medicamentos	MAC ONCOLOGÍA	Tratamiento de Cancer de riñon	14/12/16	73	M	SORIANO	CAMS IAMPP	IAMC	ALICIA PALMA	
2017	Tratamiento con medicamentos	MAC INMUNOLOGÍA	Tratamiento Inmunosupresor	9/2/17	62	F	MONTEVIDEO	Hospital Maciel	ASSE	MELANIA KURDIAN	
2017	Acto Médico	ACTOS CARDIOLOGÍA	Cirugia cardiaca infantil	4/4/17	1	F	CERRO LARGO	CANCEL IAMPP	IAMC	RAFAEL ANZIBAR	
2017	Acto Médico	ACTOS NEFROLOGÍA	Dialisis - Hemodialisis	29/5/17	38	M	COLONIA	Círculo Católico de Obreros	IAMC	LUCIA ORIHUELA	

Figura 34. Ejemplo de información utilizada en el Modelo I

5.2. Modelo II - Objetivo y Selección de Variables

En el segundo modelo se busca predecir si la demora en las autorizaciones de una prestación determinada será mayor o menor a una cierta cantidad de días, entendiendo a esta demora como la cantidad de días que transcurren entre las fechas de solicitud y de autorización (“demora_aut” en el conjunto de datos). Vale la pena aclarar que la fecha de autorización difiere de la fecha de realización. La realización del acto médico es coordinada entre el FNR y el paciente, una vez que la autorización de la solicitud le es comunicada. Las coordinaciones tienen diferentes demoras según el tipo de procedimiento a realizarse, o el Instituto de Medicina Altamente Especializada (IMAE) escogido por el paciente para la realización de este.

Dados que los tiempos transcurridos entre las solicitudes y las autorizaciones son muy dispares según el tipo de prestación (tal como se mostró en la Figura 26), y para acotar el análisis a solicitudes con niveles similares de urgencia, el análisis fue acotado a un solo tratamiento. En el **Modelo II** me focalicé puntualmente en la prestación “PCI-Cateterismo izq.adultos”¹⁵ por la gran cantidad de solicitudes que tuvo en el período analizado (fue la prestación más solicitada) y la importancia del factor tiempo en los actos cardiológicos. Las autorizaciones correspondientes a esta prestación durante 2016/17 ascendieron a 8.676 (sobre un total de 9.530 requerimientos) lo cual representa un 91,04%. La demora promedio en la autorización fue de 10,90 días, mientras que la mediana fue de 3 días. En la tabla contenida en la Figura 35 se puede apreciar la distribución de solicitudes de esta prestación que han sido autorizadas, según la cantidad de días que tardó dicha aceptación.

Demora en la autorización (días)	Cantidad	%
0 a 3	4.428	51,04%
4 a 13	2.714	31,28%
14 o +	1.534	17,68%
	<u>8.676</u>	

Figura 35. Demoras en la autorización de PCI - Cateterismo Izquierdo

¹⁵ PCI es la sigla de “Procedimiento Coronario Intervencionista”, según “Anexo IV”.
Extraído de: http://www.fnr.gub.uy/sites/default/files/formularios/form_solicitud/s_pci.pdf

Para el período 2016/17 el tiempo promedio transcurrido entre la autorización y la realización fue de 14,45 días¹⁶, para una muestra de 3.788 realizaciones. En la Figura 36 se pueden observar algunas cifras que el FNR reveló respecto a la demora en la realización para el período analizado.¹⁷ Aun cuando este lapso hasta la realización del acto médico excede el alcance del **Modelo II**, es importante tener esta noción de los plazos posteriores a la autorización, pues son un insumo importante a la hora de definir los días que signifiquen un punto de inflexión en la clasificación del modelo .



Figura 36. Tiempo de espera entre la autorización y la autorización de Actos Médicos, según IMAE.

Fuente: http://www.fnr.gub.uy/tiempo_espera_am

El **Modelo II** buscará predecir si un paciente, que sabemos que ha sido autorizado para este tipo de procedimiento, tendrá una demora menor o mayor a 14 días entre su solicitud y la autorización del procedimiento. De acuerdo a un cardiólogo con el cual mantuve contacto, desde que se requiere un cateterismo hasta que se realiza, sería aconsejable (aunque no indispensable) un lapso menor a 4 semanas. Habiendo visto que la coordinación con los IMAE lleva en promedio unas 2 semanas, me pareció importante tomar en cuenta lo dicho por el especialista en cuanto a los tiempos aconsejables y tomar 14 días como valor de referencia para el análisis.

Para poder trabajar en el **Modelo II** introduje dos nuevas variables, estrechamente relacionadas entre sí. Una de ellas es la ya introducida “*demora_aut*” que representa los días transcurridos entre la fecha de solicitud y la fecha de autorización. La segunda variable,

¹⁶ Cálculo y criterios reflejados en “*Anexo III*”.

¹⁷ Extraído de: http://www.fnr.gub.uy/tiempo_espera_am

“label”, da valores 1 y 0 para aquellas solicitudes en que su “demora_aut” es mayor (o igual) o menor a 14 días, respectivamente. La variable a predecir será “label”.

Tal como ocurrió en el **Modelo I** algunas variables fueron removidas del modelo, ya sea porque no deberían tener ninguna capacidad predictiva, o porque su inclusión daría lugar a data leakage. A continuación describiré cuales fueron:

- Número de paciente
- Tipo de prestación
- Área
- Código de prestación
- Descripción de prestación
- Estado de autorización
- Fecha de autorización
- Demora en la autorización (“demora_aut”)



Los registros que forman parte de este modelo son en su totalidad Actos Médicos, Autorizados, correspondientes al Área de “Actos Cardiología”. Corresponden a la prestación “PCI - Cateterismo izq. Adultos”, cuyo código es el 202.

La fecha de Autorización (y la de solicitud) dan valor a “IA_Time”, que a su vez define si “label” será 1 o 0. La inclusión de estas variables llevaría a que el modelo incluya información que no debería estar.

La predicción se realizará utilizando las variables que, a modo de ejemplo, presento a continuación:

Año	Fecha de Solicitud	Edad	Sexo	Departamento de Residencia	Prestador de salud	Prestador Tipo	Médico Solicitante	label
2016	7/1/16	45	F	SORIANO	Centro departamental de Soriano	ASSE	GERARDO SOCA	VARIABLE A PREDECIR
2016	18/2/16	66	F	SALTO	Centro departamental de Salto	ASSE	MILTON ERMIDA	
2016	8/4/16	62	M	SORIANO	CAMS IAMPP	IAMC	TOMAS DIESTE	
2016	2/12/16	72	M	CANELONES	Casa de Galicia	IAMC	DANIELA KORJTICKI	
2017	19/1/17	65	F	MONTEVIDEO	Hospital de Clinicas	ASSE	JUAN ALBISTUR	
2017	31/8/17	45	M	MONTEVIDEO	Hospital Evangelico	IAMC	ANTONIO MOMBELLI	
2017	29/12/17	70	M	CANELONES	CASMU	IAMC	LEANDRO JUBANY	

Figura 37. Ejemplo de información utilizada en el Modelo II

5.3. Metodologías utilizadas

Los modelos predictivos que previamente detallé fueron implementados en R. Ambos apuntan a resolver un problema de “aprendizaje supervisado”, lo que significa que buscan predecir cierta variable a partir de las demás variables del conjunto de datos (que en este caso son categóricas). Sumada dicha similitud a que los **Modelos I** y **II** utilizan exactamente el mismo conjunto de datos¹⁸ correspondiente al mismo período, hacen que la estructura de ellos sea prácticamente la misma.

El objetivo al entrenar modelos de aprendizaje supervisado es que los mismos tengan buena performance predictiva en datos para los que no se conoce la variable a predecir (en este caso, datos futuros). De este modo, para estimar dicha performance dividimos los datos de entrenamiento en tres conjuntos: 1) conjunto de entrenamiento, 2) conjunto de validación, 3) conjunto de testeo. Considerando que no se observaron grandes fluctuaciones en las solicitudes presentadas durante el período analizado, y que la situación política y económica del Uruguay ha permanecido prácticamente incambiada en este lapso, opté por una división temporal de los datos. Esta división se hizo de la siguiente manera:

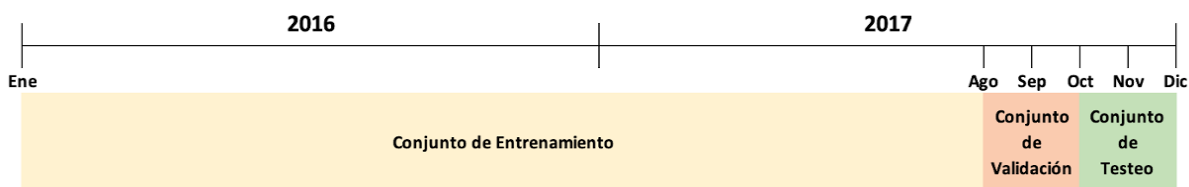


Figura 38. División del conjunto de datos

- En una primera instancia los modelos fueron entrenados con la información de 20 meses (enero 2016 a agosto 2017) y evaluados con los datos del conjunto de validación.
- Una vez hecho esto se tomó la combinación de hiperparámetros que maximiza la performance de cada modelo en la clasificación de los datos de validación, a partir de lo cual se reentrenó el modelo utilizando información de 22 meses (se anexaron los conjuntos de entrenamiento y validación).



Figura 39. Nueva configuración del conjunto de datos, al que se aplica la mejor combinación resultante de la Figura 38.

En relación a la métrica para evaluar la performance del modelo, se utilizó el “Área bajo la Curva ROC” (también *AUC*), dado que es muy útil en modelos de clasificación binarios, como lo son los casos que trabajaremos.^[32] Esta métrica arroja un valor igual a 0.5 cuando el modelo predice resultados similares a lo que se predecirían por puro azar y un valor igual

¹⁸ El **Modelo II** se centra en las solicitudes aprobadas de una prestación específica del Dataset. El **Modelo I**, entre muchos otros registros, incluye aquellos datos analizados en el **Modelo II**.

a 1 cuando genera unas predicciones que permiten clasificar sin errores a las observaciones.

Teniendo en cuenta que la predicción de los **Modelos I y II** se trata de una clasificación, me incliné por la elección del algoritmo XGBoost (Extreme Gradient Boosting)^[33-34], es una popular implementación de Gradient Boosting Machines (GBM) que suele tener muy buenos resultados en “problemas tradicionales” de predicción y que funciona bien para clasificación. Boosting es una estrategia aditiva que consiste en la construcción de varios árboles de forma secuencial, de modo que la construcción de cada árbol contará con la información de aquellos que se han construido previamente. El hecho de construir e ir “ensamblando” los árboles considerando información previa, lleva a considerables mejoras en la precisión.

Vale la pena mencionar que previo a la utilización de los datos en XGBoost se aplicó One-Hot Encoding. La importante presencia de variables categóricas, como por ejemplo “medico_solicitante” (con más de 2100 categorías distintas), hizo que fuera imperante trabajar con matrices ralas.

En XGBoost son siete los hiperparámetros que se suelen modificar para obtener mejores resultados. Es importante ser cauto a la hora de seleccionar sus valores, pues fácilmente se puede sobre-ajustar los datos. Los siguientes son los hiperparámetros y los valores entre los que busqué en los **Modelos I y II**:

- nrounds: indica la cantidad de árboles
Valores buscados: Entre 50 y 300
- max_depth: máxima profundidad de cada árbol
Valores buscados: Entre 2 y 8
- eta: “learning rate”, que retrasa el aprendizaje (λ). También conocido como “Shrinkage”, controla la información de árboles previos que será considerada.
Valores buscados: Entre 0.001 y 0.125
- gamma: mínima reducción del error para realizar un corte
Valores buscados: Entre 0 y 1
- colsample_bytree: cantidad de variables aleatorias a considerar en cada árbol
Valores buscados: Entre 0.5 y 1
- min_child_weight: mínima cantidad de observaciones en los “hijos” para efectuar un corte
Valores buscados: Entre 0 y 2
- subsample: muestreo de observaciones a considerar en cada árbol
Valores buscados: Entre 0.5 y 1

Para optimizar la utilización de dichos hiperparámetros utilicé Random-Search. Este consiste en la definición de una lista de “valores candidatos” para cada hiperparámetro, los cuales son probados y evaluados aleatoriamente cubriendo una cierta cantidad de combinaciones. Esta técnica es reconocida como una de las más prácticas^[35] en lo que refiere a la optimización de hiperparámetros. Otra alternativa podría haber sido el Grid-Search, cuya lógica es similar pero en lugar de probar combinaciones aleatorias, cubre todas las combinaciones posibles.

Al trabajar con datos, un trade-off recurrente es el de precisión e interpretabilidad. Opuesto a *Decision Trees* (poco predictivo y muy sencillo de interpretar), XGBoost suele tener un gran desempeño y presentar dificultades en su interpretación. Para la interpretación de los modelos he utilizado SHAP (SHapley Additive exPlanations)^[36], metodología que busca identificar la contribución individual de cada característica en la predicción. El SHAP value $\Phi_{i,j}$ estima, para cada observación i , la contribución que la característica j tiene en la salida del modelo. De este modo, al calcular $\sum_i |\Phi_{i,j}|$, el SHAP value resulta útil para determinar la importancia de cada feature.^[37]

5.4. Resultados e Interpretaciones

Modelo I

Tal como se expresó al presentar los conjuntos de datos a ser utilizados en este trabajo (Sección 3), en algún momento logré unificar los conjuntos de datos correspondientes a las solicitudes de coberturas y los que detallaban el importe por cada autorización.¹⁹ Al utilizar este dataset “unificado” para la predicción de la aceptación o rechazo de una solicitud (**Modelo I**), la performance de acuerdo a la métrica AUC fue de 0.99 en los datos de validación, lo cual es extremadamente alto.

Pensando en retrospectiva el por qué de tan alta precisión, llegué a la conclusión que la falta de información inicial y los criterios que tomé evidenciaban cuándo una solicitud se autorizó y cuándo no se hizo. Los criterios a los que hago referencia están detallados en el *Anexo II*, pero creo que es importante mencionar que las prestaciones rechazadas (a diferencia de las autorizadas) no formaban parte de los conjuntos de datos con información respecto a los gastos, por lo que debí tomar una postura respecto al valor a asignarles por concepto de importe en el conjunto de datos “unificado” que integra dicha variable. Mi criterio fue, para cada solicitud no autorizada, asignar el importe promedio de las solicitudes autorizadas de esa misma prestación. El modelo predictivo aprendió que casi todas las solicitudes que tenían asociado el importe promedio serían rechazadas y la totalidad de las que diferían serían autorizadas, lo cual explica el altísimo AUC mencionado. Dicho en otros términos, el pipeline de trabajo utilizado daba lugar a un problema de *data leakage*, significando esto que “*cierta información utilizada en la realización del modelo le dio a este una ventaja irreal para hacer mejores predicciones*”²⁰, causando sobreestimaciones en la performance.

En vistas de la alteración que esto provocaba en el desempeño del modelo, resolví volver a trabajar con los datos originales publicados por el FNR. Habiendo mencionado dicho intento fallido, a partir de este momento lo expresado se corresponderá con los datos finalmente

¹⁹ Criterios detallados en “*Anexo II*”.

²⁰ Zheng, A. & Casari, A. (2018). “*Feature Engineering for Machine Learning*”, O’Reilly Media. Estados Unidos

utilizados para el entrenamiento del **Modelo I**.

El Random-Search para el **Modelo I**, cuya división de datos era del tipo Entrenamiento-Validación-Testeo, se corrió en 50 rondas. Aquella configuración de hiperparámetros que obtuvo mejores resultados en validación fue:

-	nrounds	max_depth	eta	gamma
-	134	7	0.089	0.544
colsample_bytree	min_child_weight	subsample	perf_tr	perf_vd
0.610	0.928	0.729	0.882	0.772

Figura 40: Configuración de hiperparámetros que resulta en un mejor desempeño del Modelo I

Una vez obtenida la configuración expresada en la Figura 40, se reentrenó el modelo sobre los datos de entrenamiento y validación (período enero 2016 a octubre 2017 inclusive). Posteriormente se procedió a testear sobre los datos desconocidos al momento del entrenamiento, correspondientes a los meses de noviembre y diciembre de 2017. En el conjunto de testeo, compuesto por 4173 registros, se obtuvo un AUC de 0.7874.

La siguiente imagen refleja la distribución de probabilidades de que las predicciones sean autorizadas (catalogadas como 1), en función de la información real, para los datos de testeo. En la enorme mayoría de los casos la probabilidad de que el output sea “Autorizado” es mayor a un 50%, pero se puede observar que la distribución de probabilidades de aquellos registros que en la realidad fueron aceptados o rechazados, presentan formas diferentes.

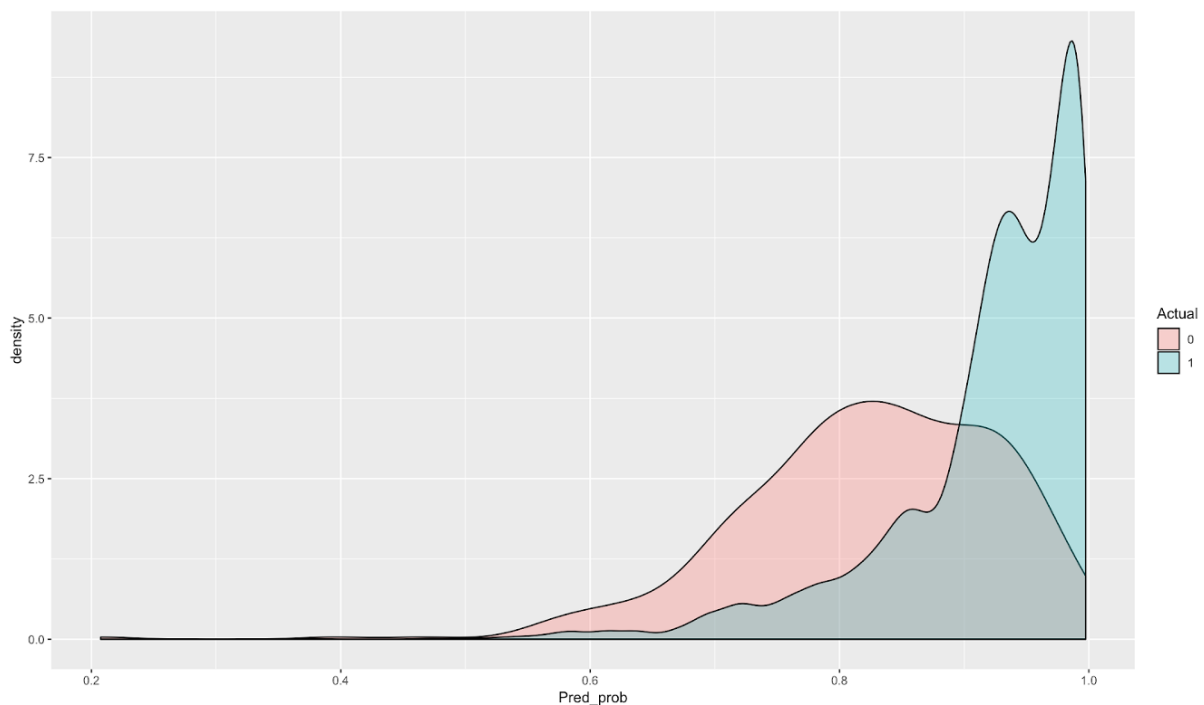


Figura 41. Clasificación del Modelo I, en función de la información real

A partir del gráfico de la Figura 41, me parece oportuno dar mi opinión respecto a los errores de clasificación del **Modelo I**. Desde mi punto de vista hay una asimetría en los mismos, siendo el “peor escenario” que el modelo clasifique una solicitud como autorizada y en los hechos no sea autorizada. Veo en ello cierta similitud con la Teoría de las Perspectivas de Kahneman, D. y Tversky, A.^[38] en que se muestra como (a nivel psicológico) el valor de las pérdidas es mayor al de las ganancias; en el caso del Modelo I el escenario planteado anteriormente podría entenderse como el equivalente a perder algo luego de hipotéticamente contar con ello.

De acuerdo a SHAP, metodología introducida anteriormente, las diez características individualmente más influyentes del **Modelo I** a la hora de predecir el estado de la solicitud fueron:

1. PCI - ATCP con cateterismo izquierdo (Prestación dentro de “Actos Cardiología”)
2. Prótesis de rodilla - implante (Prestación dentro de “Actos Traumatología”)
3. RHA (Prestación dentro de “Actos Otra Área”).
4. Cirugía cardíaca de adultos (Prestación dentro de “Actos Cardiología”)
5. Marcapasos - implante (Prestación dentro de “Actos Cardiología”)
6. Mes de la solicitud
7. PCI - cateterismo izquierdo adultos (Prestación dentro de “Actos Cardiología”)
8. Edad - años
9. PCI - ATCP (Prestación dentro de “Actos Cardiología”)
10. Prestador - ASSE (Tipo de prestador)

La Figura 42 refleja el uso que el **Modelo I** a cada una de estas diez características. La línea horizontal marcada en SHAP value = 0 sirve a modo de referencia para los valores que se encuentran encima o debajo de la misma, los cuales indican una tendencia a generar un output alto o bajo, respectivamente.^[37]

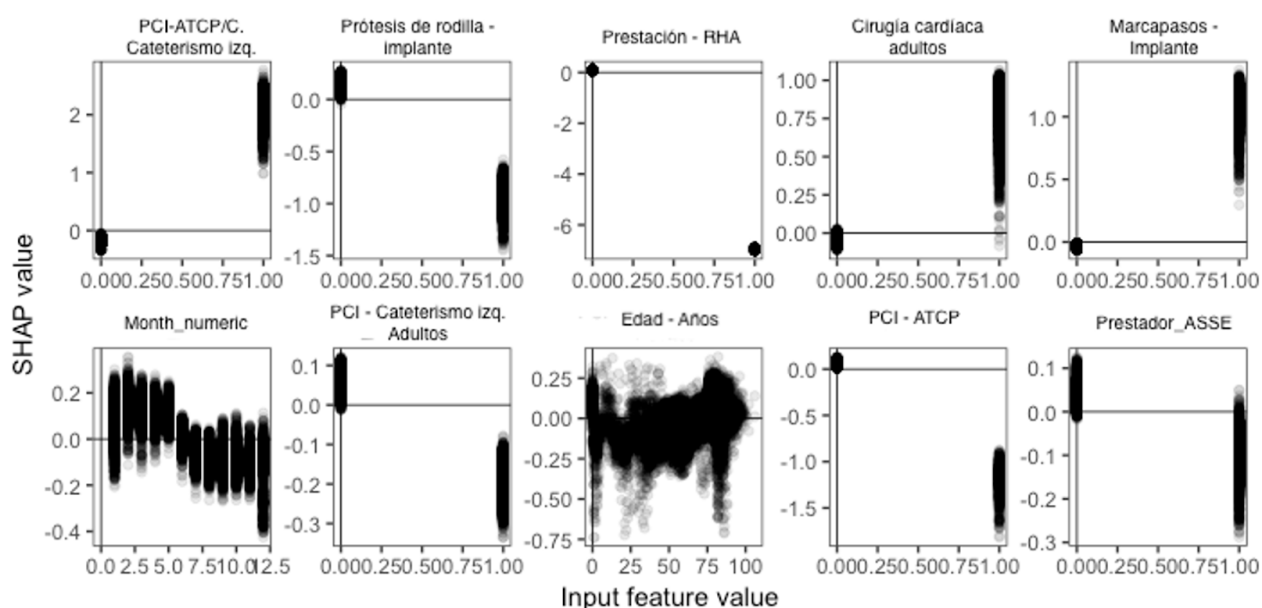


Figura 42. SHAP feature dependence Plot, para el Modelo I

En este caso, la presencia de features tales como “PCI-ATCP con Cateterismo Izquierdo” (99,39% autorizados), “Cirugía cardíaca adultos” (97,56% autorizados) o “Marcapasos - implante” (98,02% autorizados) reflejan una mayor probabilidad que el output del **Modelo I** sea 1, lo que representa la autorización de la solicitud. Como contracara, features como “Prótesis de rodilla - implante” (79,47% autorizados) o “PCI - ATCP” (75,51% autorizados), cuyos niveles de rechazo es mayor que la media (9,20%, según Figura 11), influyen en que el output del modelo sea menor. Más claro aún es en la prestación “RHA”, cuyas solicitudes fueron rechazadas en el 100% de los casos.

Modelo II

La configuración de hiperparámetros que logró mejores resultados en los datos de validación del **Modelo II** fue:

-	nrounds	max_depth	eta	gamma
-	103	3	0.088	0.380
colsample_bytree	min_child_weight	subsample	perf_tr	perf_vd
0.735	0.733	0.824	0.770	0.734

Figura 43: Configuración de hiperparámetros que resulta en un mejor desempeño del Modelo II

Luego de reentrenar el modelo bajo esta configuración de hiperparámetros (Figura 43) el AUC que se obtuvo en el conjunto de testeo fue de 0.7077.

Al igual que en el **Modelo I**, el **Modelo II** asignó a cada registro del conjunto de testeo la probabilidad que la demora entre la solicitud y la autorización sea mayor o igual a 14 días (lo que equivale a que “label” sea 1). La prestación analizada tuvo una demora promedio de 10,90 días, siendo 17,68% los casos donde la demora fue de al menos 14 días. En ese contexto, suena razonable que este desbalance sea contemplado en el modelo, el cual suele asignar probabilidades bajas a que *label* sea 1.

La Figura 44 compara las predicciones del modelo con lo que realmente sucedió. Si bien hay una clara tendencia a catalogar las demoras como menores a 14 días (probabilidad suele ser menor a 0.5), la distribución de probabilidades de aquellas solicitudes cuya demora fue menor a 14 días presenta un pico cercano a 0.10, mientras que las autorizaciones que tuvieron más demora presentan una mayor variabilidad en sus predicciones, cuya media es de alrededor de 0.25.

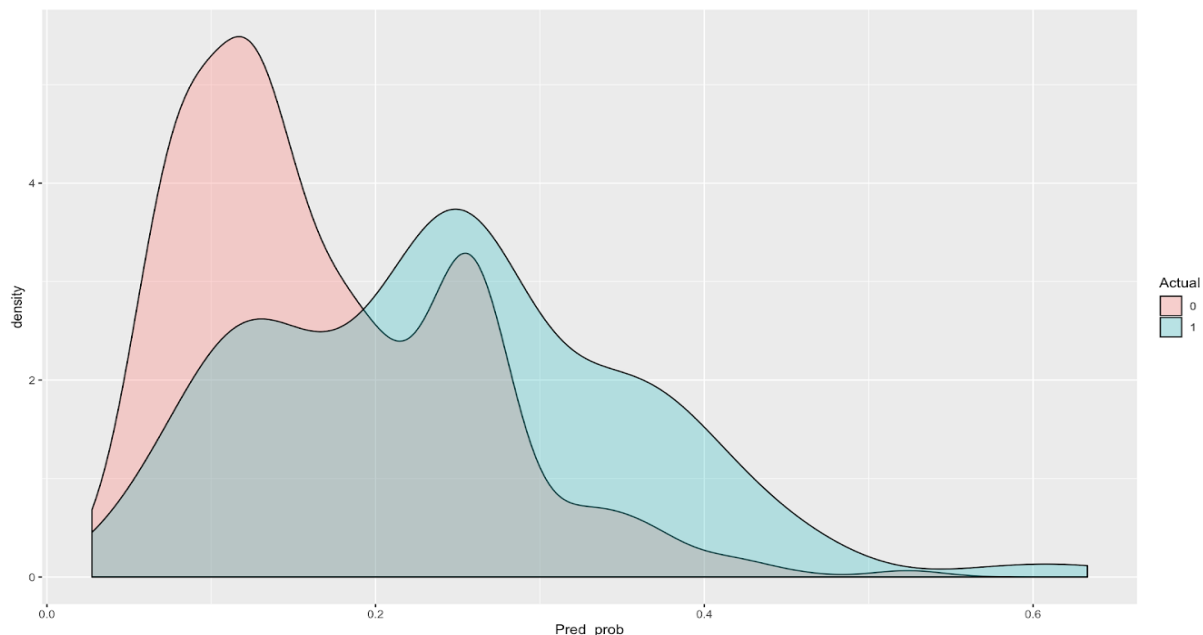


Figura 44. Clasificación del Modelo II, en función de la información real

De la misma forma que en el **Modelo I** percibí asimetrías en los errores de clasificación, pienso que en el **Modelo II** ocurre algo similar. Desde mi perspectiva, en este modelo el caso más adverso se daría cuando el modelo estima que el tiempo de demora será bajo y en la realidad la demora es mayor. De todas formas pienso que aquí el efecto es menor que en el **Modelo I** porque el paciente igualmente es autorizado, aunque a partir del error puede darse que la preparación de un usuario para la intervención pueda no ser la óptima.

En el caso del **Modelo II** los atributos más influyentes en la predicción del tiempo de demora en la autorización para la prestación cardiológica “*PCI - Cateterismo Izquierdo adultos*” fueron los siguientes (conforme a metodología SHAP):

1. Departamento de residencia - Montevideo
2. Dr. Leandro Jubany (Médico Solicitante)
3. Dr. Andrés Tuzman (Médico Solicitante)
4. Dr. Tomás Dieste (Médico Solicitante)
5. Dr. Sebastián Lluberas (Médico Solicitante)
6. Prestador - ASSE (Tipo de prestador)
7. Edad - años
8. Dr. Jorge Mayol (Médico Solicitante)
9. Prestador de salud - Asociación Española
10. Fecha de solicitud

La Figura 45 representa el *SHAP feature dependence plot* de los diez atributos mencionados del **Modelo II** (tal como la Figura 42 lo ha hecho respecto al **Modelo I**)

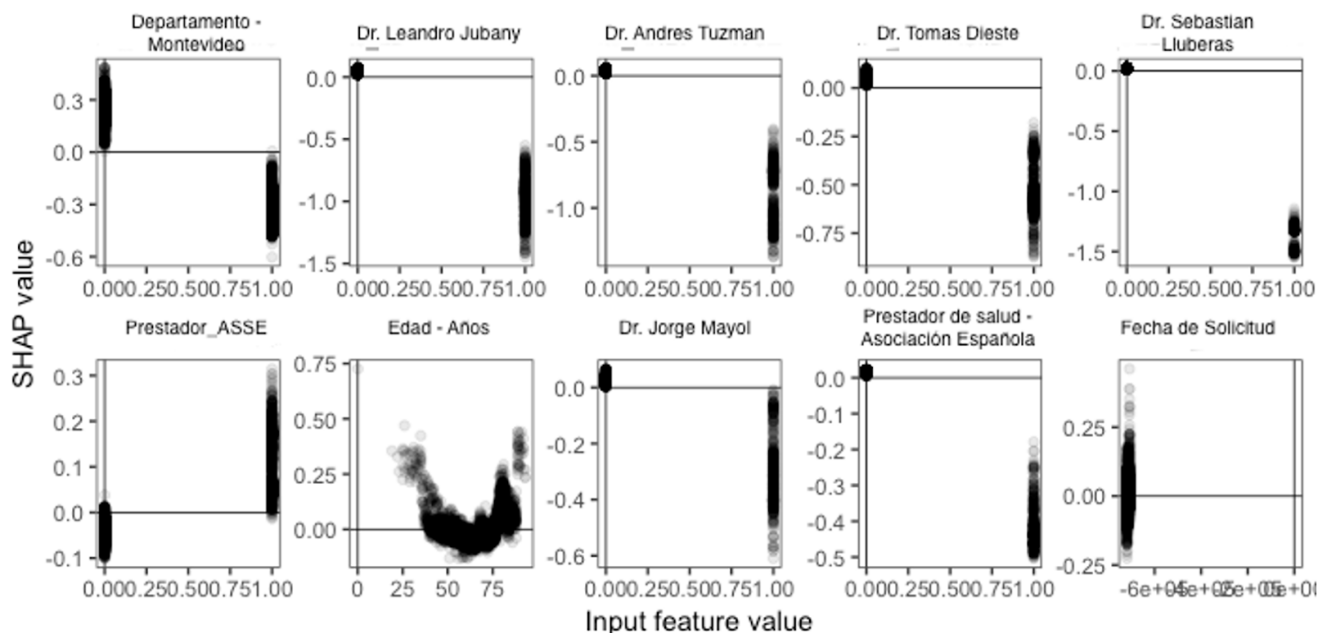


Figura 45. SHAP feature dependence Plot, para el Modelo II

La Figura 45 ilustra la reacción del **Modelo II** ante estos features, conforme a la metodología SHAP. Montevideo, capital y ciudad más poblada del país, es también la que cuenta con más recursos humanos, económicos y materiales. En tal sentido, una solicitud de esta prestación proveniente de Montevideo tiene demoras menores que cualquier otro Departamento del Uruguay, promediando los 8 días. A raíz de ello, el **Modelo II** asocia que si el solicitante reside en Montevideo la predicción tiende a ser 0 (es decir, la demora menor a 14 días).

Los médicos solicitantes Jubany, Dieste, Tuzman, Mayol y Lluberas, son cardiólogos que durante el período 2016/17 han tenido conjuntamente 2310 autorizaciones de cateterismos (203 el que menos, 566 el que más) con las características de los analizados en el **Modelo II**. En forma agrupada se les aprobó un 96,37% de sus solicitudes (e individualmente nunca menos del 95%). Más allá de tener un importante número de autorizaciones, su importancia a la hora de categorizar la demora está dada por la demora promedio en la autorización que presentan las solicitudes que ellos realizaron, las cuales van de 1.80 a 9.46 días, debajo del promedio general para este tipo de cobertura. Este modelo predictivo suele percibir que la presencia de estos profesionales sugiere una demora menor a 14 días en su autorización.

El caso contrario se presenta cuando ASSE (Administración de Servicios de Salud del Estado) es el tipo de prestador. Su demora promedio en las 2438 solicitudes de esta prestación durante el período fue de 13,67 días, superando la media de 10,90 días. Por tanto, el **Modelo II** asocia a la característica "Prestador-ASSE" con un aumento en el output, lo que se puede interpretar como una mayor probabilidad que la demora sea igual a 14 días (cuando "label" = 1).

Con respecto a la edad del paciente, se puede observar una acentuada forma de “U”. Los pacientes más jóvenes y más ancianos, simplemente por su edad suelen causar una predicción de un output mayor (lo que implica una mayor demora); en el caso de pacientes de entre aproximadamente 40-80 años, la demora que capta el Modelo II es menor.

6. CONCLUSIONES

A lo largo de este trabajo se buscó comprender y ejemplificar la potencialidad que la explotación de datos y la toma de decisiones basada en ellos puede tener en el sector público. A partir de información pública de carácter administrativo correspondiente al Fondo Nacional de Recursos, se elaboraron dos modelos predictivos. El **Modelo I** busca predecir si determinada solicitud de una cobertura financiera será autorizada o rechazada, mientras que el **Modelo II** busca (haciendo foco puntualmente en “PCI - Cateterismo izq.adultos”) anticipar si el lapso de tiempo entre la solicitud y la autorización será menor o mayor a una cierta cantidad de días.

Los resultados obtenidos sugieren que a partir de datos de índole meramente administrativo se puede predecir la autorización o rechazo de cierta solicitud, así como los tiempos de demora de la misma. De todas formas, la precisión de los modelos, aunque buena, dista de ser perfecta, más aún teniendo en cuenta cuán delicado e influyente es el output de estos modelos.

A continuación expondré respecto al impacto que la aplicación de estos modelos podrían tener en el seno de la institución analizada, algunas posibles mejoras o ampliaciones a este trabajo y unas palabras finales.

6.1. *¿Qué impacto tendrían el uso de estos modelos en el funcionamiento del FNR?*

A lo largo de este trabajo he buscado reflejar la importancia que el proceso de evaluación de una solicitud tiene en el FNR, lo cual es coherente con la finalidad de este fondo dedicado al financiamiento de tratamientos muy complejos o costosos.

La realización de los **Modelos I y II** sirvió no solo para intentar predecir la autorización (o el rechazo) de una solicitud o la demora de la misma a partir del aprendizaje de información histórica, sino también para mostrar que es factible la realización de este tipo de modelos y la automatización de ciertos procesos críticos en la órbita pública.

La salud figura como una de las industrias más dominadas por el fraude, el desperdicio y el abuso.^[39] Que un modelo predictivo pueda resolver ciertas situaciones, posiblemente evitaría ciertas irregularidades y daría un mayor nivel de transparencia al proceso. Si bien algunos modelos predictivos suelen presentar dificultades en la interpretación (lo que dificulta el concepto de “transparencia”), hay algunas técnicas para sobreponerse a esta

dificultad tal como es el caso de SHAP ^[36] y el “predictive, descriptive, relevant framework” (PDR) ^[40].

Lógicamente esta imparcialidad o “justicia” del modelo depende de los datos de los que aprende. Creo oportuno aclarar que los datos con los cuales fueron elaborados los modelos predictivos tienen ciertos criterios o sesgos inherentes al proceso evaluatorio del FNR durante el período 2016/17, lo cual ineludiblemente forma parte de los modelos de Machine Learning (pues los mismos se entrenaron con dicha información).^[41] Un concepto estrechamente vinculado a ello es el de “Feedback Loop” que implica la amplificación de observaciones pasadas, lo cual no necesariamente es algo bueno si en el pasado ha habido algún tipo de situación injusta o poco ética, y ella está dentro de los datos de los que el modelo se nutre. Un ejemplo de esto puede ser el algoritmo “*PredPol’s drug crime prediction*” puesto en marcha en Estados Unidos; en base a información pasada (y sesgada) el algoritmo sugería a la policía ir habitualmente a los mismos barrios en dónde se concentraban ciertas minorías, mientras que no solían recorrer otros territorios en que también se suscitaba el problema que pretendían encontrar. Al ir a los barrios (generalmente marginales) que el sistema predecía y allí arrestar delincuentes, esa información pasaba a incorporarse a futuras predicciones, lo cual amplificaba la imagen negativa de dichas zonas, por más que el crimen vinculado a las drogas haya sido un problema presente en muchas más áreas.^[42-45]

Los modelos automatizados de clasificación, por más sofisticados que sean, son elaborados por personas. De igual forma, los registros que nutren los conjuntos de datos surgen a partir de alguna acción o comportamiento humano. Por tanto, la ética o justicia presentes en los modelos de aprendizaje automático dependen (casi exclusivamente) de las características e información con que son desarrollados. Las implicancias que los modelos de Machine Learning y la Inteligencia Artificial pueden tener en la vida de las personas es un tema de estudio recurrente, e incluso Microsoft ha formado un equipo de trabajo denominado FATE (Fairness, Accountability, Transparency, and Ethics in AI) para tratar estos asuntos. Algunas técnicas sugeridas para tratar estos temas son la búsqueda constante de sesgos en los datos y ser escépticos al respecto, ser críticos con los resultados y no aceptarlos “porque sí” y establecer canales para que se puedan interpelar personalmente ciertas decisiones.

Llevado al caso del FNR, por su cometido y el tipo de disciplina a la que pertenece, sus resoluciones son de enorme importancia para los usuarios. En tal sentido es fundamental que, de implementarse un sistema automatizado de clasificación tal como se plantea en el trabajo (especialmente en el **Modelo I**), es crucial un análisis exhaustivo de estos tópicos para promover la justicia y transparencia, y mejorar la calidad de vida de los usuarios, tal como se busca.

Los **Modelos I** y **II**, adicionalmente a las predicciones que oportunamente realizan, posibilitan una respuesta inmediata que podría ser de mucha utilidad tanto para el usuario como para el médico solicitante. De acuerdo a un prestigioso Cardiólogo que ha presentado solicitudes correspondientes a “*Cirugía Cardíaca Adultos*” y a “*PCI - Cateterismo izq. adultos*” durante el período 2016/17, la inmediatez de la respuesta que proveen estos modelos podrían ser de mucha utilidad para definir los pasos a seguir con cada paciente

puesto que “no es igual la preparación para alguien que se operará esta semana que si es dentro de un mes”. También enfatizó la importancia de “desburocratizar y transparentar todo lo vinculado a la salud”, teniendo en cuenta la importancia de lo que hay en juego detrás de cada solicitud.

Estructuralmente, la realización y puesta en marcha de estos modelos predictivos tendría un impacto directo en la “Unidad de Evaluación” (dependiente de la “Subdirección de Evaluación de la Gestión”, tal como se puede ver en el organigrama de la Figura 1) y posiblemente también en otras áreas de la organización. La implementación de automatizaciones de esta índole probablemente llevarían a que la cantidad de personal médico dedicado a la evaluación de coberturas sea reducido y/o sustituido por una red interdisciplinaria de profesionales (como podrían ser programadores o analistas de datos, entre otros). En lugar de ver esto como una pérdida de fuentes de trabajo, lo veo como el potencial aprovechamiento de muchos reconocidos profesionales en otras ramas del Fondo Nacional de Recursos o del Ministerio de Salud Pública, pudiendo agregar valor allí.

6.2. Posibles Mejoras y Ampliaciones

Como he escrito previamente, la información utilizada para entrenar al modelo son datos reales del Fondo Nacional de Recursos desde enero 2016 hasta agosto 2017. Esto implica que el **Modelo I** y **Modelo II** replican en nuevas observaciones los elementos aprendidos durante el entrenamiento del modelo, en búsqueda de poder discernir cómo se clasificarían. Habiendo resaltado la importancia que hoy tiene el juicio experto de los profesionales de la salud en los procesos evaluatorios de actos médicos y tratamientos con medicamentos, es lógico deducir que tales opiniones y/o sesgos inherentemente forman parte de este modelo.

Los datos de carácter administrativo con los que conté han sido suficientes para tener una performance correcta en la predicción de la aceptación o rechazo de una cobertura (**Modelo I**), o en la estimación de la demora entre solicitud y autorización para “PCI-Cateterismo izq.adultos” (**Modelo II**). Sin embargo, hay otros elementos relevantes en el funcionamiento del proceso de evaluación de coberturas que no forman parte de los conjuntos de datos publicados. El analytics para la gestión y la toma de decisiones sería aún más propicio en el seno del FNR si se pudiera contar con cierta información que no es de dominio público.

Desde luego que sería muy útil poseer información adicional de las solicitudes, tal como la evaluación del estado de salud del paciente y la expectativa de vida del mismo, el conocimiento de enfermedades preexistentes del paciente y si son tratadas o no, el importe estimado de todas las solicitudes (incluyendo las rechazadas), entre otros. Los mencionados son algunos de los principales elementos que evalúa el profesional del FNR, a raíz de la información recabada por el médico solicitante y por el médico evaluador. Siendo estos criterios muy importantes en la admisión de pacientes, si esta información fuera conocida probablemente lograría predecir de una forma más certera que el **Modelo I** si se autorizaría o no la petición de un paciente para que el FNR le financie un acto médico o un tratamiento con medicamentos. Si se contara con la información previamente mencionada, tomando como base las normativas de cobertura de cada prestación podría dictaminarse cuándo el paciente es incluido o excluido de la cobertura financiera de tal prestación. No

obstante, se podrían presentar situaciones más controversiales, como por ejemplo si el solicitante cumple solamente un criterio de exclusión. Una idea para subsanar esto sería agregar una tercera categoría de clasificación al **Modelo I** para aquellos casos en que no es del todo claro si el solicitante debería ser rechazado o autorizado. “*Ateneo*” podría ser una adición a las ya existentes categorías “*Autorizado*” y “*No Autorizado*”, con la finalidad que ciertas evaluaciones excepcionales sean evaluadas de forma personal, conjunta y consensuada (tal como hoy se hace en esos casos) pero que aquellas solicitudes cuyo dictamen sea claro puedan ser automatizadas.

A lo largo del trabajo he hecho mención que el lapso de tiempo entre que se presenta una solicitud y se autoriza depende únicamente del FNR y los médicos evaluadores, mientras que la fecha de realización de los actos médicos surge de una coordinación entre el FNR y el paciente que será tratado, siendo este último quien define el IMAE de su preferencia para realizarse el procedimiento. En la Figura 36 se puede observar de forma agregada la información de los tiempos de demora desde la autorización hasta su realización dividido por algunos de los principales Institutos de Medicina Altamente Especializados (IMAE). Entendiendo que el tiempo total del proceso (desde la solicitud hasta la realización) es tan o más importante que el tiempo transcurrido hasta la autorización, sería muy útil para el **Modelo II** tener otra variable más en el conjunto de datos que indique la fecha de realización de cada acto médico.

Mejor aún sería contar con información en tiempo real de cada IMAE respecto a la capacidad disponible para ejecutar cada tipo de operación. Más allá de permitir un mejor manejo de los recursos, esta información actualizada permitiría al FNR ofrecer en un abanico de opciones a los usuarios en cuanto a la coordinación de fechas y lugares posibles para su tratamiento, simultáneamente al anuncio de una autorización. Comprendiendo que los usuarios son personas a punto de someterse a actos médicos de alta complejidad, la mayor automatización posible podría traducirse en menos factores de preocupación, resultando esto en una mejor experiencia de usuario. Continuando con la idea de la experiencia de usuario en los actos médicos, creo que sería positivo que los pacientes que reciban una cobertura financiera del FNR realicen un feedback de su experiencia que luego pueda ser utilizada como un insumo por los usuarios que deben definir el IMAE en que operarse.

En adición a lo antedicho, si información tal como la cantidad de recursos económicos, materiales y humanos estuviese disponible al momento de cada evaluación, la predicción del **Modelo II** sería más certera. Esta misma información podría ser de mucha utilidad para la aplicación del “Analytics Prescriptivo”^[46] en la gestión, permitiendo optimizar los recursos de esta institución pública. No obstante, la relación entre el sector de la salud y la optimización de recursos suele conducir a dilemas que involucran conceptos como la moral y la ética, pues se debe establecer un orden de qué personas o qué patologías prevalecen sobre otras, entre otras resoluciones más que complejas.

Siguiendo en línea con aquellas inclusiones que podrían impactar positivamente en la gestión, un aspecto que considero que podría dar buenos resultados sería contar con información sobre los hechos posteriores a una autorización (y realización, si fuese un acto

médico). Esto permitiría analizar ex post si la autorización fue un acierto, o si el paciente no estaba en condiciones de recibir esa cobertura. Podría ser un mecanismo para controlar y evaluar a los médicos evaluadores, a las normativas de cobertura y serviría de “auditoría” para el proceso evaluatorio en general.

Más allá de la factibilidad de los modelos a la que hice mención en el apartado previo, en caso de realizarse una automatización de un proceso crucial como lo es el de autorizaciones o rechazos para el FNR creo firmemente que no deberían ser programadores o científicos de datos los únicos involucrados. Estos profesionales conocen herramientas de explotación de datos más que útiles, pero probablemente los modelos que elaboren para industrias cuyos conceptos no dominan presenten imprecisiones y carezcan de aceptación. Desde mi perspectiva, sería oportuna la conformación de un equipo multidisciplinario de trabajo para dar sustento a los modelos en campos que exceden a la programación y elaboración del mismo. Sumado a los programadores y/o data scientists, sería útil contar con asesores legales, asesores financieros y lógicamente médicos e investigadores de la salud.

Contar con información adicional a la publicada y poder conformar un equipo de trabajo capaz de integrar diferentes áreas de conocimiento, permitiría a esta institución desarrollar modelos de analytics^[46] descriptivo, predictivo y prescriptivo que tengan una gran funcionalidad y que gocen de una aceptación generalizada por la comunidad científica y la sociedad en general.

Desde mi punto de vista, implementaciones de este tipo tarde o temprano generarían cambios en la estructura organizacional presentada en la Figura 1. Más allá de los cambios que este equipo de trabajo interdisciplinario sugerido podría tener directamente sobre las unidades de evaluación, las demás áreas también podrían verse impactadas. Por poner un ejemplo, de haber presencia de Abogados en el equipo que desarrollaría el o los modelos, posiblemente el trabajo de la sección “Asesoría Jurídica” se vería menguado; esto permitiría reducir la plantilla de dicha sección, llevando a una reducción en los costos administrativos y por tanto permitiendo realizar más coberturas financieras. Creo que del arquetipo^[29] “Burocracia Profesional” que hoy en día caracteriza al FNR, se iría mutando hacia la “Adhocracia”, arquetipo que presenta una estructura muy descentralizada que suele ser propicia para proyectos o para innovación en las metodologías (como podría ser este caso). Situaciones de este tipo probablemente requerirían menos colaboradores, lo que causaría que muchos sean trasladados a otras instituciones públicas, pudiendo agregar valor allí.

Suele definirse a la cultura organizacional como el “conjunto de experiencias, hábitos, costumbres, creencias, y valores, que caracteriza a un grupo humano”²¹. Sin formar parte del FNR ni haberlo hecho en ningún momento ni en ningún rol, imagino una cultura laboral y organizacional con la confianza y el conocimiento profesional como pilares fundamentales. La automatización, por más útil que pueda resultar, suele parecer antipática en muchos contextos e imagino que una propuesta tal como lo sería desarrollar algoritmos para automatizar procedimientos, no sería visto de la mejor manera por las personas que forman

²¹ Cultura organizacional. En Wikipedia.

Recuperado desde: https://es.wikipedia.org/wiki/Cultura_organizacional

parte de la institución. Según el Prof. Daniel Serrot²², con el fin de minimizar el impacto del “choque cultural” que la implementación de esto podría traer, así como para ir mejorando la performance de los modelos, lo ideal sería en una primera instancia mantener tanto el funcionamiento actual como al equipo encargado de desarrollar los modelos. Esta primer etapa podría ser útil para detectar desvíos entre ambos sistemas y luego, al alcanzar altos niveles de precisión, efectuar una transición paulatina del sistema actual al automatizado.

En cuanto a aspectos de índole técnico y/o metodológico de los modelos predictivos realizados, hay ciertas implementaciones que podrían mejorar aún más el desempeño de los mismos. El **Modelo I** presenta un desbalance entre las solicitudes autorizadas (~91%) y rechazadas (~9%), que se puede apreciar en la Figura 11. Si bien la robustez en metodología utilizada permitió lidiar con la disparidad entre las dos clases del **Modelo I**, hay técnicas para calibrar el desbalance presente, tales como la asignación de pesos a cada clase, o la utilización de técnicas de oversampling o undersampling que permitan balancear los datos. Considero que a futuro sería oportuno poder desarrollar estos conceptos y evaluar cómo varían los resultados del **Modelo I**.

La métrica para medir la bondad de los modelos predictivos, tal como se mencionó en la sección 5.3, fue AUC. En caso de modelos donde el desbalance es importante, una métrica que suele tener buen desempeño es el área bajo la curva de precision/recall. En el caso de los **Modelos I y II** concretamente utilicé el área bajo la curva ROC, pues por el tipo de problemas que buscan resolver, creí que es importante considerar todas las configuraciones posibles (en precision/recall no se consideran los *True Negative*). Considero que de haber sido otra la temática tratada en el trabajo, ante un conjunto de datos desbalanceado podría haber sido más conveniente el uso de el área bajo la curva de precision/recall.^[47]

La codificación de variables categóricas se hizo a través de One-Hot Encoding, tal como se mencionó en la sección 5.3. Otras posibles formas de trabajar el encoding de variables categóricas podrían haber sido Target-Encoding o Leave-One-Out Encoding. Estas codificaciones continuas podrían, de forma adicional a One-Hot Encoding, mejorar el desempeño del modelo y la utilización de recursos del mismo.

En la sección 5.4 al presentar los resultados de los **Modelos I y II** hago mención a la asimetría en los errores de clasificación que considero que hay. Entiendo que para su abordaje una matriz de costos podría ser una buena herramienta, tomando para cada paciente un umbral de decisión que se adapte de manera de minimizar los costos esperados. Para ello habría que obtener los costos asociados a los diferentes errores o aciertos, lo cual no es sencillo considerando que el costo en una problemática como esta no es meramente económico.

²² Profesor full time de la Escuela de Negocios de la Universidad Torcuato Di Tella. En el Mim & Analytics dicta el curso de “Gestión Organizacional”.

6.3. Palabras finales

El Fondo Nacional de Recursos y la automatización de procesos que se podría lograr a través de ciertos modelos predictivos, sirvieron como caso de estudio a lo largo de este trabajo. La institución analizada es importante para el Uruguay, no tanto por su magnitud sino por su noble finalidad.

La “*Dirección Técnico-Médica*” en general y la “*Unidad de Evaluación*” particularmente, son quienes definen los lineamientos respecto a qué casos recibirán coberturas financieras y cuáles no, siendo decisiones que literalmente impactan en la vida de cada solicitante. El trabajo que realizan muchos de sus miembros, más allá de ser trascendental, puede ser bastante repetitivo. En tal sentido, para la información publicada por parte de esta institución me pareció interesante buscar patrones detrás de ella y poder aplicar técnicas de Machine Learning para intentar predecir el output del proceso evaluatorio (si se autorizará o no, o cuándo se autorizará).

A pesar de las limitaciones que la información utilizada tenía y de tratarse de procesos cuyo output actual se da “caso a caso”, logré mostrar que es factible la modelización de este tipo de problemas con un buen desempeño. Este approach, que se centra en entender al funcionamiento desde el lado de la estadística (no de la medicina), es un primer paso para poder automatizar un proceso. Indudablemente, no es condición suficiente para su implementación, pero acompañado de más y mejor información, equipos que integren conocimientos de diversas áreas y un plan paulatino para su oportuna incorporación, podría transformarse en una herramienta muy importante.

La medicina, con la envergadura y la complejidad que esta disciplina conlleva, es un sector en el cual el analytics para la toma de decisiones va ganando terreno día a día, siendo el caso de estudio del presente trabajo una posible aplicación de esto en un proceso importante dentro de una institución puntual de un pequeño país. En sectores diferentes al de la salud, en que se presentan procesos muy repetitivos y las consecuencias de cada resolución no llegan a ser drásticas, la aplicación de analytics puede ser aún más propicia.

Analizando el proceso de evaluación de solicitudes del FNR, me permito generalizar para otras ramas del ámbito público que la aplicación de analytics y la automatización de procesos correctamente implementada garantiza una mayor capacidad de procesamiento, más transparencia y velocidad, resultando así en una mejor experiencia para los usuarios. En adición a ello, se demandaría un menor número de profesionales dedicado a tareas de índole repetitiva, pudiendo aprovechar los recursos humanos en otros departamentos o en la realización de diferentes tareas o investigaciones. A raíz de este tipo de iniciativas, es probable que la incorporación de nuevos funcionarios sea menor, llevando esto a un ahorro en costos para el estado y, por ende, para cada uno de los ciudadanos que financia al mismo a través de impuestos y tributos.

Más allá que estos conceptos sean estadística y computacionalmente factibles, queda claro que los escollos a superar para poner en marcha nuevas formas de trabajo son importantes.

Es fundamental tener un relevamiento constante y digitalizado de los acontecimientos, que cumplan con las propiedades que caracterizan al Big Data: volumen, velocidad y veracidad.^[48] El fomento de la cooperación y la transparencia, con la finalidad de eliminar los “silos” de información, es otro aspecto necesario para la adecuada aplicación de analytics en la gestión pública. Otro gran desafío es el de reconvertir procesos que lleven mucho tiempo haciéndose igual, capacitar a los funcionarios acostumbrados a trabajar de cierta manera y atraer (por sobre el sector privado) a recursos humanos^[7] capaces de pensar y procesar analíticamente los datos. Por último pero no menos importante, resulta fundamental que los outputs sean imparciales e insesgados, de forma de evitar situaciones injustas.^[49] Esto es más que importante en decisiones trascendentales como lo son las asignaciones de coberturas financieras tratadas en este trabajo, cuyo impacto en la vida de cada solicitante puede ser literalmente “de vida o muerte”.

Más allá de diferencias culturales, estructurales y de magnitud, las “problemáticas” del sector público y privado no son muy distintas. A nivel privado está en auge la aplicación de analytics para optimizar recursos, hacer campañas de marketing dirigidas o predecir eventos desconocidos (p.ej. churn o fraude). En esencia, el sector público atraviesa situaciones muy similares. En mi opinión, las complejidades de la aplicación de analytics a la gestión pública, por muchas que sean, deben ser abordadas. Estoy convencido que, incluso con sus aspectos negativos (como una posible pérdida de privacidad), es realmente significativo el potencial que en el largo plazo el trabajo y la toma de decisiones basada en datos pueden tener a nivel público, tal como está aconteciendo actualmente en el ámbito privado.

7. BIBLIOGRAFÍA

Referencias

1. Marr, B., *How Much Data Do We Create Every Day? The Mind-Blowing Stats Everyone Should Read*, Forbes. Recuperado desde:
<https://www.forbes.com/sites/bernardmarr/2018/05/21/how-much-data-do-we-create-every-day-the-mind-blowing-stats-everyone-should-read/#5b9169c860ba>
2. Fassbender, M., *More data will be generated in 2019 than in the last 5,000 years*, Recuperado desde:
<https://www.outsourcing-pharma.com/Article/2018/12/11/More-data-will-be-generated-in-2019-than-in-the-last-5-000-years>
3. Marr, B. (2017). "Want To Use Big Data? Why Not Start Via Google, Facebook, Amazon, (Etc.)". Forbes. Extraído desde:
<https://www.forbes.com/sites/bernardmarr/2017/08/14/want-to-use-big-data-why-not-start-via-google-facebook-amazon-etc/#3d2c7c0b3d5d>
4. Brown, B., Chui, M. & Manyika, J. (2011). Are you ready for the era of `big data`? *McKinsey Quarterly*. Recuperado desde:
<https://www.mckinsey.com/business-functions/strategy-and-corporate-finance/our-insights/are-you-ready-for-the-era-of-big-data#>
5. Kim, G., Trimi, S., Chung, J. (2014). Big-Data Applications in the Government Sector. *Communications of the ACM*, 57 (3). Recuperado desde:
https://www.researchgate.net/publication/260865566_Big_Data_Applications_in_the_Government_Sector_A_Comparative_Analysis_among_Leading_Countries
6. Gravano, A., Navajas J. (Abril 2020). *Conversaciones Ditellianas: Coronavirus, Sociedad, Economía y Negocios*. "Pandemia, inteligencia artificial y aceleración digital". [Webinar]. Escuela de Negocios, Universidad Torcuato Di Tella. Recuperado desde: <https://www.youtube.com/watch?v=TFkldd7iwTg>
7. Montane, M., Vázquez Brust, A. (Abril 2020). *Charlas de Políticas Públicas*. "¿Hasta dónde seguir los rastros digitales? Datos privados e interés público en tiempos de pandemia". [Webinar]. Escuela de Gobierno, Universidad Torcuato Di Tella. Recuperado desde: https://www.youtube.com/watch?v=7Jz_xziRC0o
8. Valentino DeVries, J. (13 Abr. 2019). "Tracking Phones, Google Is a Dragnet for the Police". *New York Times*, Nueva York, Estados Unidos. Recuperado desde:
<https://www.nytimes.com/interactive/2019/04/13/us/google-location-tracking-police.html>

9. TED. (2018). Prukalpa Sankar: *How Big Data Can Influence Decisions That Actually Matter*. Recuperado desde: <https://www.youtube.com/watch?v=C6WKt6fJiso&feature=youtu.be>
10. (24 Nov. 2017). *Cómo el 'big data' ayuda a luchar contra el fraude fiscal*. BBVA, España. Recuperado desde: <https://www.bbva.com/es/big-data-ayuda-luchar-fraude-fiscal/>
11. Loaiza, C. (6 Jun. 2020). *Big tax data: ¿más o menos igualdad?*. Diario El Observador, Montevideo, Uruguay. Recuperado desde: <https://www.observador.com.uy/nota/big-tax-data-mas-o-menos-igualdad--2020665024>
12. Jetzek, T., Avital, M., Bjorn-Andersen, N. (2013). Data-Driven Innovation through Open Government Data. *Journal of Theoretical and Applied Electronic Commerce Research*, 9. Recuperado desde: https://scielo.conicyt.cl/scielo.php?pid=S0718-18762014000200008&script=sci_arttext
13. TED. (2015). Justin Graside: *Construyamos la Democracia Digital*. Recuperado desde: https://www.youtube.com/watch?v=C-PG06_Ozlo
14. Partido Digital del Uruguay. Recuperado desde: <https://partidodigital.org.uy/>
15. Partido de la Red. Recuperado desde: <http://partidodelared.org/>
16. AGESIC (Agencia del Gobierno Electrónico y Sociedad de la Información y el Conocimiento). *Uruguay, Gobierno Digital y D9*. Recuperado desde: <https://www.gub.uy/agencia-gobierno-electronico-sociedad-informacion-conocimiento/uruguay-gobierno-digital-d9>
17. Raghupathi, W., Raghupathi, V. (2014). Big data analytics in healthcare: promise and potential. *Health Information Science and Systems*, 2 (3). Recuperado desde: <https://link.springer.com/content/pdf/10.1186/2047-2501-2-3.pdf>
18. Archenaa, J., Mary Anita, E.A. (2015). A Survey of Big Data Analytics in Healthcare and Government. *Procedia Computer Science - Elsevier B.V.*, 50. Recuperado desde: <https://www.sciencedirect.com/science/article/pii/S1877050915005220>
19. COVID-19 data, tools and findings from the Kaggle community <https://www.kaggle.com/covid-19-contributions>
20. Dandekar, R., & Barbastathis, G. (2020). *Quantifying the effect of quarantine control in Covid-19 infectious spread using machine learning*.

Recuperado desde: <https://doi.org/10.1101/2020.04.03.20052084>

21. Watson, I. & Jeong, S. (28 Feb. 2020). "Coronavirus mobile apps are surging in popularity in South Korea". CNN Business, Seúl, Corea del Sur. Recuperado desde: <https://edition.cnn.com/2020/02/28/tech/korea-coronavirus-tracking-apps/index.html>
22. Kim, M. (6 Mar. 2020). "South Korea is watching quarantined citizens with a smartphone app". MIT Technology Review. Recuperado desde: <https://www.technologyreview.com/2020/03/06/905459/coronavirus-south-korea-smartphone-app-quarantine/>
23. (25 Dic. 2019). "Tras propuesta de Vázquez: cómo funcionan el FNR y el acceso a medicamentos caros". Diario El Observador, Montevideo, Uruguay. <https://www.observador.com.uy/nota/tras-propuesta-de-vazquez-como-funcionan-el-fnr-y-el-acceso-a-medicamentos-caros-20191224144825>
24. Fondo Nacional de Recursos (2019). *Proceso de incorporación de nuevas prestaciones al Fondo Nacional de Recursos*. Recuperado desde: <https://www.youtube.com/watch?v=MPGfPyJMPSY>
25. Fondo Nacional de Recursos (2019). *Video Institucional - 2018*. Recuperado desde: https://www.youtube.com/watch?v=kQe8mNIA_U4
26. Designación de nuevas autoridades (2020). Recuperado desde: http://www.fnr.gub.uy/noticia_autoridades_2020
27. (26 Mar. 2020) "María Ana Porcelli será la nueva directora general del Fondo Nacional de Recursos". Diario El Observador, Montevideo, Uruguay. <https://www.observador.com.uy/nota/maria-ana-porcelli-sera-la-nueva-directora-general-del-fondo-nacional-de-recursos-202032611515>
28. Ateneos. Recuperado desde: <http://www.fnr.gub.uy/ateneos>
29. Mintzberg, H. (1993). *Structure in fives: Designing effective organizations*. Prentice-Hall, Inc.
30. Mariella Lazo, A. (2013). La Esperanza de Vida en Uruguay a lo largo de los siglos XIX, XX, XXI y sus probables valores futuros. *Banco de Previsión Social (BPS)*. Recuperado desde: https://www.bps.gub.uy/bps/file/6826/1/07_esperanza_vida_uy_siglos_xix_xx_xxi.pdf
31. Anexo: Departamentos de Uruguay. En Wikipedia. Recuperado desde: https://es.wikipedia.org/wiki/Anexo:Departamentos_de_Uruguay

32. Alpaydin, E. (2014). *Introduction to Machine Learning*, 3 edition. Adaptive Computation and Machine Learning. MIT Press, Cambridge, MA.
33. *XGBoost Documentation*. Recuperado de: <https://xgboost.readthedocs.io/>
34. Chen, T. & Guestrin, C. (2016). *Xgboost: A scalable tree boosting system*. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '16, page 785–794, New York, NY, USA. Association for Computing Machinery.
Recuperado desde: <https://dl.acm.org/doi/abs/10.1145/2939672.2939785>
35. Caponetto, G. (2019). “*Random Search vs Grid Search for hyperparameter optimization*”. Recuperado desde: <https://towardsdatascience.com/random-search-vs-grid-search-for-hyperparameter-optimization-345e1422899d>
36. “*Interpretable Machine Learning*”, Sección 5 (Model-Agnostic Methods) <https://christophm.github.io/interpretable-ml-book/agnostic.html>
37. Gálvez, R., Gauder, L., Luque, J. & Gravano, A. (2020). "A unifying framework for modeling acoustic/prosodic entrainment: definition and evaluation on two large corpora".
38. Kahneman, D., & Tversky, A. (1990). “Prospect theory: An analysis of decision under risk”. Recuperado desde: https://doi.org/10.1142/9789814417358_0006
39. Liu, J., Bier, E., Wilson, A., Guerra-Gomez, J. A., Honda, T., Sricharan, K., Gilpin, L., & Davies, D. (2016). Graph Analysis for Detecting Fraud, Waste, and Abuse in Healthcare Data. *AI Magazine*, 37(2), 33-46.
Recuperado desde: <https://doi.org/10.1609/aimag.v37i2.2630>
40. Murdoch, W., Singh, C., Kumbier, K., Abbasi-Asi, R. & Yu, B. (2019). Definitions, methods, and applications in interpretable machine learning. *National Academy of Sciences*. Recuperado desde: <https://www.pnas.org/content/116/44/22071>
41. Hosanagar, K. (2019). “*Who Made That Decision: You or an Algorithm?*”. Knowledge@Wharton [Podcast], Wharton University of Pennsylvania. Recuperado de: <https://knowledge.wharton.upenn.edu/article/algorithms-decision-making/>
42. TED. (2017). Osonde Osoba: *Making AI fair*. Recuperado desde: https://www.youtube.com/watch?v=4l_LZ5NclBI&feature=youtu.be
43. TED. (2017). Josh Lovejoy: *Fair is not the default: The myth of neutral AI*. Recuperado desde: <https://www.youtube.com/watch?v=NF98WCdvR6U&feature=youtu.be>

44. Crash course. (Dic. 2019). Algorithmic Bias and Fairness: Crash Course AI #18.
Recuperado desde:
https://www.youtube.com/watch?v=gV0_raKR2UQ&feature=youtu.be
45. Dilhac, M., Mai, V., Mörch, C., Noiseau, P. & Voarino, N. (2020). *Pensar la inteligencia artificial responsable: una guía de deliberación*. UNESCO. Recuperado desde: https://opendialogueonai.com/wp-content/uploads/2020/07/ES_Delib.pdf
46. Rose, R., *Defining analytics: a conceptual framework*, *Informs*. Recuperado desde: <https://www.informs.org/ORMS-Today/Public-Articles/June-Volume-43-Number-3/Defining-analytics-a-conceptual-framework>
47. Davis, J. & Goadrich, M. (2006). The relationship between Precision-Recall and ROC curves. Association for Computing Machinery. Recuperado desde: <https://dl.acm.org/doi/10.1145/1143844.1143874>
48. Wilder-James, E. (2012). *What is Big Data?*.
Recuperado desde: <https://www.oreilly.com/radar/what-is-big-data/>
49. Algorithmic Justice League.
<https://www.ajlunited.org/>

Marco Jurídico (Fondo Nacional de Recursos)

Ley N° 14.897 de mayo 1979

(<https://legislativo.parlamento.gub.uy/temporales/leytemp7681536.htm>)

Ley N° 16.343 de diciembre 1992

(<https://legislativo.parlamento.gub.uy/temporales/leytemp5165000.htm>)

Ley N° 17.930 de diciembre 2005

(<https://legislativo.parlamento.gub.uy/temporales/leytemp791093.htm>)

Ley N° 18.381 de noviembre 2008

(<https://www.impo.com.uy/bases/leyes/18381-2008>)

Ley N° 18.834 de octubre 2011

(<https://legislativo.parlamento.gub.uy/temporales/leytemp1723923.htm>)

Ley N° 18.996 de octubre 2012

(<https://legislativo.parlamento.gub.uy/temporales/leytemp7290041.htm>)

Ley N° 19.167 de noviembre 2013

(<https://legislativo.parlamento.gub.uy/temporales/leytemp9266066.htm>)

Ley N° 19.355 de diciembre 2015

(<https://legislativo.parlamento.gub.uy/temporales/leytemp2348892.htm>)

Ordenanza del N° 740 de Junio 2019

(<https://www.gub.uy/ministerio-salud-publica/institucional/normativa/ordenanza-740019>)

Otras fuentes de información

<http://www.fnr.gub.uy/estadisticas>

<https://catalogodatos.gub.uy/organization/fondo-nacional-de-recursos>

James, G., Witten, D., Hastie, T. & Tibshirani, R., (2017), "*An Introduction to Statistical Learning with Applications in R*", Springer. Nueva York, Estados Unidos.

Zheng, A. & Casari, A. (2018). "*Feature Engineering for Machine Learning*", O'Reilly Media. Estados Unidos

Entrevistas y conversaciones con conocedores del entorno público, la institución analizada, las organizaciones y sus estructuras, la ciencia de datos y la medicina.

8. ANEXOS

Anexo I

Al día de hoy las prestaciones que cubre el Fondo Nacional de Recursos son las siguientes:

Técnicas (Actos Médicos)²³

Prestaciones Traumatológicas

Artroplastia de Cadera en Adultos
Artroplastia de Cadera por Fractura
Artroplastia de Rodilla

Prestaciones Cardiovasculares

Cateterismo Cardíaco Derecho
Cateterismo Cardíaco Infantil
Cateterismo Terapéutico
Cirugía Cardíaca
Cirugía Cardíaca Infantil
Implante de Cardiodesfibrilador
Marcapasos
Procedimiento Cardiológico Intervencionista

Prestaciones Nefrológicas

Hemodiálisis
Diálisis Peritoneal Crónica Ambulatoria

Trasplantes

Cardíaco
Hepático
Médula Ósea
Renal
Hepático pediátrico
Pulmonar

Otras prestaciones

Implante Coclear
PET SCAN
Reproducción Asistida de Alta Complejidad
Tromboendarterectomía
Retinoblastoma Congénito
Tratamiento de Quemados
Epilepsia Refractaria

²³ Extraído de: http://www.fnr.gub.uy/tecnicas_beneficiarios

Tratamientos con Medicamentos²⁴

Hematológicos

Aplasia Medular (Eltrombopag)
 Leucemia Mieloide Crónica y Leucemia Aguda Linfoblástica PHI+ (Inhibidores de Tirosinkinasa)
 Leucemia linfoide crónica (Bendamustina, Ibrutinib, Rituximab)
 Linfomas no Hodgkin (Bendamustina, Ibrutinib, Rituximab)
 Mieloma Múltiple (Bortezomib, Lenalidomida)
 Síndromes Mielodisplásicos y Leucemia Aguda Mieloblástica (Azacitidina)
 Tricoleucemia (Cladribine)
 Trombocitopenia Inmune Primaria (Eltrombopag)
 Tumores estromales gastrointestinales (GIST) (Inhibidores de Tirosinkinasa)

Infectológicos

Virus Sincicial Respiratorio (Palivizumab)
 Virus de la Hepatitis C (Ribavirina, Daclatasvir/Sofosbuvir)
 Citomegalovirus en Trasplantes (Valganciclovir)
 Virus de la Inmunodeficiencia Humana (Darunavir, Etravirine)

Neumológicos

Asma Alérgico Severo (Omalizumab)
 Fibrosis Quística (Tobramicina, Alfa-dornasa)
 Fibrosis Pulmonar Idiopática (Pirfenidona)
 Hipertensión Arterial Pulmonar (Bosentan, Iloprost)

Neurológicos

Esclerosis Múltiple (Interferón Beta, Acetato de Glatiramer, Fingolimod)
 Espasticidad y Distonías (Toxina Botulínica)

Oncológicos

Cáncer de Hígado (Sorafenib, Regorafenib)
 Cáncer de Mama (Trastuzumab, Pertuzumab, T-DM1, Lapatinib, Fulvestrant)
 Cáncer de Riñón (Sunitinib, Sorafenib, Pazopanib)
 Cáncer Colo- Rectal (Bevacizumab)
 Cáncer de Pulmón (Erlotinib, Gefitinib, Pembrolizumab)
 Cáncer de Próstata (Abiraterona)
 Melanoma Cutáneo (Vemurafenib y Cobimetinib, Pembrolizumab)
 Tumores SNC (Temozolamida)

²⁴ Extraído de: http://www.fnr.gub.uy/tratamientos_medicamentos

Reumatológicos

Artritis Idiopática Juvenil (Adalimumab, Etanercept, Golimumab, Infliximab, Tocilizumab)

Artritis Reumatoidea (Adalimumab, Etanercept, Golimumab, Infliximab, Rituximab, Tocilizumab, Tofacitinib, Upadacitinib)

Espondiloartritis (Adalimumab, Etanercept, Golimumab, Infliximab)

Otras

Cobertura Farmacológica- Tabaquismo

Colitis Ulcerosa (Adalimumab, Infliximab, Golimumab)

Diabetes (Insulina Glargina, Insulina Detemir)

Enfermedad de Crohn (Adalimumab, Infliximab)

Infarto Agudo de Miocardio (Fibrinolíticos)

Psoriasis Severa (Adalimumab)

Trasplante Renal (Tacrolimus, Everolimus)

Vasculitis ANCA asociadas (Rituximab)

Dispositivos²⁵

Dispositivo de Endoprótesis

Bomba de Insulina

²⁵ Extraído de: <http://www.fnr.gub.uy/dispositivos>

Anexo II

Para lograr ese Dataset “unificado” he debido tomar ciertos supuestos y criterios que a continuación detallaré.

Actos Médicos

El trabajo realizado para el armado de este nuevo Dataset consistió en buscar el número de paciente en el conjunto de datos de Solicitudes de Prestaciones y en el conjunto de datos del detalle de Gastos por actos médicos.

En los registros no autorizados, se asignó como importe (en la variable “Act.Med_NoAut”) al importe promedio de los casos autorizados por concepto de cada prestación. Por ejemplo, en 2017 el gasto promedio por cirugías cardíacas de adultos autorizadas fue de \$U483.922; ese mismo fue el importe que adjudiqué a esas mismas cirugías que no fueron autorizadas.

La única prestación que no tuvo casos autorizados y no se pudo aplicar lo antes mencionado fue a “*Trasplante de pulmón - Modulo pre*”; al no tener importe asignado, sus 12 registros fueron excluidos del Dataset unificado.

Durante la asignación del importe para cada paciente (por actos médicos), se han presentado algunas situaciones que a continuación describo y ejemplifico.

1. Registros duplicados:

	Prestación (acto médico)	Fecha Aut.	Estado	Fecha Aut.	Paciente		Otros	Importe
2017	PCI-ATCP	5/7/17	AUTORIZADO	6/7/17	361686	89 F	...	\$ 102.884
2017	PCI-ATCP	6/7/17	AUTORIZADO	6/7/17	361686	89 F	...	\$ 102.884

Ante estos casos, lo que hice fue solamente dejar uno de los registros.

2. Paciente duplicado, con un registro autorizado y otro no autorizado.

Importe > \$0:

	Prestación (acto médico)	Fecha Aut.	Estado	Fecha Aut.	Paciente		Otros	Importe
2017	Cirugia cardiaca adultos	10/2/17	AUTORIZADO	10/2/17	355609	73 M	...	\$ 598.549
2017	Cirugia cardiaca adultos	15/5/17	NO AUTORIZADO		355609	74 M	...	\$ 0

Ante estos casos, mantuve el registro autorizado y eliminé el no autorizado.

3. Paciente duplicado, con un registro autorizado y otro no autorizado.

Importe = \$0:

	Prestación (acto médico)	Fecha Aut.	Estado	Fecha Aut.	Paciente		Otros	Importe
2017	PCI-ATCP	2/2/17	NO AUTORIZADO		354279	77 F	...	\$ 0
2017	PCI-ATCP	2/2/17	AUTORIZADO	7/3/17	354279	77 F	...	\$ 0

Ante estos casos, mantuve el registro no autorizado y eliminé el autorizado.

4. Registro único de paciente autorizado, sin importe:

	Prestación (acto médico)	Fecha Aut.	Estado	Fecha Aut.	Paciente		Otros	Importe
2017	Cardiodesfibrilador - Implante	3/5/17	AUTORIZADO	16/5/17	357158	43	M ...	\$ 0

Ante estos casos, eliminé el registro. El desbalance entre casos autorizados y no autorizados es importante de igual manera.

Aplicando los criterios explicados, las solicitudes de actos médicos tendrían 17.111 registros en 2016 y 17.943 en 2017.

Tratamiento con Medicamentos

Los criterios tomados para este tipo de prestaciones fueron idénticos que para los actos médicos.

Un detalle no menor, tanto para la limpieza de datos de actos médicos como de tratamientos con medicamentos, es que únicamente permanecieron aquellas prestaciones que fueron solicitadas y autorizadas el mismo año. La falta de información del 2018 en adelante imposibilitaron que algunas solicitudes hechas a fines de 2017 tengan un gasto asociado, por lo que de haber incluido las solicitudes realizadas en 2016 que fueron autorizadas en 2017 el dataset resultante no mantendría la relación original entre las prestaciones de los años 2016/17.

Algunos tratamientos con medicamentos tenían muchas solicitudes autorizadas pero no tenían ningún gasto asociado en el desglose, por lo que fueron descartados de este análisis; los mismos fueron: *Tratamiento de Hepatitis C*, *Tratamiento de VIH*, *Tratamiento del IAM* y *Tratamiento con ARV*.

La principal diferencia asumida entre los actos médicos y los tratamientos con medicamentos es que en este último varios pacientes recibieron más de una (no) autorización de un medicamento del mismo tipo en el período de un año, a diferencia de los actos médicos que no se repiten para un mismo paciente en el correr de un año (sí se puede hacer p.ej. un cateterismo y una cirugía cardíaca, pero no se le autorizarán dos cateterismos en un mismo año).

Por ejemplo:

	Prestación (Medicamento)	Fecha Sol.	Estado	Fecha Aut.	Paciente	Edad	Sexo	Importe (\$U)
2017	Tratamiento de Linfomas no Hodgkin	13/2/17	AUTORIZADO	15/2/17	355701	53	F	\$ 113.166
2017	Tratamiento de Linfomas no Hodgkin	29/8/17	AUTORIZADO	30/8/17	355701	54	F	\$ 61.402

Ante este tipo de casos, ambos registros permanecieron en el Dataset.

Las solicitudes de tratamientos con medicamentos, luego de aplicados estos criterios, fueron 2.414 en 2016 y 2.547 en 2017.

Anexo III

El tiempo promedio de demora entre la autorización de un “*PCI-Cateterismo izq.adultos*” fue calculado como se indica debajo:

	Cantidad de Realizaciones, por IMAE	% de la muestra	Media*	Ponderación de demoras
Asociación Española	620	16,4%	13	2,13
Casa de Galicia	554	14,6%	13	1,90
Hospital de Clínicas	135	3,6%	15	0,53
Instituto Nacional de Cirugía Cardíaca	812	21,4%	9	1,93
Instituto de Cardiología Integral	468	12,4%	11	1,36
Sanatorio Americano	1.175	31,0%	21	6,51
Sanatorio Americano - Salto	24	0,6%	13	0,08
	<u>3.788</u>			<u>14,45</u>

* Extraído de: http://www.fnr.gub.uy/tiempo_espera_am para el período ene-2016 hasta dic-2017.

Las 3.788 realizaciones del procedimiento por parte de estos *IMAE* (sobre el total de 8.676 autorizaciones en el período) permitieron ponderar la demora de cada uno de los Institutos aquí reflejados. Al asignar la demora de cada *IMAE* de acuerdo a su “peso”, llegué a una demora promedio de 14,45 días entre la autorización de un “*PCI-Cateterismo izq.adultos*” y su realización, para esta muestra.

Anexo IV

GLOSARIO DE TÉRMINOS, CONCEPTOS Y ABREVIATURAS²⁶

ACTOS MÉDICOS: Son los procedimientos o técnicas de medicina altamente especializada que cubre financieramente el Fondo Nacional de Recursos.

ACTOS MÉDICOS AUTORIZADOS: Son los procedimientos evaluados y autorizados por el equipo médico del FNR en el año correspondiente al informe estadístico.

ACTOS MÉDICOS REALIZADOS: Son los procedimientos autorizados por el FNR y realizados por el IMAE en el año correspondiente al informe estadístico.

ÁREA DE PRESTACIÓN: Es la forma de agrupar las prestaciones que cubre financieramente el FNR. Se agrupan en diferentes áreas según la especialización médica o el tipo de prestación:

- ACTOS (actos de cardiología, nefrología, trasplantes, traumatología),
- TRATAMIENTOS CON MEDICAMENTOS (tratamientos de cardiología, endocrinología, gastroenterología, infectología, inmunología, neumología, neurología, oncología, reumatología)
- DISPOSITIVOS (para implante coclear y endoprótesis)
- PROGRAMAS (Programa de prevención primaria de la insuficiencia cardíaca)
- OTRA ÁREA (Se incluyen otras prestaciones como Grandes quemados, Inicio de tratamiento de Reproducción asistida, Tomografía por emisión de positrones)

ARV: Antirretroviral

ATCP: Angioplastia Transluminal Coronaria Percutánea. Procedimiento de revascularización miocárdica.

CARDIODESFIBRILADOR-IMPLANTE: El cardiodesfibrilador es un dispositivo implantable destinado al tratamiento de personas que presentan un trastorno grave del ritmo cardíaco.

CATETERISMO DERECHO ADULTOS: Es un procedimiento diagnóstico que consiste en la medición, registro y análisis de las presiones de la circulación pulmonar, cavidades cardíacas derechas y vena cava, y del gasto cardíaco.

CATETERISMO DIAGNÓSTICO INFANTIL: Es un procedimiento diagnóstico mediante cateterismo cardíaco aplicado a las cardiopatías congénitas en niños.

²⁶ Extraído de: <http://www.fnr.gub.uy/sites/default/files/estadisticas/glosario.pdf>

CATETERISMO TERAPÉUTICO: Es un procedimiento terapéutico mediante cateterismo destinado a corregir o disminuir las consecuencias que originan alguna malformación del corazón.

CIRUGÍA CARDIACA ADULTO: La cirugía cardíaca de adulto es una intervención quirúrgica destinada a reparar lesiones del corazón en pacientes mayores de 18 años.

CIRUGÍA CARDIACA INFANTIL: La cirugía cardíaca infantil es una intervención quirúrgica destinada a reparar lesiones del corazón en pacientes menores de 18 años.

CMV: Citomegalovirus

DEPARTAMENTO DE RESIDENCIA: Es el departamento donde vive el paciente. El que figura en el formulario de inicio de una prestación.

DEPARTAMENTO DEL PRESTADOR: Corresponde al departamento donde está ubicado el prestador de salud

DPCA: Diálisis peritoneal crónica ambulatoria. Es una técnica sustitutiva de la función renal normal ambulatoria.

FECHA DE AUTORIZACIÓN: Es la fecha en que el equipo médico del FNR autoriza la cobertura financiera de una prestación.

FECHA DE REALIZACIÓN: Es la fecha en que efectivamente el paciente se realizó el acto médico en el IMAE.

FECHA DE SOLICITUD: Es la fecha en el que el trámite ingresa al FNR.

GIST: Tumor del Estroma Gastrointestinal

GRANDES QUEMADOS: Tratamiento a personas que padecen quemaduras severas como consecuencias de accidentes y requieren una atención especializada en virtud de los riesgos de vida y de secuelas que presentan.

HEMODIÁLISIS: Técnica sustitutiva de la función renal normal, que requiere la conexión periódica del paciente a un equipo que realiza la función de filtración y depuración de la sangre.

HTAP: Hipertensión Arterial Pulmonar

IAM: Infarto Agudo de Miocardio

IMAE: Instituto de Medicina Altamente Especializada. Son prestadores públicos o privados, habilitados por el Ministerio de Salud Pública y autorizados por el FNR. En estos institutos se realizan los actos médicos autorizados por el FNR.

INICIO DE TRATAMIENTOS CON MEDICAMENTOS: Es el comienzo de la cobertura del tratamiento con medicamentos.

IRC: Insuficiencia Renal Crónica

LLC: Leucemia Linfoide Crónica

LMC: Leucemia Mieloide Crónica

MARCAPASOS-IMPLANTE: El Marcapasos es un dispositivo implantable destinado al tratamiento de personas que presentan trastornos de la conducción cardíaca.

ORIGEN DEL PRESTADOR: Es la agrupación de los prestadores de salud según su origen. Se agrupan en públicos o privados.

PACIENTE ENMASCARADO: Es un número de identificación de cada paciente del FNR. Está enmascarado para mantener anónima la identidad de los pacientes.

PACIENTES PREVALENTES: Total de pacientes tratados en el mes de diciembre de cada año

PACIENTES TRATADOS: Total de pacientes diferentes tratados durante el año

PCI: Procedimiento Coronario Intervencionista.

PCI-CATETERISMO IZQ. ADULTOS: Procedimiento diagnóstico mediante cateterismo cardíaco aplicado al estudio de las lesiones del corazón en pacientes mayores de 18 años.

PCI- ATCP CON CATETERISMO IZQ: ATCP con Cateterismo diagnóstico izq. realizado en la misma internación.

PCI- ACTP: ATCP realizada en forma diferida al cateterismo cardíaco izq.

PRESTACIONES: Son los procedimientos de medicina altamente especializada (actos médicos), tratamientos con medicamentos de alto precio, programas, dispositivos, estudios y otros tratamientos que cubre financieramente el Fondo Nacional de Recursos (FNR).

PRESTADOR DE SALUD: Es la institución de salud de donde es afiliada o beneficiaria la persona.

PRÓTESIS DE CADERA-ARTROSIS: Implante de dispositivo sustitutivo de la articulación de la cadera debido a artrosis de cadera.

PRÓTESIS DE CADERA-FRACTURA: Implante de dispositivo sustitutivo de la articulación de la cadera debido a fractura de la cadera.

PRÓTESIS DE CADERA-RECAMBIO: Recambio de dispositivo sustitutivo de la articulación de la cadera.

PRÓTESIS DE RODILLA-IMPLANTE: Implante de dispositivo de sustitución de la articulación de la rodilla.

PRÓTESIS DE RODILLA-RECAMBIO: Recambio de dispositivo de sustitución de la articulación de la rodilla.

RHA: Tratamiento de la infertilidad humana mediante técnicas de reproducción asistida de alta complejidad.

SEXO DEL PACIENTE: Es el sexo biológico adjudicado en el nacimiento de la persona.
F = Femenino. M= Masculino. U= Indefinido

SNC: Sistema Nervioso Central

TASA DE USO DE LAS PRESTACIONES QUE CUBRE EL FNR POR DEPARTAMENTO:
Se utiliza para el cálculo de esta tasa la población proyectada por INE a junio de cada año.
Fórmula = $\frac{\text{Cantidad de prestaciones autorizadas por departamento en el año} * 100000}{\text{Total de habitantes para el departamento proyectado para el año}}$

TASA DE USO DE LAS PRESTACIONES QUE CUBRE EL FNR POR PRESTADOR DE SALUD PRIVADO:
Fórmula = $\frac{\text{Cant. de prestaciones autoriz. por prestador de salud privado en el año} * 100000}{\text{Nº promedio de usuarios de prestadores de salud privados en el año}}$

TASA DE USO DE LAS PRESTACIONES QUE CUBRE EL FNR POR PRESTADOR DE SALUD PÚBLICO:
Fórmula = $\frac{\text{Cant. de prestaciones autoriz. por prestador de salud públicos en el año} * 100000}{\text{Nº promedio de usuarios de prestadores de salud públicos en el año}}$

TPH-ALOGÉNICO: Trasplante de Progenitores Hematopoyéticos con donante de otra persona.

TPH-AUTÓLOGO: Trasplante de Progenitores Hematopoyéticos de la propia persona.

TIPO DE PRESTACIÓN: Las prestaciones que cubre financieramente el FNR se presentan en las estadísticas agrupadas en tres tipos: Actos Médicos, Tratamientos con Medicamentos y Otras prestaciones.

TIPO DE PRESTADOR: Es una agrupación de los prestadores de salud según el tipo de prestador:

- ASSE: Administración de Servicios de Salud del Estado, el paciente se puede registrar asociado a un hospital (Centro departamental), policlínica o centro auxiliar.
- IAMC : Instituciones de Asistencia Médica Colectiva
- SEGURO PRIVADO: Es el Seguro Privado al que está afiliado el paciente que está habilitado a recibir medicación del FNR, en tanto está afiliado por FONASA o paga la cuota del FNR a través de su seguro individual.
- OTRO: Son prestadores cuyos afiliados están habilitados a recibir cobertura del FNR como ANCAP, Banco Hipotecario, BPS, entre otros. También se incluye en esta agrupación la Dirección de Sanidad de las Fuerzas Armadas.

TRASPLANTE CARDIACO: Intervención quirúrgica donde se realiza un trasplante del corazón.

TRASPLANTE CARDIACO-MÓDULO PRE: Evaluación previa a trasplante cardiaco que determina la aptitud del paciente para trasplante.

TRASPLANTE HEPÁTICO: Intervención quirúrgica donde se realiza trasplante de hígado.

TRASPLANTE HEPÁTICO-MÓDULO PRE: Evaluación previa a trasplante hepático que determina la aptitud del paciente para trasplante.

TRASPLANTE RENAL-Cadavérico: Trasplante Renal con donante cadavérico

TRASPLANTE RENAL-Vivo: Trasplante Renal con donante vivo

TRASPLANTE RENOPANCREÁTICO: Trasplante de Riñón y Páncreas

TRATAMIENTOS CON MEDICAMENTOS: Son los tratamientos con medicamentos de alto precio que cubre el Fondo Nacional de Recursos.

TRATAMIENTOS CON MEDICAMENTOS AUTORIZADOS: Son los tratamientos con medicamentos evaluados y autorizados por el equipo médico del FNR en el año correspondiente al informe.

VIH: Virus de la Inmunodeficiencia Humana

VRS: Virus Respiratorio Sincial.

Anexo V

En el presente Anexo se expondrán ciertos datos y gráficos vinculados al conjunto de datos del Fondo Nacional de Recursos, de forma más detallada que los reflejados en el análisis exploratorio del documento.

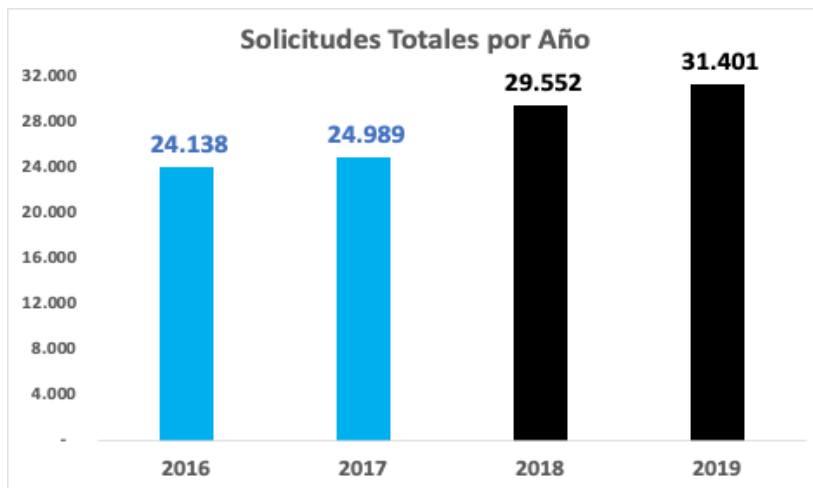
Análisis por Estado de Solicitud

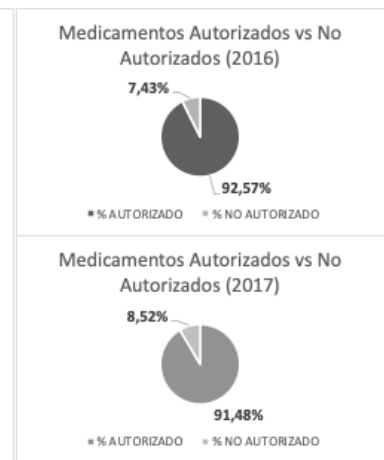
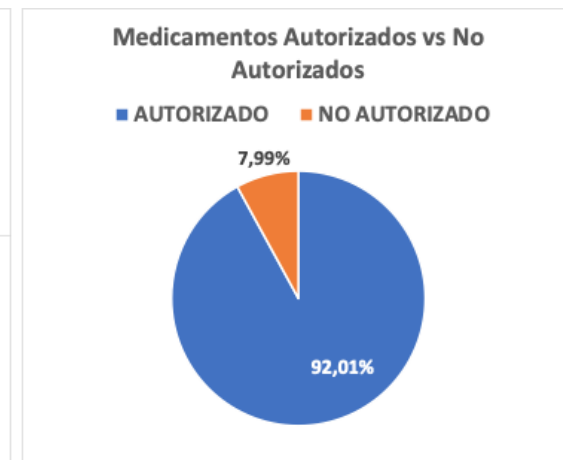
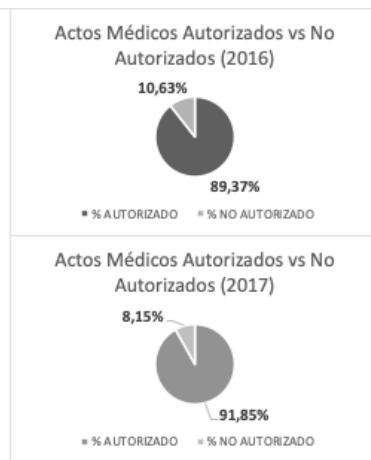
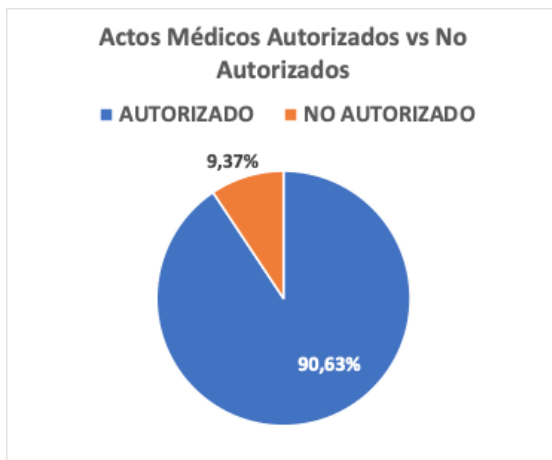
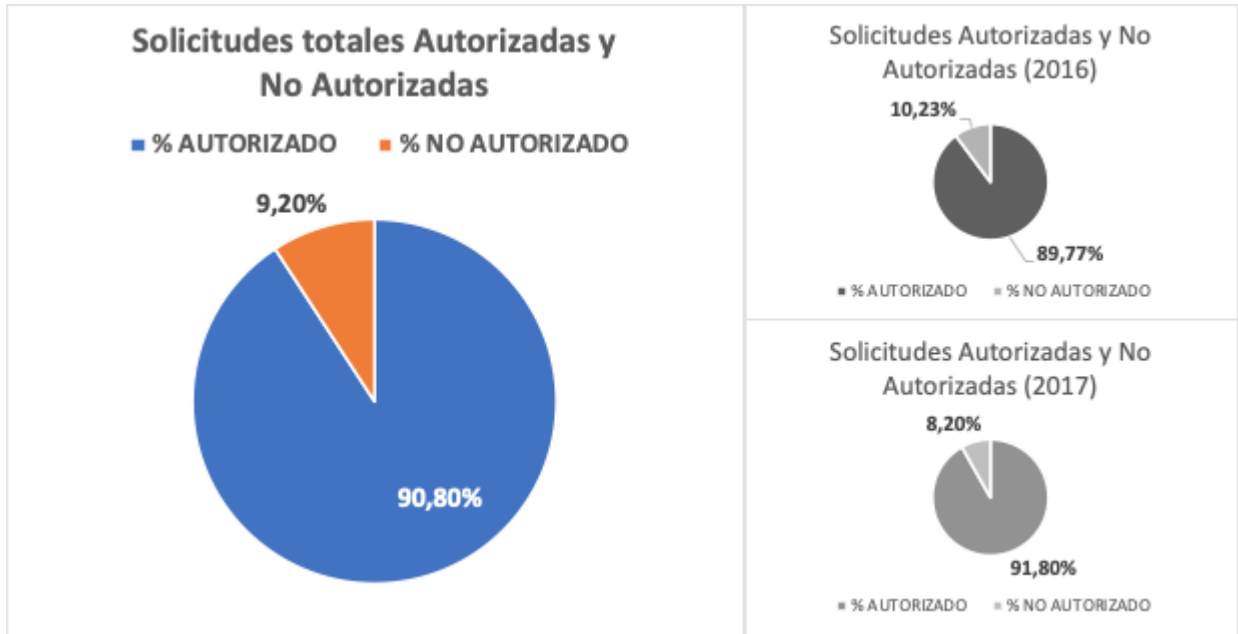
	AUTORIZADO	NO AUTORIZADO	Total general	% AUTORIZADO	% NO AUTORIZADO
2016	21.668	2.470	24.138	89,77%	10,23%
Acto Médico	18.865	2.245	21.110	89,37%	10,63%
Tratamiento con medicamentos	2.803	225	3.028	92,57%	7,43%
2017	22.941	2.048	24.989	91,80%	8,20%
Acto Médico	19.944	1.769	21.713	91,85%	8,15%
Tratamiento con medicamentos	2.997	279	3.276	91,48%	8,52%
Total general	44.609	4.518	49.127	90,80%	9,20%

Solicitudes por Año	
2016	24.138
2017	24.989
2018 *	29.552
2019 *	31.401

*Extraído de:
<http://www.fnr.gub.uy/estadisticas>

División por Tipo de Prestación		AUTORIZADO	NO AUTORIZADO	Total general
Acto Médico	Cantidad	38.809	4.014	42.823
	%	90,63%	9,37%	
Tratamiento con medicamentos	Cantidad	5.800	504	6.304
	%	92,01%	7,99%	
Total general		44.609	4.518	49.127



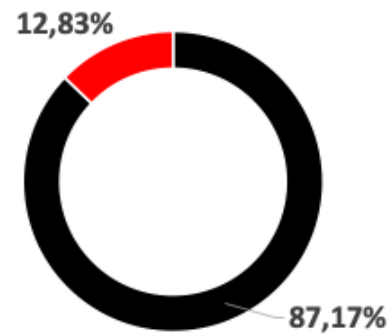


Análisis por Tipo de Prestación

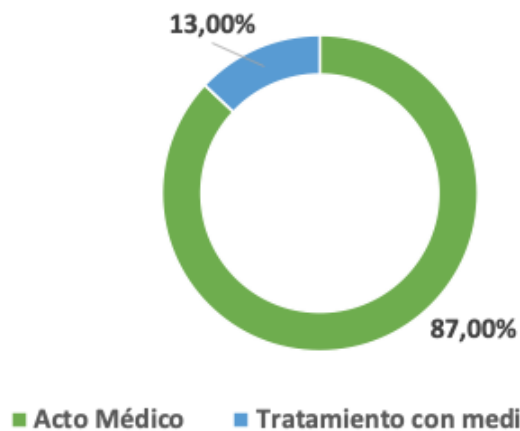
División por Estado de Solicitud	AUTORIZADO		NO AUTORIZADO		Total general	
	Cantidad	%	Cantidad	%	Cantidad	%
Acto Médico	38.809	87,00%	4.014	88,84%	42.823	87,17%
Tratamiento con medicamentos	5.800	13,00%	504	11,16%	6.304	12,83%
Total general	44.609		4.518		49.127	

Solicitudes totales, por tipo de prestación

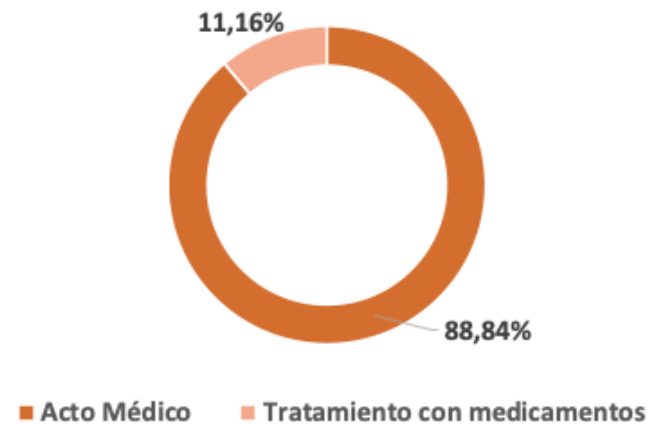
■ Acto Médico ■ Tratamiento con medicamentos



Solicitudes Autorizadas, por tipo de prestación



Solicitudes No Autorizadas, por tipo de prestación



	importe Total		Importe Promedio
	Total	%	
Acto Médico	\$ 10.119.590.924	84,08%	\$ 210.505
Tratamiento con medicamentos	\$ 1.916.470.473	15,92%	\$ 77.411
Total general	\$ 12.036.061.397		

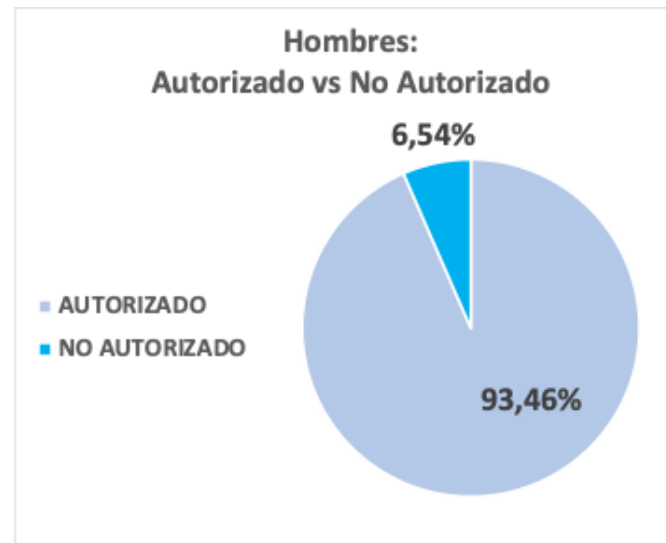
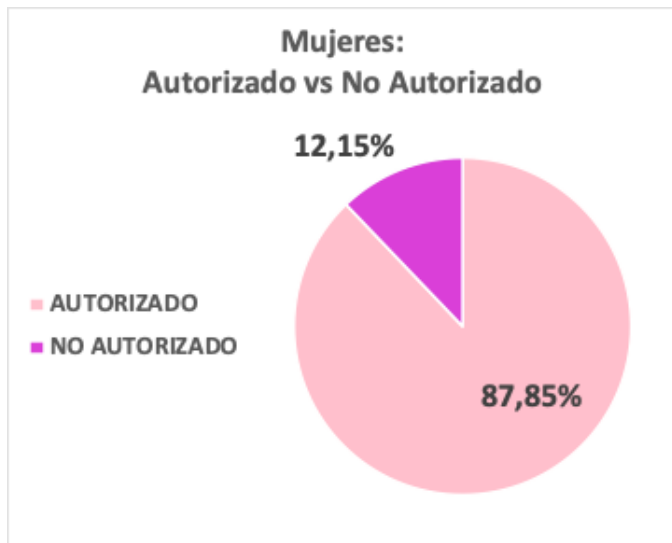


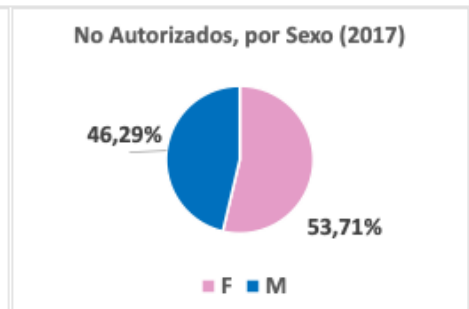
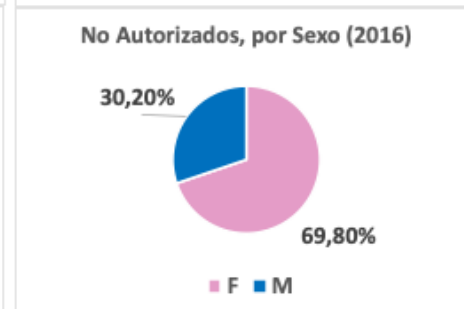
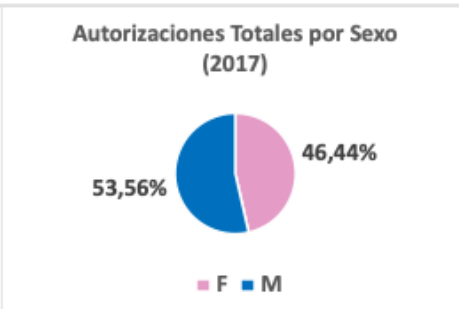
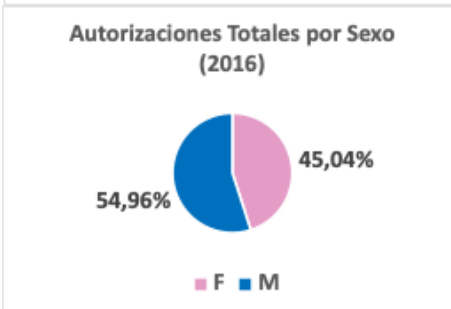
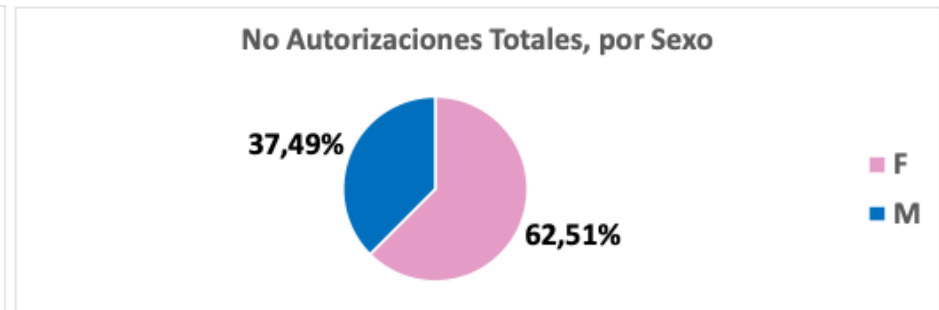
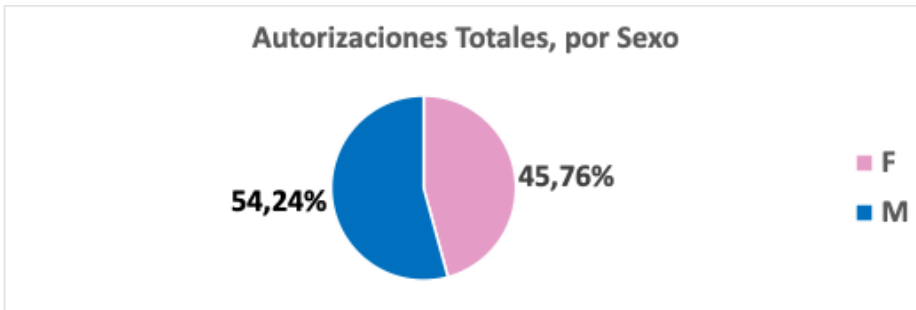
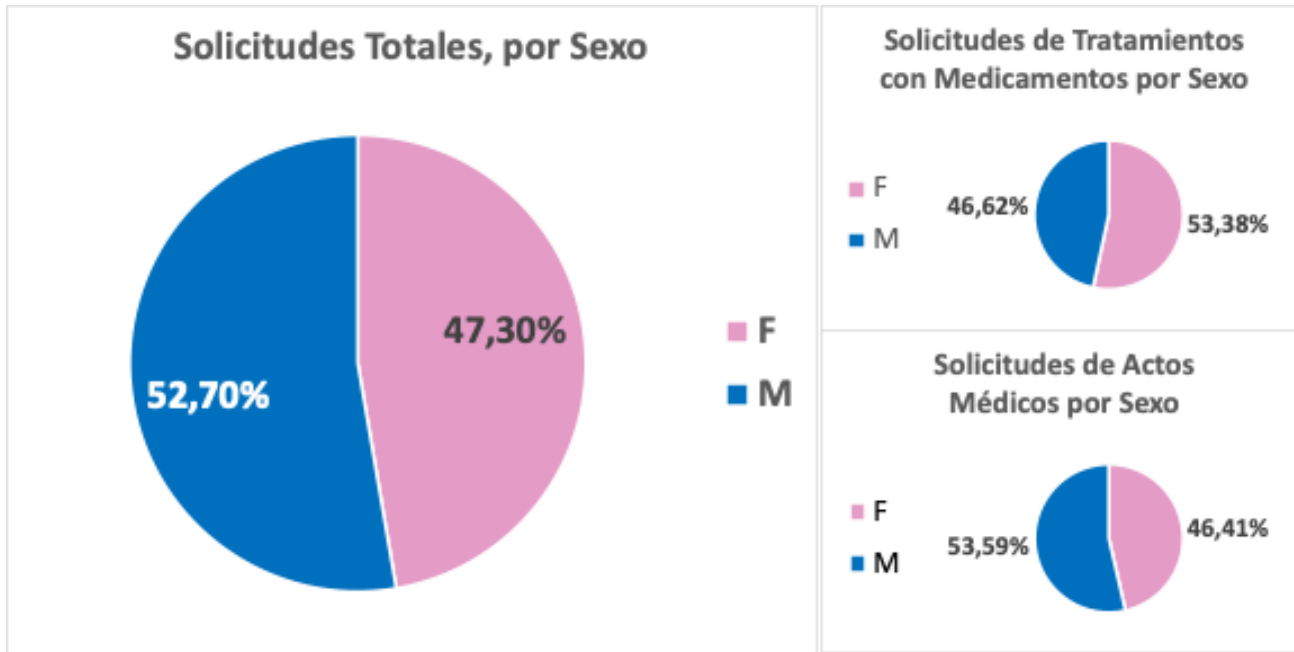
Análisis por Sexo

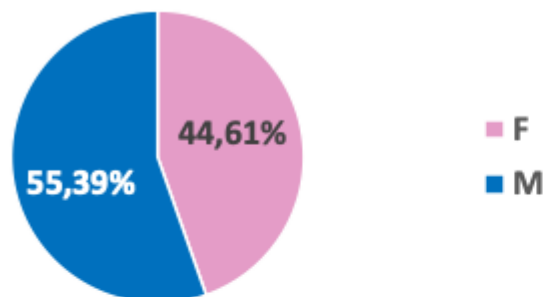
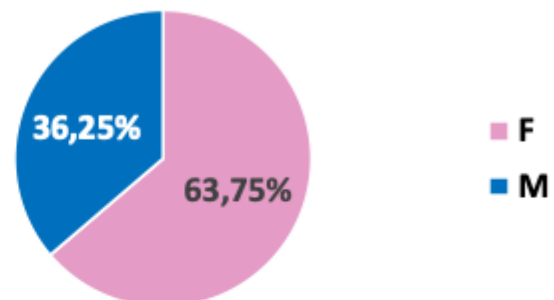
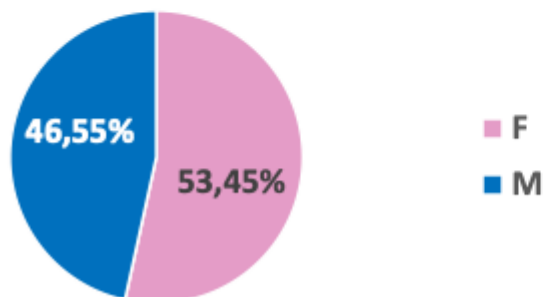
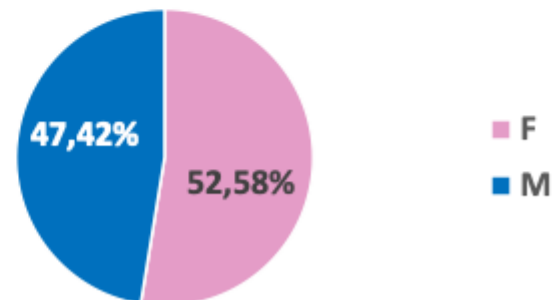
		AUTORIZADO	NO AUTORIZADO	Total general
	2016	21.668	2.470	24.138
F		9.760	1.724	11.484
M		11.908	746	12.654
	2017	22.941	2.048	24.989
F		10.654	1.100	11.754
M		12.287	948	13.235
Total general		44.609	4.518	49.127

	Cantidad	%
F	23.238	
AUTORIZADO	20.414	87,85%
NO AUTORIZADO	2.824	12,15%
M	25.889	
AUTORIZADO	24.195	93,46%
NO AUTORIZADO	1.694	6,54%
Total general	49.127	

	2016			2017			Total general
	AUTORIZADO	NO AUTORIZADO	TOTAL	AUTORIZADO	NO AUTORIZADO	TOTAL	
Acto Médico	18.865	2.245	21.110	19.944	1.769	21.713	42.823
F	8.253	1.603	9.856	9.061	956	10.017	19.873
M	10.612	642	11.254	10.883	813	11.696	22.950
Tratamiento con medicamento	2.803	225	3.028	2.997	279	3.276	6.304
F	1.507	121	1.628	1.593	144	1.737	3.365
M	1.296	104	1.400	1.404	135	1.539	2.939
Total general	21.668	2.470	24.138	22.941	2.048	24.989	49.127



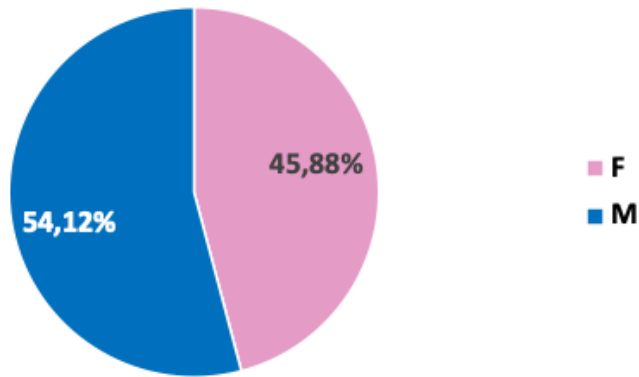


Actos Médicos Autorizados, por Sexo**Actos Médicos No Autorizados, por Sexo****Medicamentos Autorizados, por Sexo****Medicamentos No Autorizados, por Sexo**

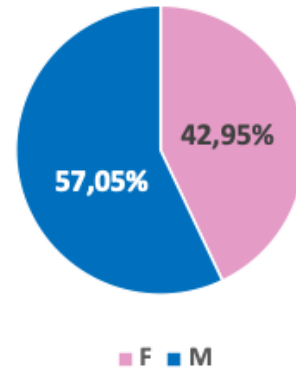
	importe Total		Importe Promedio
	Total	%	
F	\$ 5.522.243.057	45,88%	\$ 152.789
M	\$ 6.513.818.340	54,12%	\$ 177.551
Total general	\$ 12.036.061.397		\$ 165.262

Acto Médico	Importe Total		importe Promedio
	Total	%	
Acto Médico	\$ 10.119.590.924		\$ 210.505
F	\$ 4.345.995.107	42,95%	\$ 199.706
M	\$ 5.773.595.817	57,05%	\$ 219.437
Tratamiento con medicamentos	\$ 1.916.470.473		\$ 77.411
F	\$ 1.176.247.950	61,38%	\$ 81.792
M	\$ 740.222.523	38,62%	\$ 71.340
Total general	\$ 12.036.061.397		\$ 165.262

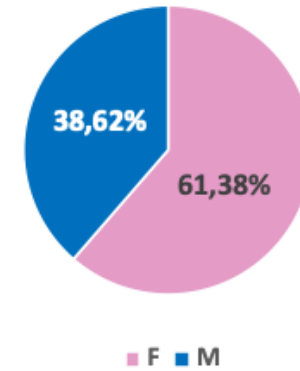
Proporción del importe total Autorizado, por Sexo



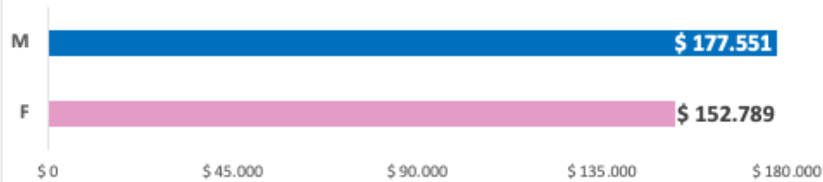
Gasto en Actos Médicos, por sexo



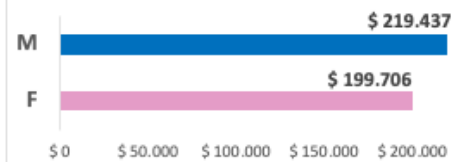
Gasto en Medicamentos, por Sexo



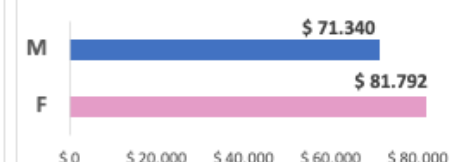
Importe promedio, por Sexo



Importe promedio en Actos Médicos, por Sexo

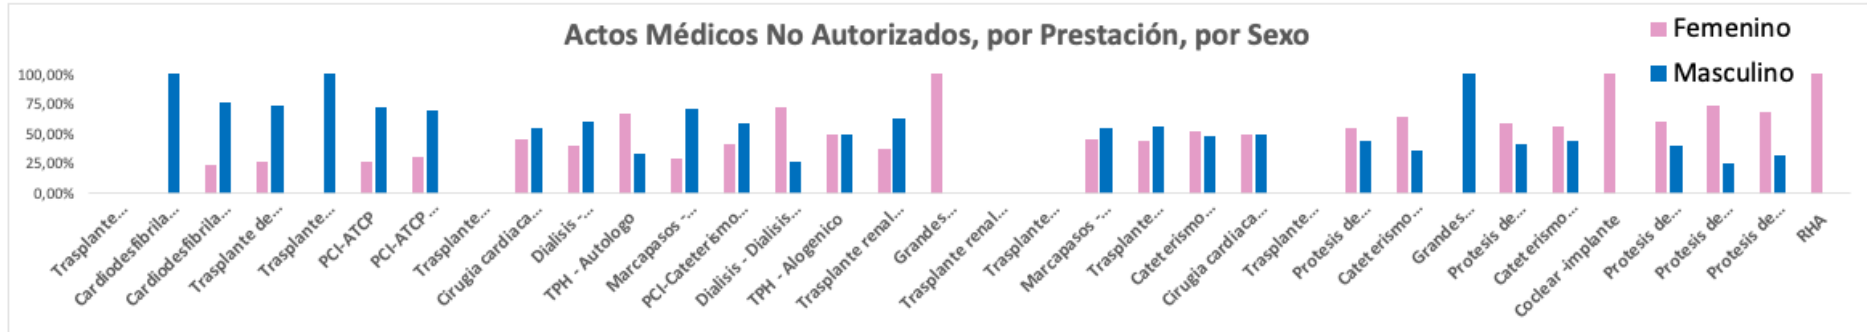
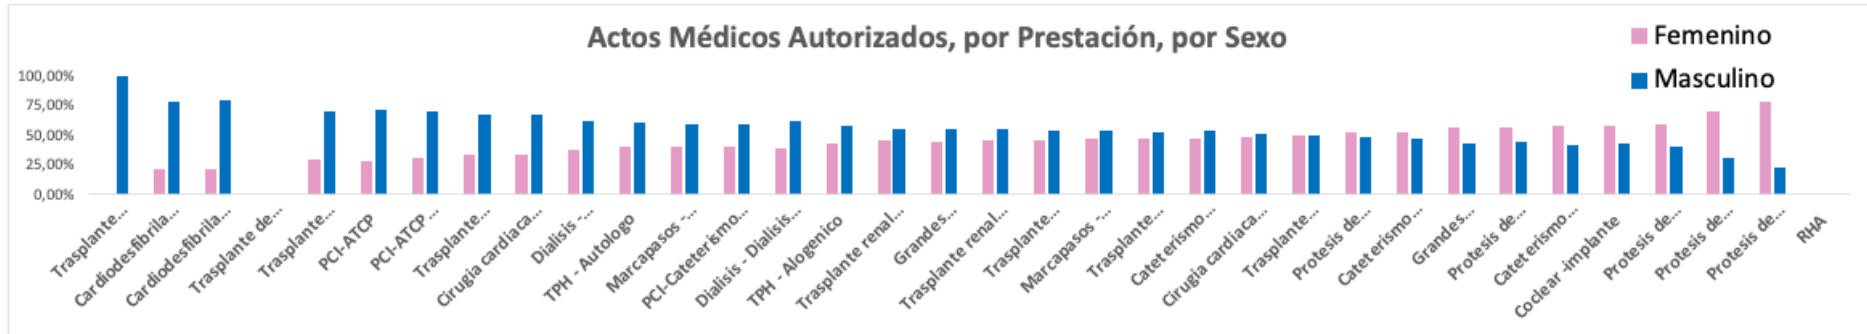
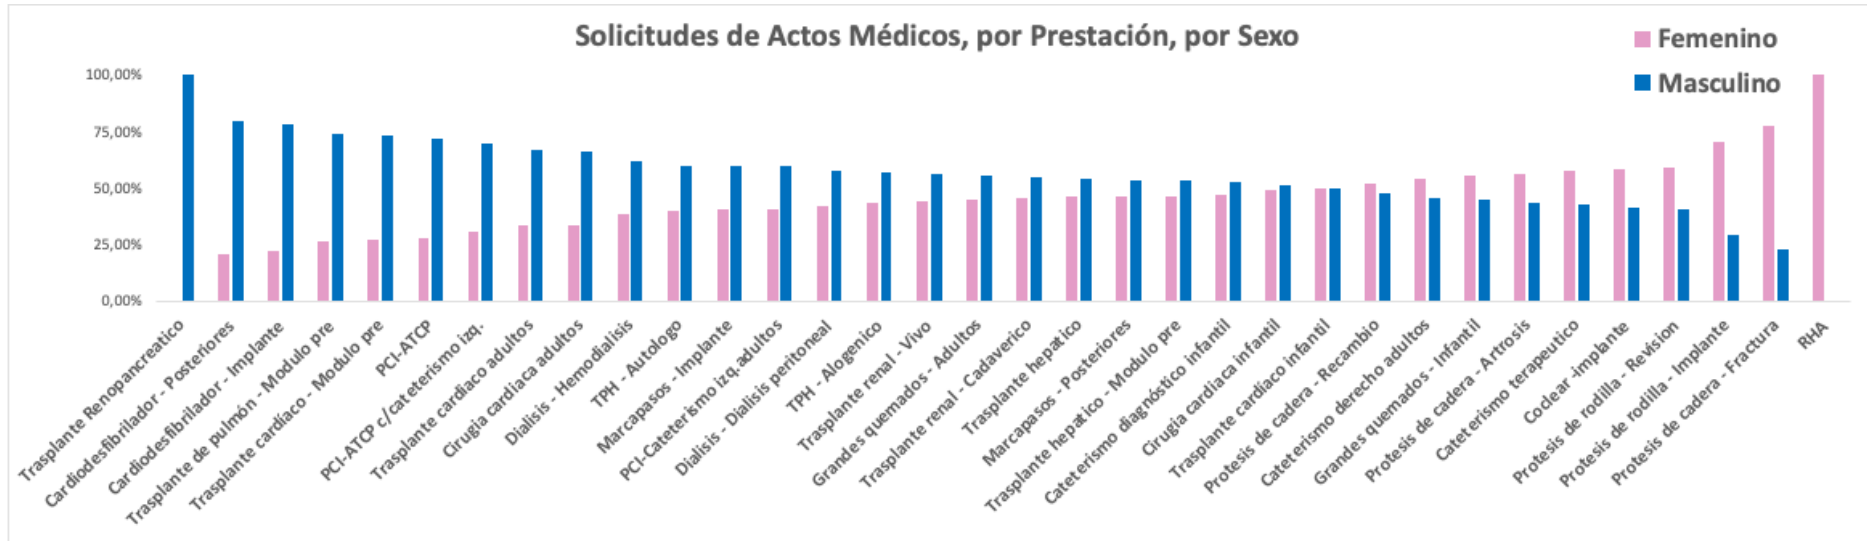


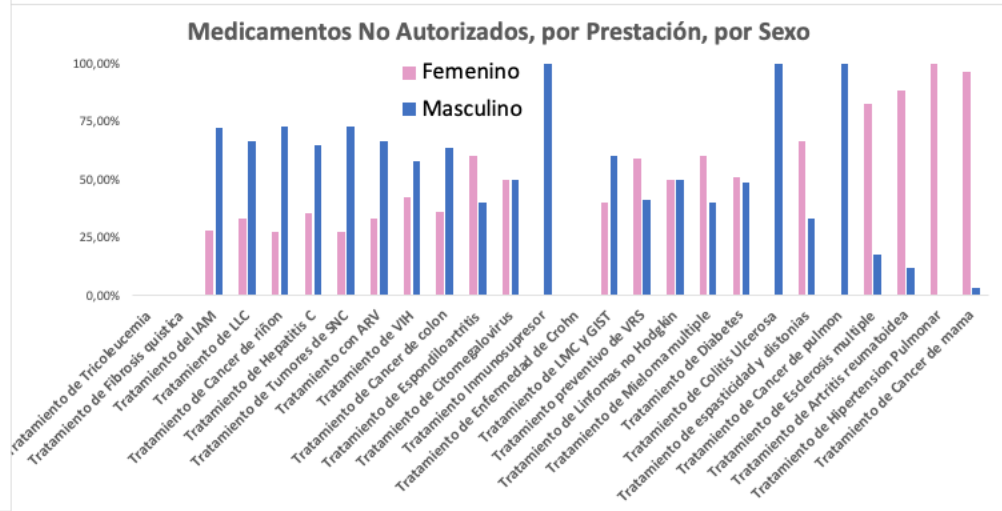
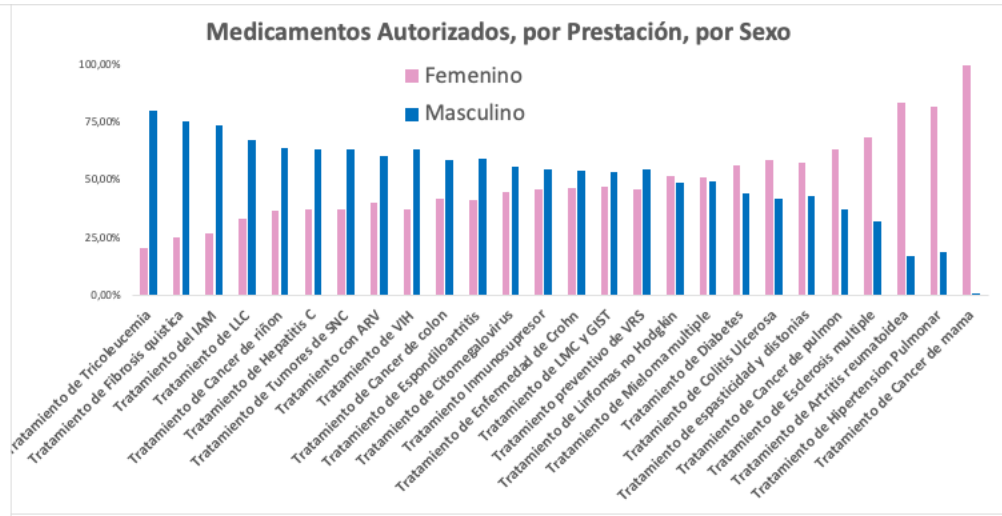
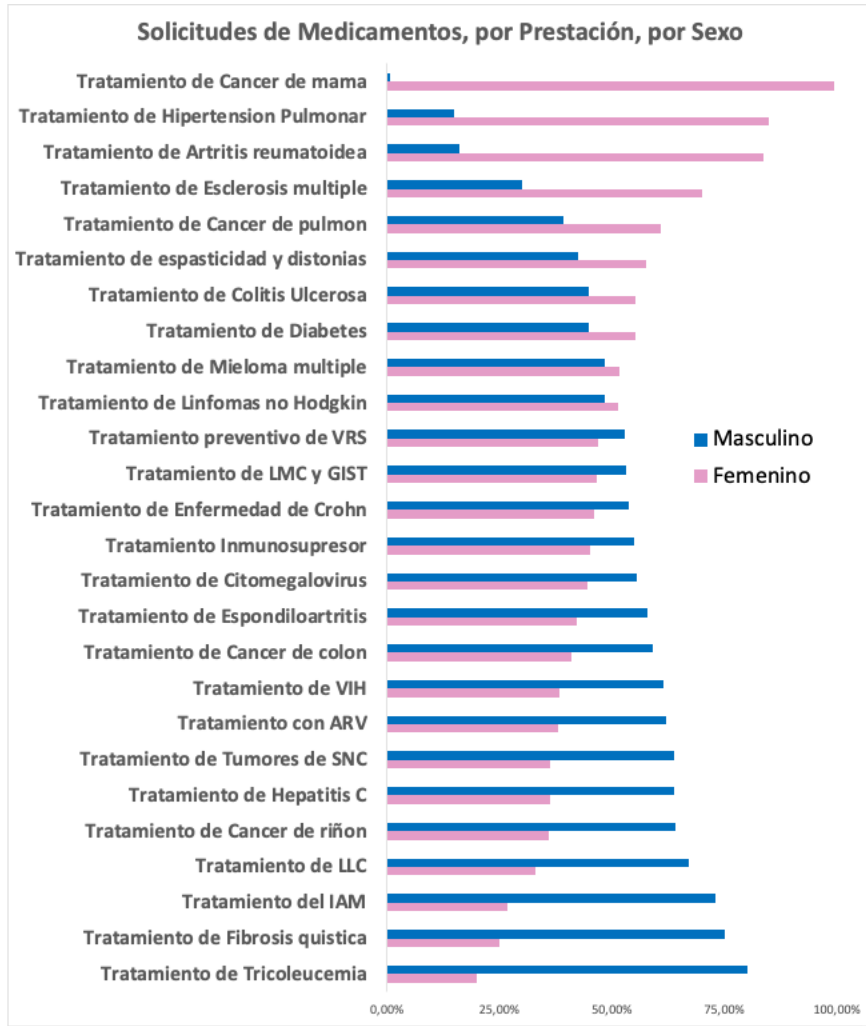
Importe promedio en Medicamentos, por Sexo



	AUTORIZADO					NO AUTORIZADO					TOTAL SOLICITUDES		
	F	M	TOTAL	% Femenino	% Masculino	F	M	TOTAL	% Femenino	% Masculino	TOTAL	% Femenino	% Masculino
Acto Médico	17.314	21.495	38.809	44,61%	55,39%	2.559	1.455	4.014	63,75%	36,25%	42.823	46,41%	53,59%
Cardiodesfibrilador - Implante	54	202	256	21,09%	78,91%	27	87	114	23,68%	76,32%	370	21,89%	78,11%
Cardiodesfibrilador - Posteriores	16	58	74	21,62%	78,38%		4	4	0,00%	100,00%	78	20,51%	79,49%
Cateterismo derecho adultos	54	48	102	52,94%	47,06%	9	5	14	64,29%	35,71%	116	54,31%	45,69%
Cateterismo diagnóstico infantil	72	83	155	46,45%	53,55%	11	10	21	52,38%	47,62%	176	47,16%	52,84%
Cateterismo terapeutico	147	106	253	58,10%	41,90%	39	31	70	55,71%	44,29%	323	57,59%	42,41%
Cirugía cardiaca adultos	1.517	3.038	4.555	33,30%	66,70%	52	62	114	45,61%	54,39%	4.669	33,60%	66,40%
Cirugía cardiaca infantil	215	226	441	48,75%	51,25%	9	9	18	50,00%	50,00%	459	48,80%	51,20%
Coclear -implante	16	12	28	57,14%	42,86%	1		1	100,00%	0,00%	29	58,62%	41,38%
Dialisis - Dialisis peritoneal	35	56	91	38,46%	61,54%	8	3	11	72,73%	27,27%	102	42,16%	57,84%
Dialisis - Hemodialisis	429	695	1.124	38,17%	61,83%	19	29	48	39,58%	60,42%	1.172	38,23%	61,77%
Grandes quemados - Adultos	125	155	280	44,64%	55,36%	1		1	100,00%	0,00%	281	44,84%	55,16%
Grandes quemados - Infantil	26	20	46	56,52%	43,48%		1	1	0,00%	100,00%	47	55,32%	44,68%
Marcapasos - Implante	1.103	1.614	2.717	40,60%	59,40%	16	39	55	29,09%	70,91%	2.772	40,37%	59,63%
Marcapasos - Posteriores	197	227	424	46,46%	53,54%	5	6	11	45,45%	54,55%	435	46,44%	53,56%
PCI-ATCP	202	507	709	28,49%	71,51%	62	168	230	26,96%	73,04%	939	28,12%	71,88%
PCI-ATCP c/cateterismo izq.	2.269	5.224	7.493	30,28%	69,72%	14	32	46	30,43%	69,57%	7.539	30,28%	69,72%
PCI-Cateterismo izq.adultos	3.514	5.162	8.676	40,50%	59,50%	355	499	854	41,57%	58,43%	9.530	40,60%	59,40%
Protesis de cadera - Artrosis	2.103	1.641	3.744	56,17%	43,83%	145	103	248	58,47%	41,53%	3.992	56,31%	43,69%
Protesis de cadera - Fractura	1.712	494	2.206	77,61%	22,39%	51	24	75	68,00%	32,00%	2.281	77,29%	22,71%
Protesis de cadera - Recambio	197	183	380	51,84%	48,16%	15	12	27	55,56%	44,44%	407	52,09%	47,91%
Protesis de rodilla - Implante	2.946	1.277	4.223	69,76%	30,24%	810	281	1.091	74,24%	25,76%	5.314	70,68%	29,32%
Protesis de rodilla - Revision	42	29	71	59,15%	40,85%	3	2	5	60,00%	40,00%	76	59,21%	40,79%
RHA				0,00%	0,00%	879		879	100,00%	0,00%	879	100,00%	0,00%
TPH - Alogénico	40	54	94	42,55%	57,45%	6	6	12	50,00%	50,00%	106	43,40%	56,60%
TPH - Autólogo	81	123	204	39,71%	60,29%	2	1	3	66,67%	33,33%	207	40,10%	59,90%
Trasplante cardíaco - Modulo pre	14	33	47	29,79%	70,21%		5	5	0,00%	100,00%	52	26,92%	73,08%
Trasplante cardíaco adultos	4	8	12	33,33%	66,67%						12	33,33%	66,67%
Trasplante cardíaco infantil	1	1	2	50,00%	50,00%						2	50,00%	50,00%
Trasplante de pulmón - Modulo pre						6	17	23	26,09%	73,91%	23	26,09%	73,91%
Trasplante hepatico	23	27	50	46,00%	54,00%						50	46,00%	54,00%
Trasplante hepatico - Modulo pre	43	48	91	47,25%	52,75%	11	14	25	44,00%	56,00%	116	46,55%	53,45%
Trasplante renal - Cadaverico	102	123	225	45,33%	54,67%						225	45,33%	54,67%
Trasplante renal - Vivo	15	18	33	45,45%	54,55%	3	5	8	37,50%	62,50%	41	43,90%	56,10%
Trasplante Renopancreatico		3	3	0,00%	100,00%						3	0,00%	100,00%

	AUTORIZADO					NO AUTORIZADO					TOTAL SOLICITUDES		
	F	M	TOTAL	% Femenino	% Masculino	F	M	TOTAL	% Femenino	% Masculino	TOTAL	% Femenino	% Masculino
Tratamiento con medicamentos	3.100	2.700	5.800	53,45%	46,55%	265	239	504	52,58%	47,42%	6.304	53,38%	46,62%
Tratamiento con ARV	21	32	53	39,62%	60,38%	6	12	18	33,33%	66,67%	71	38,03%	61,97%
Tratamiento de Artritis reumatoidea	263	53	316	83,23%	16,77%	37	5	42	88,10%	11,90%	358	83,80%	16,20%
Tratamiento de Cancer de colon	194	275	469	41,36%	58,64%	13	23	36	36,11%	63,89%	505	40,99%	59,01%
Tratamiento de Cancer de mama	718	4	722	99,45%	0,55%	28	1	29	96,55%	3,45%	751	99,33%	0,67%
Tratamiento de Cancer de pulmon	31	18	49	63,27%	36,73%		2	2	0,00%	100,00%	51	60,78%	39,22%
Tratamiento de Cancer de riñon	75	131	206	36,41%	63,59%	3	8	11	27,27%	72,73%	217	35,94%	64,06%
Tratamiento de Citomegalovirus	86	108	194	44,33%	55,67%	3	3	6	50,00%	50,00%	200	44,50%	55,50%
Tratamiento de Colitis Ulcerosa	21	15	36	58,33%	41,67%		2	2	0,00%	100,00%	38	55,26%	44,74%
Tratamiento de Diabetes	245	193	438	55,94%	44,06%	47	45	92	51,09%	48,91%	530	55,09%	44,91%
Tratamiento de Enfermedad de Crohn	12	14	26	46,15%	53,85%						26	46,15%	53,85%
Tratamiento de Esclerosis multiple	79	37	116	68,10%	31,90%	14	3	17	82,35%	17,65%	133	69,92%	30,08%
Tratamiento de espasticidad y distonias	132	98	230	57,39%	42,61%	4	2	6	66,67%	33,33%	236	57,63%	42,37%
Tratamiento de Espondiloartritis	42	60	102	41,18%	58,82%	3	2	5	60,00%	40,00%	107	42,06%	57,94%
Tratamiento de Fibrosis quística	5	15	20	25,00%	75,00%						20	25,00%	75,00%
Tratamiento de Hepatitis C	32	55	87	36,78%	63,22%	13	24	37	35,14%	64,86%	124	36,29%	63,71%
Tratamiento de Hipertension Pulmonar	13	3	16	81,25%	18,75%	4		4	100,00%	0,00%	20	85,00%	15,00%
Tratamiento de Linfomas no Hodgkin	289	272	561	51,52%	48,48%	14	14	28	50,00%	50,00%	589	51,44%	48,56%
Tratamiento de LLC	22	45	67	32,84%	67,16%	2	4	6	33,33%	66,67%	73	32,88%	67,12%
Tratamiento de LMC y GIST	48	54	102	47,06%	52,94%	2	3	5	40,00%	60,00%	107	46,73%	53,27%
Tratamiento de Mieloma multiple	99	95	194	51,03%	48,97%	9	6	15	60,00%	40,00%	209	51,67%	48,33%
Tratamiento de Tricoleucemia	4	16	20	20,00%	80,00%						20	20,00%	80,00%
Tratamiento de Tumores de SNC	42	71	113	37,17%	62,83%	3	8	11	27,27%	72,73%	124	36,29%	63,71%
Tratamiento de VIH	39	66	105	37,14%	62,86%	14	19	33	42,42%	57,58%	138	38,41%	61,59%
Tratamiento del IAM	175	477	652	26,84%	73,16%	10	26	36	27,78%	72,22%	688	26,89%	73,11%
Tratamiento Inmunosupresor	159	191	350	45,43%	54,57%		2	2	0,00%	100,00%	352	45,17%	54,83%
Tratamiento preventivo de VRS	254	302	556	45,68%	54,32%	36	25	61	59,02%	40,98%	617	47,00%	53,00%
Total general	20.414	24.195	44.609	45,76%	54,24%	2.824	1.694	4.518	62,51%	37,49%	49.127	47,30%	52,70%



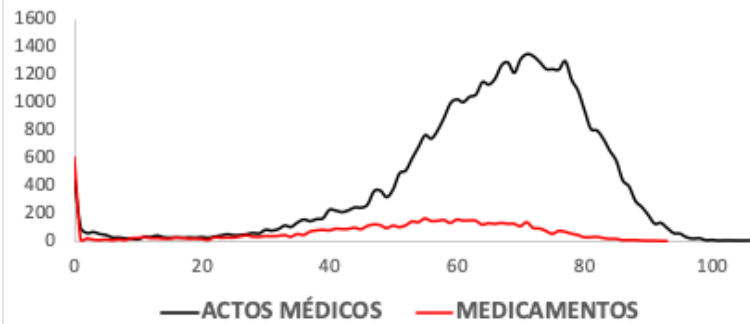


Análisis por Edad

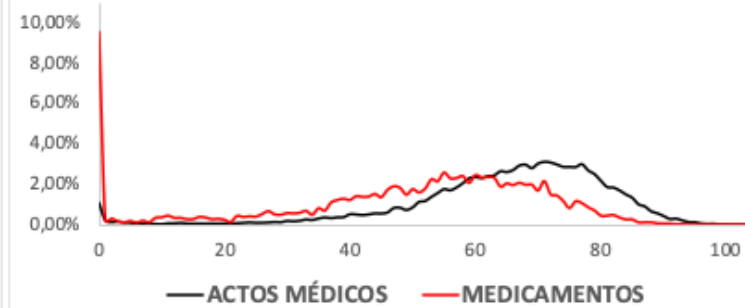
	Acto Médico						Tratamiento con medicamentos						Total general	
	Cantidad			%			Cantidad			%			Cantidad	%
	AUTORIZADO	NO AUTORIZADO	TOTAL	AUTORIZADO	NO AUTORIZADO	TOTAL	AUTORIZADO	NO AUTORIZADO	TOTAL	AUTORIZADO	NO AUTORIZADO	TOTAL		
2016	18.865	2.245	21.110				2.803	225	3.028				24.138	
0	244	14	258	1,29%	0,62%	1,22%	277	24	301	9,88%	10,67%	9,94%	559	2,32%
1	38	6	44	0,20%	0,27%	0,21%	3	3	6	0,11%	1,33%	0,20%	50	0,21%
2	27		27	0,14%		0,13%	6	1	7	0,21%	0,44%	0,23%	34	0,14%
3	20	6	26	0,11%	0,27%	0,12%	6	2	8	0,21%	0,89%	0,26%	34	0,14%
...
85	250	20	270	1,33%	0,89%	1,28%	9	1	10	0,32%	0,44%	0,33%	280	1,16%
86	191	8	199	1,01%	0,36%	0,94%	5		5	0,18%		0,17%	204	0,85%
87	200	6	206	1,06%	0,27%	0,98%	2		2	0,07%		0,07%	208	0,86%
...
2017	19.944	1.769	21.713				2.997	279	3.276				24.989	
0	199	14	213	1,00%	0,79%	0,98%	274	29	303	9,14%	10,39%	9,25%	516	2,06%
1	49	3	52	0,25%	0,17%	0,24%	4	3	7	0,13%	1,08%	0,21%	59	0,24%
2	25	4	29	0,13%	0,23%	0,13%	10	2	12	0,33%	0,72%	0,37%	41	0,16%
...
92	76	1	77	0,38%	0,06%	0,35%	1		1	0,03%		0,03%	78	0,31%
93	50	3	53	0,25%	0,17%	0,24%							53	0,21%
94	35	1	36	0,18%	0,06%	0,17%							36	0,14%
...
Total general	38.809	4.014	42.823				5.800	504	6.304				49.127	

	Total en \$U			%		
	Acto Médico	Tratamiento con medicamentos	Total general	Acto Médico	Tratamiento con medicamentos	Total general
0	\$ 108.873.052	\$ 40.397.675	\$ 149.270.727	1,08%	2,11%	1,24%
1	\$ 84.228.071	\$ 7.400.512	\$ 91.628.583	0,83%	0,39%	0,76%
2	\$ 26.319.547	\$ 256.970	\$ 26.576.517	0,26%	0,01%	0,22%
...
102	\$ 110.853		\$ 110.853	0,00%		0,00%
103	\$ 57.878		\$ 57.878	0,00%		0,00%
106	\$ 189.729		\$ 189.729	0,00%		0,00%
Total general	\$ 10.119.590.924	\$ 1.916.470.473	\$ 12.036.061.397			

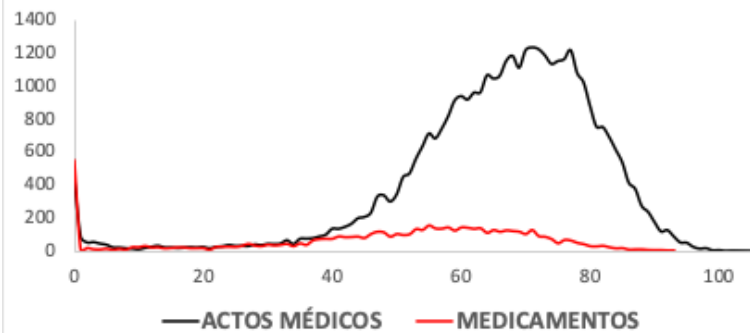
**Solicitudes por tipo de prestación, por edad
(Cantidad)**



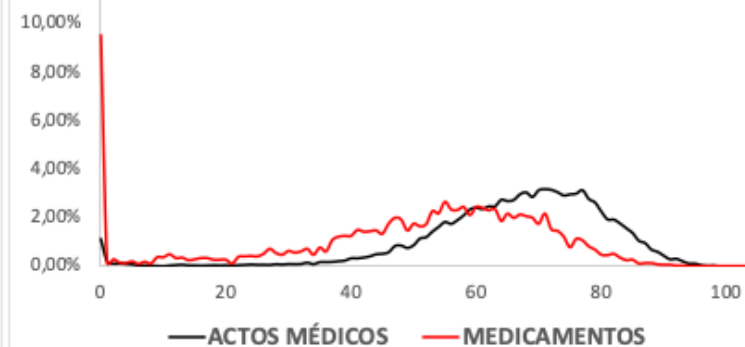
**Solicitudes por tipo de prestación, por edad
(en %)**



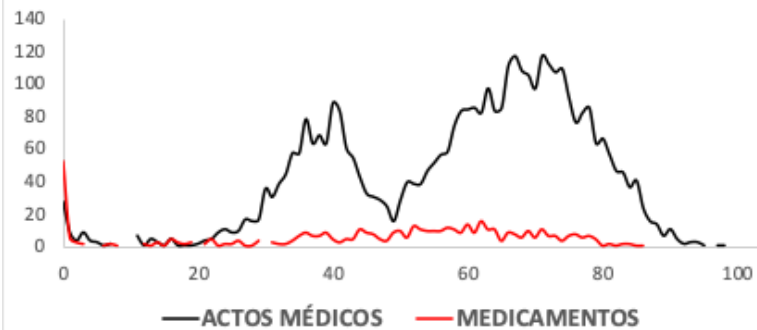
**Autorizados por Tipo de Prestación, por Edad
(Cantidad)**



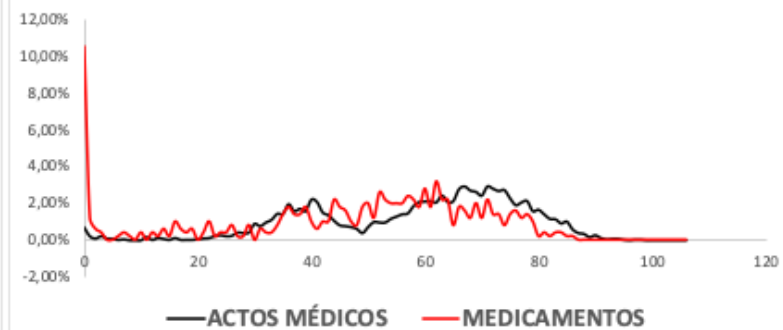
Autorizados por Tipo de Prestación, por Edad (%)

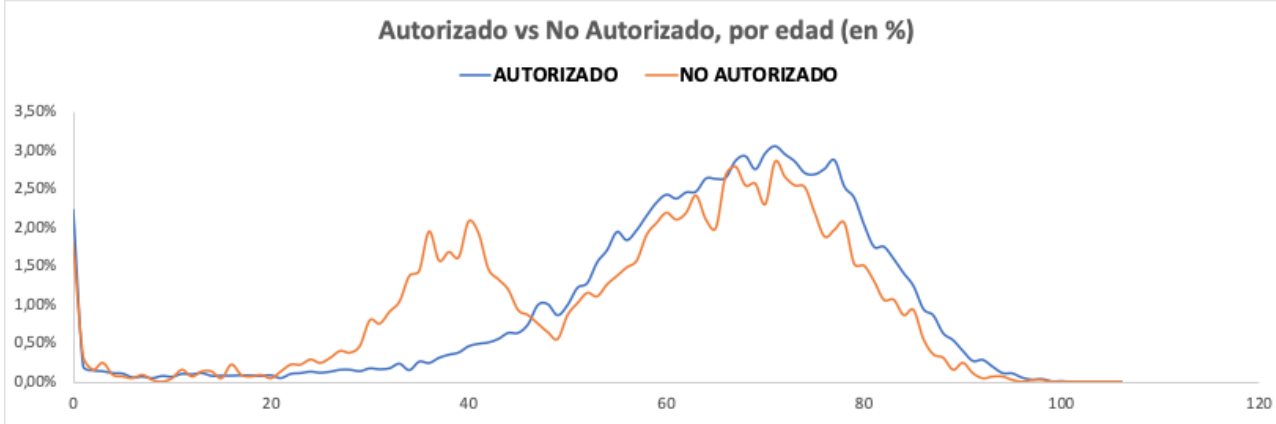
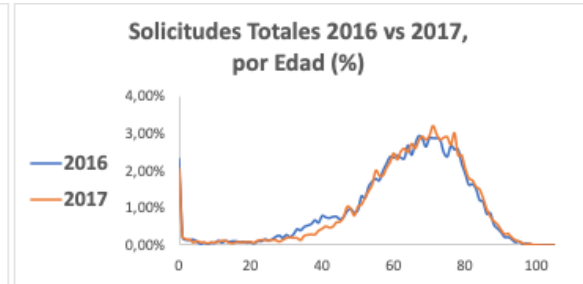
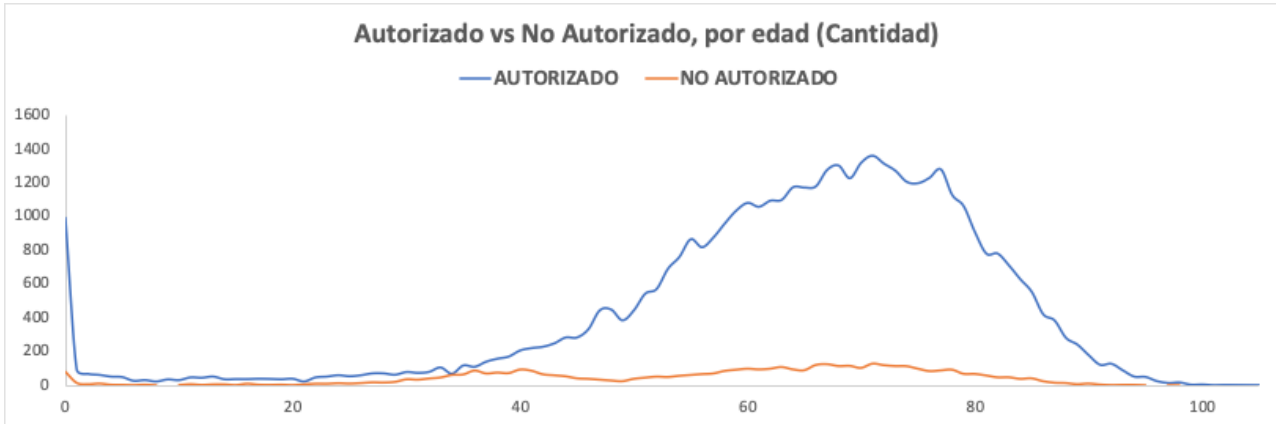


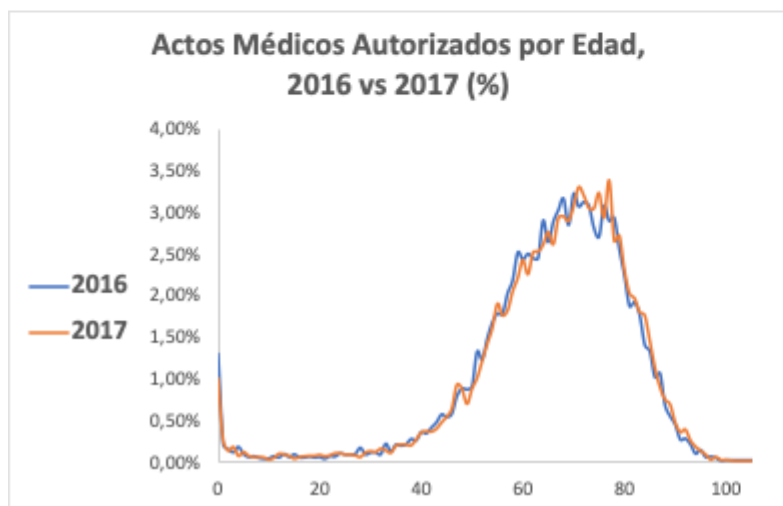
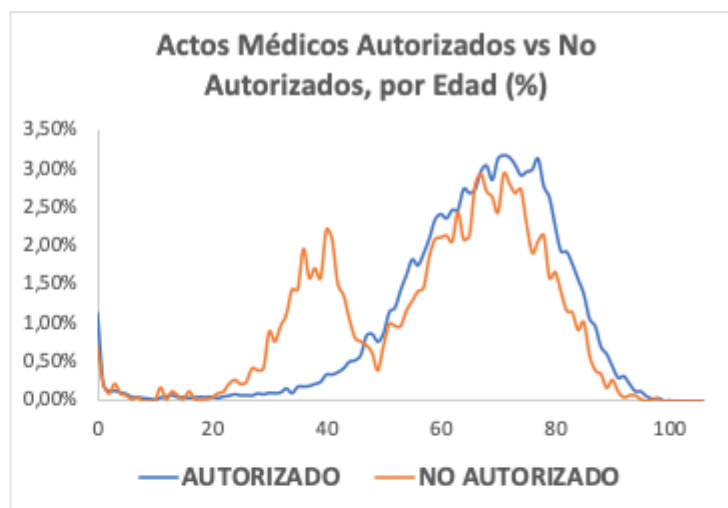
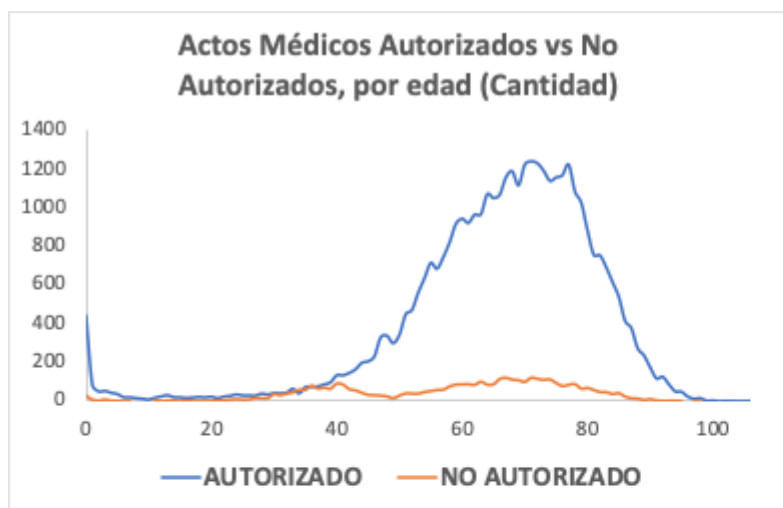
**No Autorizados por Tipo de Prestación, por Edad
(Cantidad)**

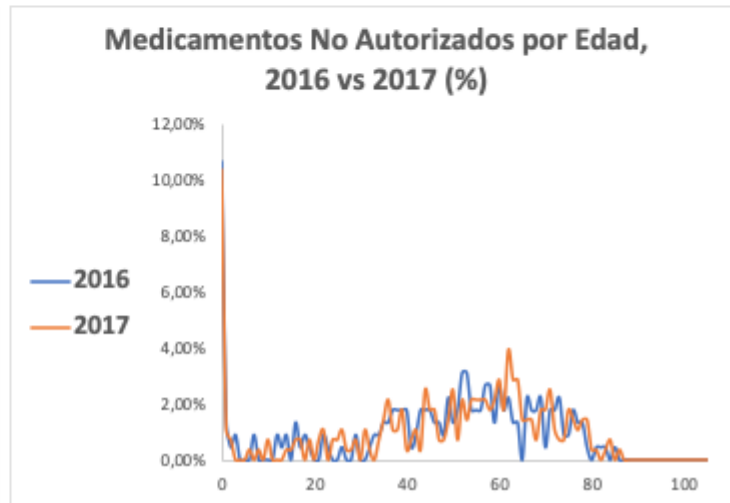
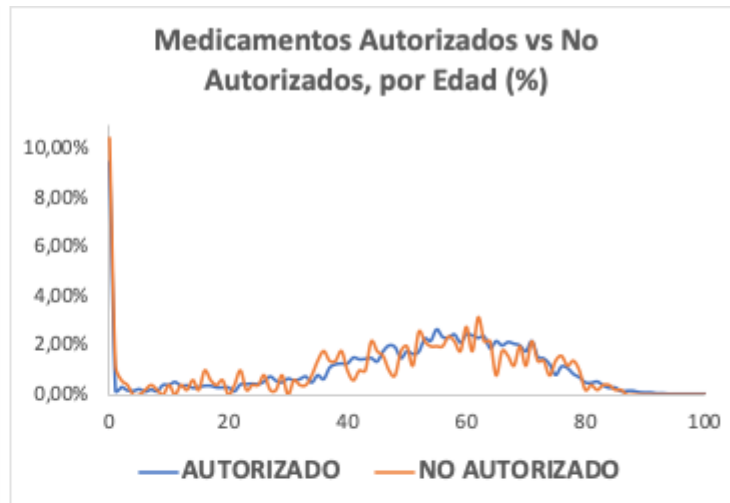
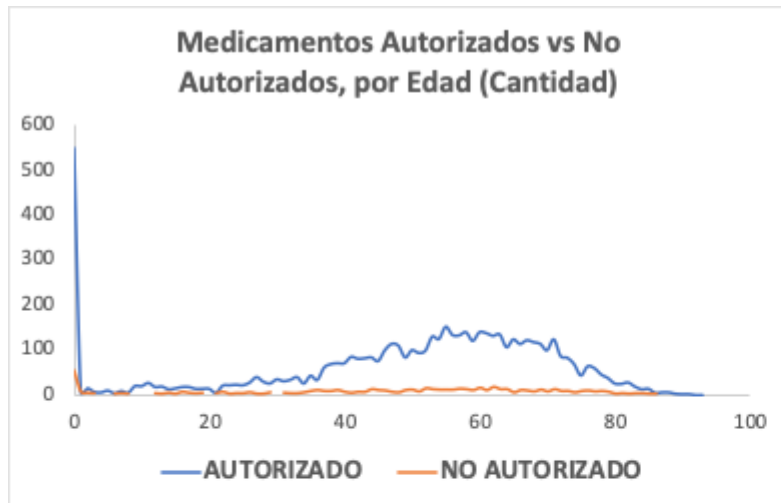


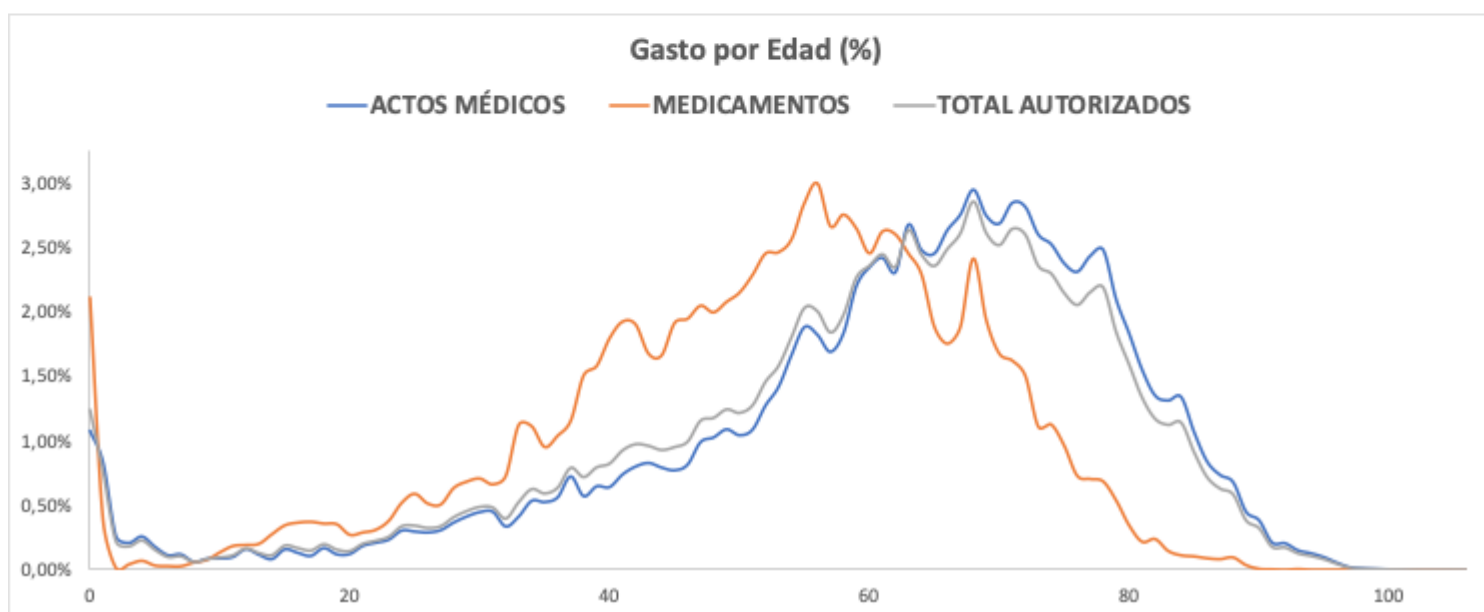
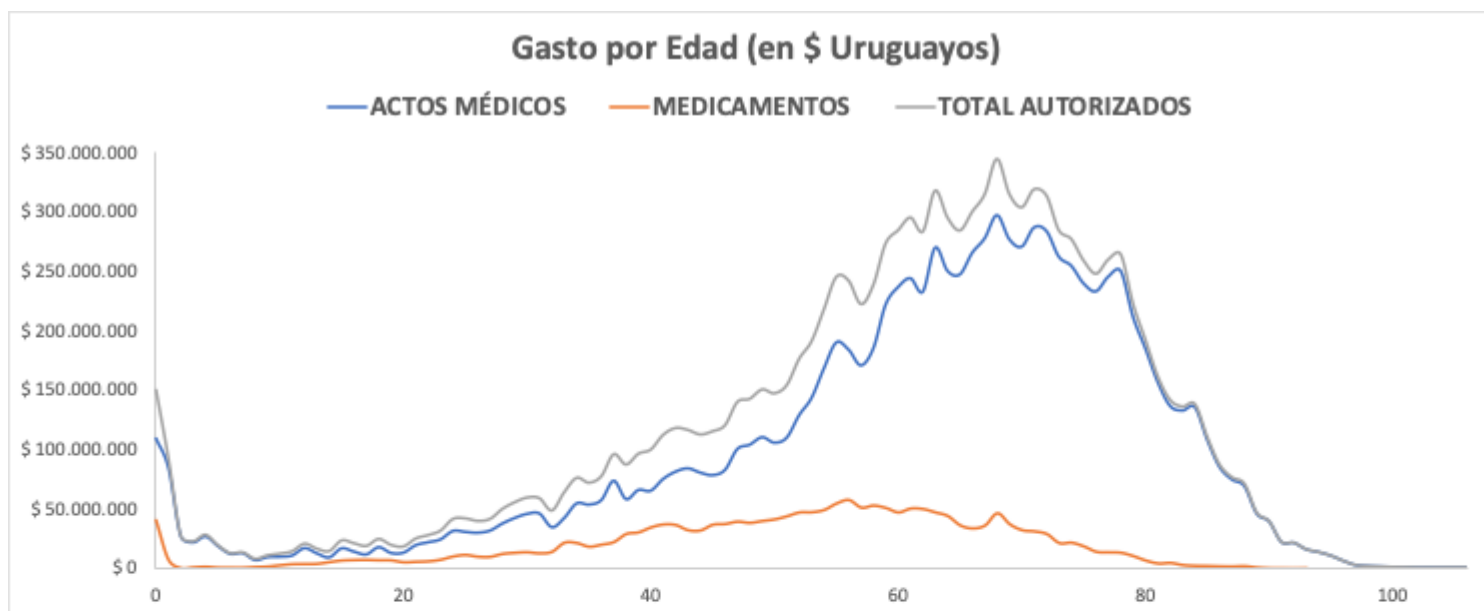
**No Autorizados por Tipo de Prestación, por Edad
(%)**







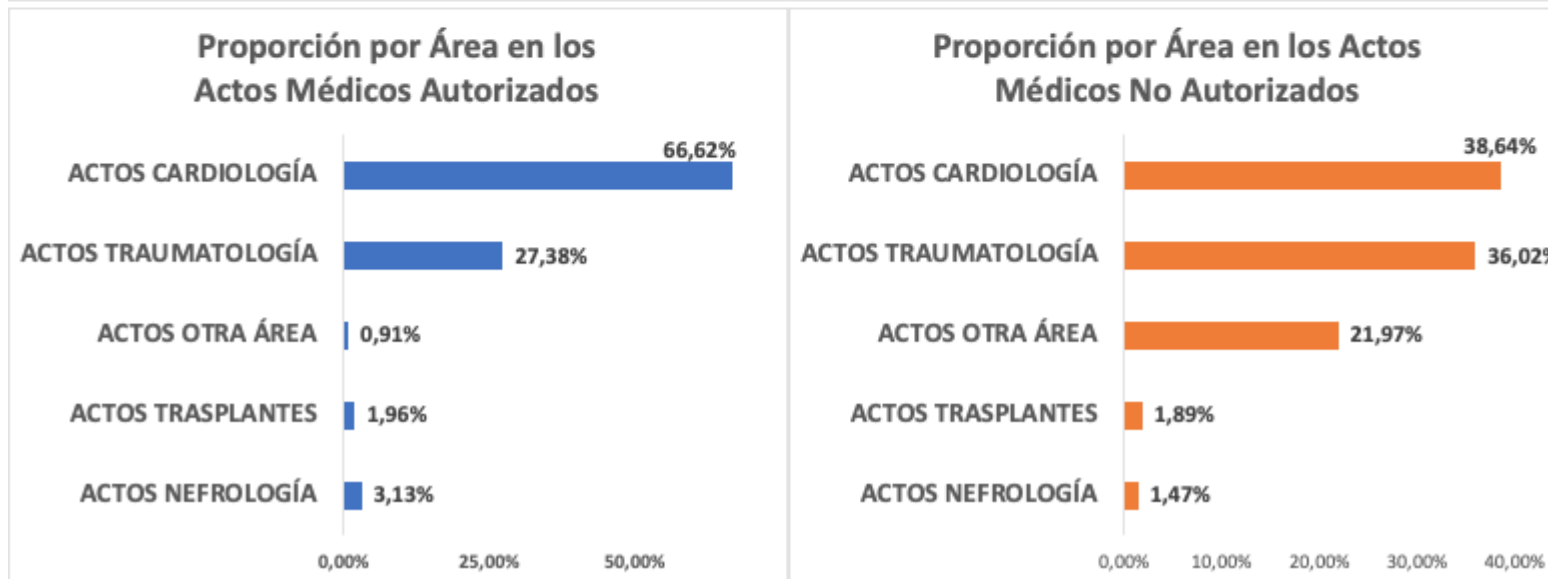
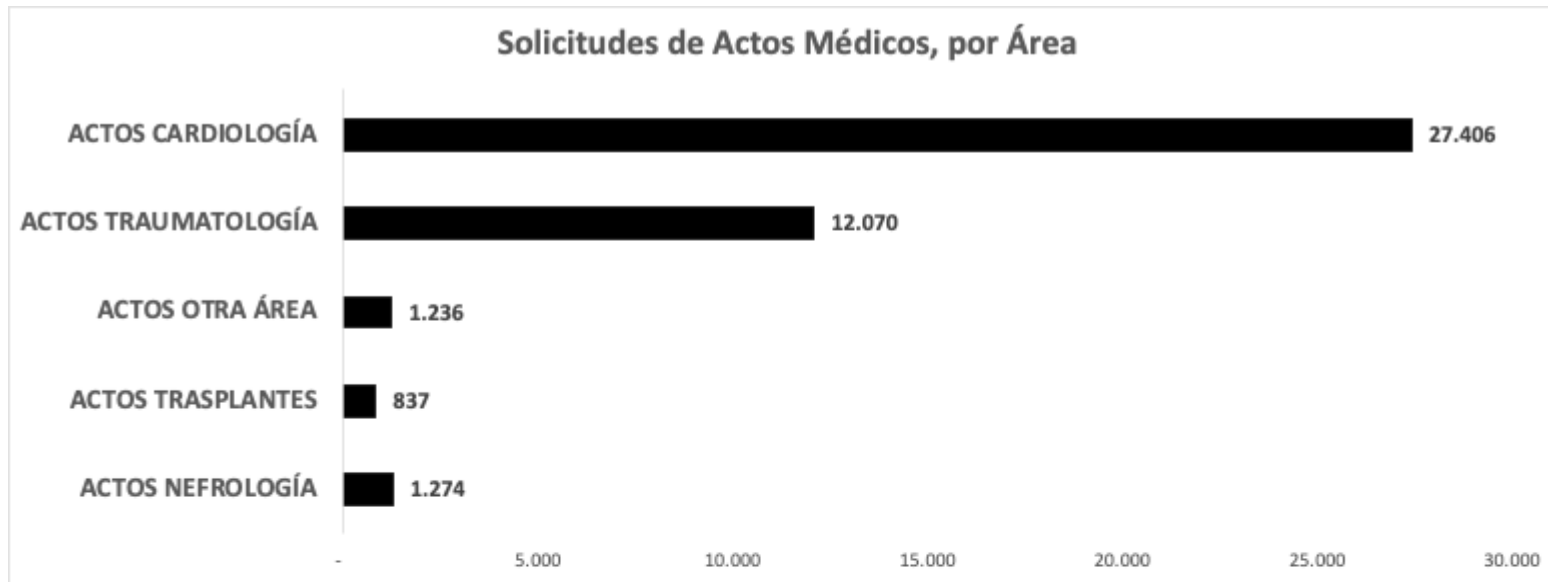




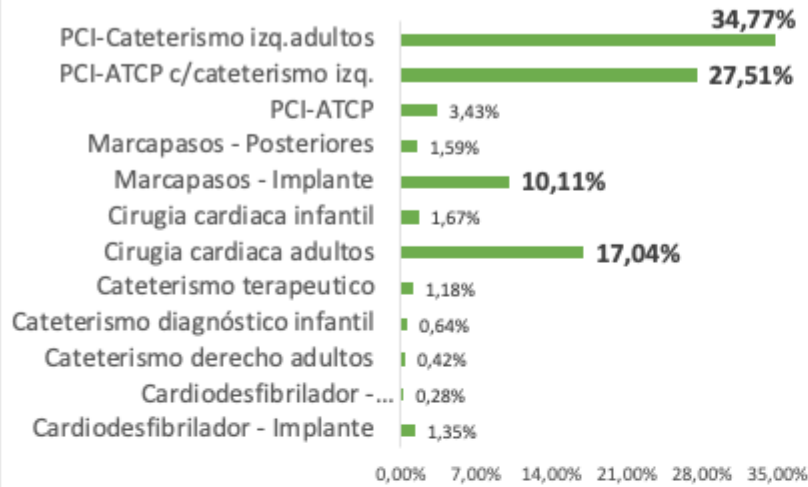
Análisis por Área y Prestación

	Cantidad			% Por Prestación		% Por Área			Demora Promedio
	AUTORIZADO	NO AUTORIZADO	TOTAL	AUTORIZADO	NO AUTORIZADO	AUTORIZADO	NO AUTORIZADO	TOTAL	
Acto Médico	38.809	4.014	42.823						30,88
ACTOS CARDIOLOGÍA	25.855	1.551	27.406			66,62%	38,64%	64,00%	11,35
Cardiodesfibrilador - Implante	256	114	370	69,19%	30,81%	0,99%	7,35%	1,35%	14,16
Cardiodesfibrilador - Posteriores	74	4	78	94,87%	5,13%	0,29%	0,26%	0,28%	8,97
Cateterismo derecho adultos	102	14	116	87,93%	12,07%	0,39%	0,90%	0,42%	21,93
Cateterismo diagnóstico infantil	155	21	176	88,07%	11,93%	0,60%	1,35%	0,64%	9,20
Cateterismo terapeutico	253	70	323	78,33%	21,67%	0,98%	4,51%	1,18%	22,74
Cirugia cardiaca adultos	4.555	114	4.669	97,56%	2,44%	17,62%	7,35%	17,04%	15,43
Cirugia cardiaca infantil	441	18	459	96,08%	3,92%	1,71%	1,16%	1,67%	13,71
Marcapasos - Implante	2.717	55	2.772	98,02%	1,98%	10,51%	3,55%	10,11%	7,51
Marcapasos - Posteriores	424	11	435	97,47%	2,53%	1,64%	0,71%	1,59%	5,43
PCI-ATCP	709	230	939	75,51%	24,49%	2,74%	14,83%	3,43%	22,75
PCI-ATCP c/ cateterismo izq.	7.493	46	7.539	99,39%	0,61%	28,98%	2,97%	27,51%	9,35
PCI-Cateterismo izq.adultos	8.676	854	9.530	91,04%	8,96%	33,56%	55,06%	34,77%	10,90
ACTOS NEFROLOGÍA	1.215	59	1.274			3,13%	1,47%	2,98%	9,91
Dialisis - Dialisis peritoneal	91	11	102	89,22%	10,78%	7,49%	18,64%	8,01%	17,33
Dialisis - Hemodialisis	1.124	48	1.172	95,90%	4,10%	92,51%	81,36%	91,99%	9,31
ACTOS OTRA ÁREA	354	882	1.236			0,91%	21,97%	2,89%	4,65
Coclear -implante	28	1	29	96,55%	3,45%	7,91%	0,11%	2,35%	23,43
Grandes quemados - Adultos	280	1	281	99,64%	0,36%	79,10%	0,11%	22,73%	2,07
Grandes quemados - Infantil	46	1	47	97,87%	2,13%	12,99%	0,11%	3,80%	8,89
RHA		879	879	0,00%	100,00%	0,00%	99,66%	71,12%	
ACTOS TRASPLANTES	761	76	837			1,96%	1,89%	1,95%	14,55
TPH - Alogénico	94	12	106	88,68%	11,32%	12,35%	15,79%	12,66%	16,51
TPH - Autólogo	204	3	207	98,55%	1,45%	26,81%	3,95%	24,73%	11,87
Trasplante cardíaco - Modulo pre	47	5	52	90,38%	9,62%	6,18%	6,58%	6,21%	16,81
Trasplante cardíaco adultos	12		12	100,00%	0,00%	1,58%	0,00%	1,43%	15,92
Trasplante cardíaco infantil	2		2	100,00%	0,00%	0,26%	0,00%	0,24%	0,50
Trasplante de pulmón - Modulo pre		23	23	0,00%	100,00%	0,00%	30,26%	2,75%	
Trasplante hepatico	50		50	100,00%	0,00%	6,57%	0,00%	5,97%	26,72
Trasplante hepatico - Modulo pre	91	25	116	78,45%	21,55%	11,96%	32,89%	13,86%	35,75
Trasplante renal - Cadaverico	225		225	100,00%	0,00%	29,57%	0,00%	26,88%	2,10
Trasplante renal - Vivo	33	8	41	80,49%	19,51%	4,34%	10,53%	4,90%	31,91
Trasplante Renopancreatico	3		3	100,00%	0,00%	0,39%	0,00%	0,36%	1,33
ACTOS TRAUMATOLOGÍA	10.624	1.446	12.070			27,38%	36,02%	28,19%	82,85
Protesis de cadera - Artrosis	3.744	248	3.992	93,79%	6,21%	35,24%	17,15%	33,07%	45,55
Protesis de cadera - Fractura	2.206	75	2.281	96,71%	3,29%	20,76%	5,19%	18,90%	5,03
Protesis de cadera - Recambio	380	27	407	93,37%	6,63%	3,58%	1,87%	3,37%	56,23
Protesis de rodilla - Implante	4.223	1.091	5.314	79,47%	20,53%	39,75%	75,45%	44,03%	158,61
Protesis de rodilla - Revision	71	5	76	93,42%	6,58%	0,67%	0,35%	0,63%	105,87

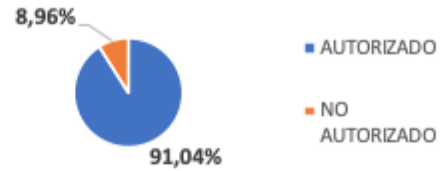
	AUTORIZADO	NO AUTORIZADO	TOTAL	AUTORIZADO	NO AUTORIZADO	AUTORIZADO	NO AUTORIZADO	TOTAL	Demora Promedio
Tratamiento con medicamento	5.800	504	6.304	92,01%	7,99%				17,18
MAC CARDIOLOGÍA	652	36	688			11,24%	7,14%	10,91%	11,88
Tratamiento del IAM	652	36	688	94,77%	5,23%	100,00%	100,00%	100,00%	11,88
MAC ENDOCRINOLOGÍA	438	92	530			7,55%	18,25%	8,41%	23,16
Tratamiento de Diabetes	438	92	530	82,64%	17,36%	100,00%	100,00%	100,00%	23,16
MAC GASTROENTEROLOGÍA	62	2	64			1,07%	0,40%	1,02%	35,08
Tratamiento de Colitis Ulcerosa	36	2	38	94,74%	5,26%	58,06%	100,00%	59,38%	38,75
Tratamiento de Enfermedad de Crohn	26		26	100,00%	0,00%	41,94%	0,00%	40,63%	30,00
MAC INFECTOLOGÍA	995	155	1.150			17,16%	30,75%	18,24%	7,77
Tratamiento con ARV	53	18	71	74,65%	25,35%	5,33%	11,61%	6,17%	11,36
Tratamiento de Citomegalovirus	194	6	200	97,00%	3,00%	19,50%	3,87%	17,39%	2,62
Tratamiento de Hepatitis C	87	37	124	70,16%	29,84%	8,74%	23,87%	10,78%	35,18
Tratamiento de VIH	105	33	138	76,09%	23,91%	10,55%	21,29%	12,00%	6,64
Tratamiento preventivo de VRS	556	61	617	90,11%	9,89%	55,88%	39,35%	53,65%	5,14
MAC INMUNOLOGÍA	350	2	352			6,03%	0,40%	5,58%	0,42
Tratamiento Inmunosupresor	350	2	352	99,43%	0,57%	100,00%	100,00%	100,00%	0,42
MAC NEUMOLOGÍA	36	4	40			0,62%	0,79%	0,63%	47,08
Tratamiento de Fibrosis quística	20		20	100,00%	0,00%	55,56%	0,00%	50,00%	26,50
Tratamiento de Hipertension Pulmonar	16	4	20	80,00%	20,00%	44,44%	100,00%	50,00%	72,81
MAC NEUROLOGÍA	346	23	369			5,97%	4,56%	5,85%	30,45
Tratamiento de Esclerosis múltiple	116	17	133	87,22%	12,78%	33,53%	73,91%	36,04%	45,68
Tratamiento de espasticidad y distonias	230	6	236	97,46%	2,54%	66,47%	26,09%	63,96%	22,76
MAC ONCOLOGÍA	2.503	143	2.646			43,16%	28,37%	41,97%	14,12
Tratamiento de Cancer de colon	469	36	505	92,87%	7,13%	18,74%	25,17%	19,09%	19,77
Tratamiento de Cancer de mama	722	29	751	96,14%	3,86%	28,85%	20,28%	28,38%	17,75
Tratamiento de Cancer de pulmon	49	2	51	96,08%	3,92%	1,96%	1,40%	1,93%	9,61
Tratamiento de Cancer de riñon	206	11	217	94,93%	5,07%	8,23%	7,69%	8,20%	10,92
Tratamiento de Linfomas no Hodgkin	561	28	589	95,25%	4,75%	22,41%	19,58%	22,26%	9,16
Tratamiento de LLC	67	6	73	91,78%	8,22%	2,68%	4,20%	2,76%	12,46
Tratamiento de LMC y GIST	102	5	107	95,33%	4,67%	4,08%	3,50%	4,04%	16,39
Tratamiento de Mieloma múltiple	194	15	209	92,82%	7,18%	7,75%	10,49%	7,90%	9,71
Tratamiento de Tricoleucemia	20		20	100,00%	0,00%	0,80%	0,00%	0,76%	20,15
Tratamiento de Tumores de SNC	113	11	124	91,13%	8,87%	4,51%	7,69%	4,69%	5,39
MAC REUMATOLOGÍA	418	47	465			7,21%	9,33%	7,38%	57,74
Tratamiento de Artritis reumatoidea	316	42	358	88,27%	11,73%	75,60%	89,36%	76,99%	59,54
Tratamiento de Espondiloartritis	102	5	107	95,33%	4,67%	24,40%	10,64%	23,01%	52,15
Total general	44.609	4.518	49.127						29,10



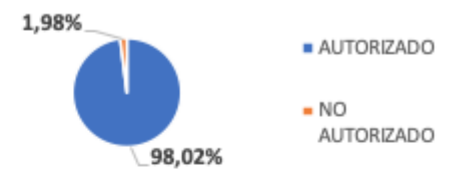
Solicitudes de Actos Cardiológicos, por Prestación



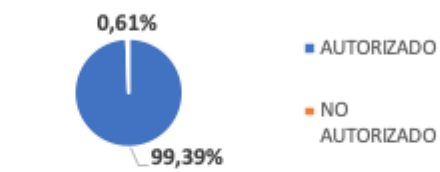
PCI-Cateterismo izq.adultos



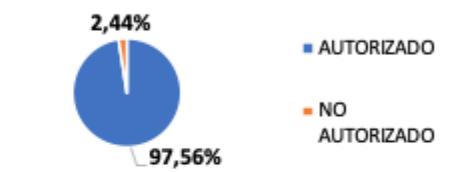
Marcapasos - Implante



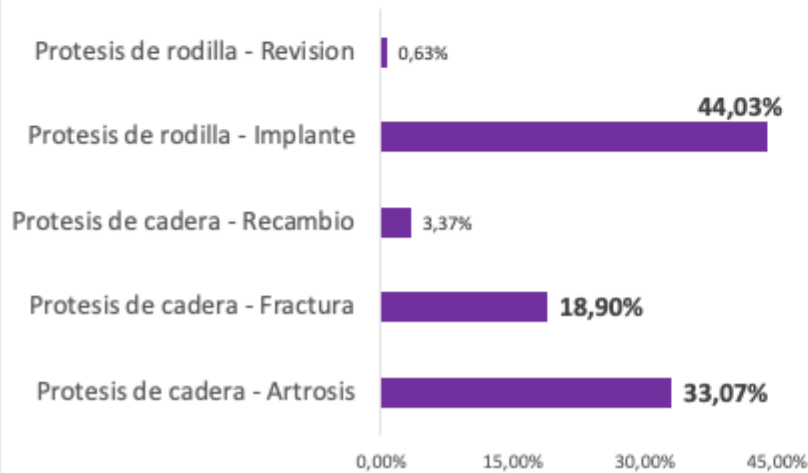
PCI-ATCP c/cateterismo izq.



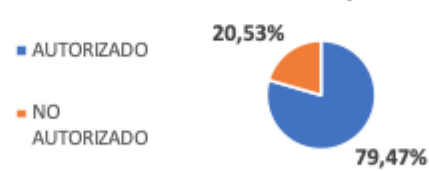
Cirugia cardiaca adultos



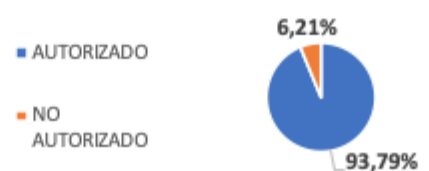
Solicitudes de Actos Traumatológicos, por Prestación



Protesis de rodilla - Implante

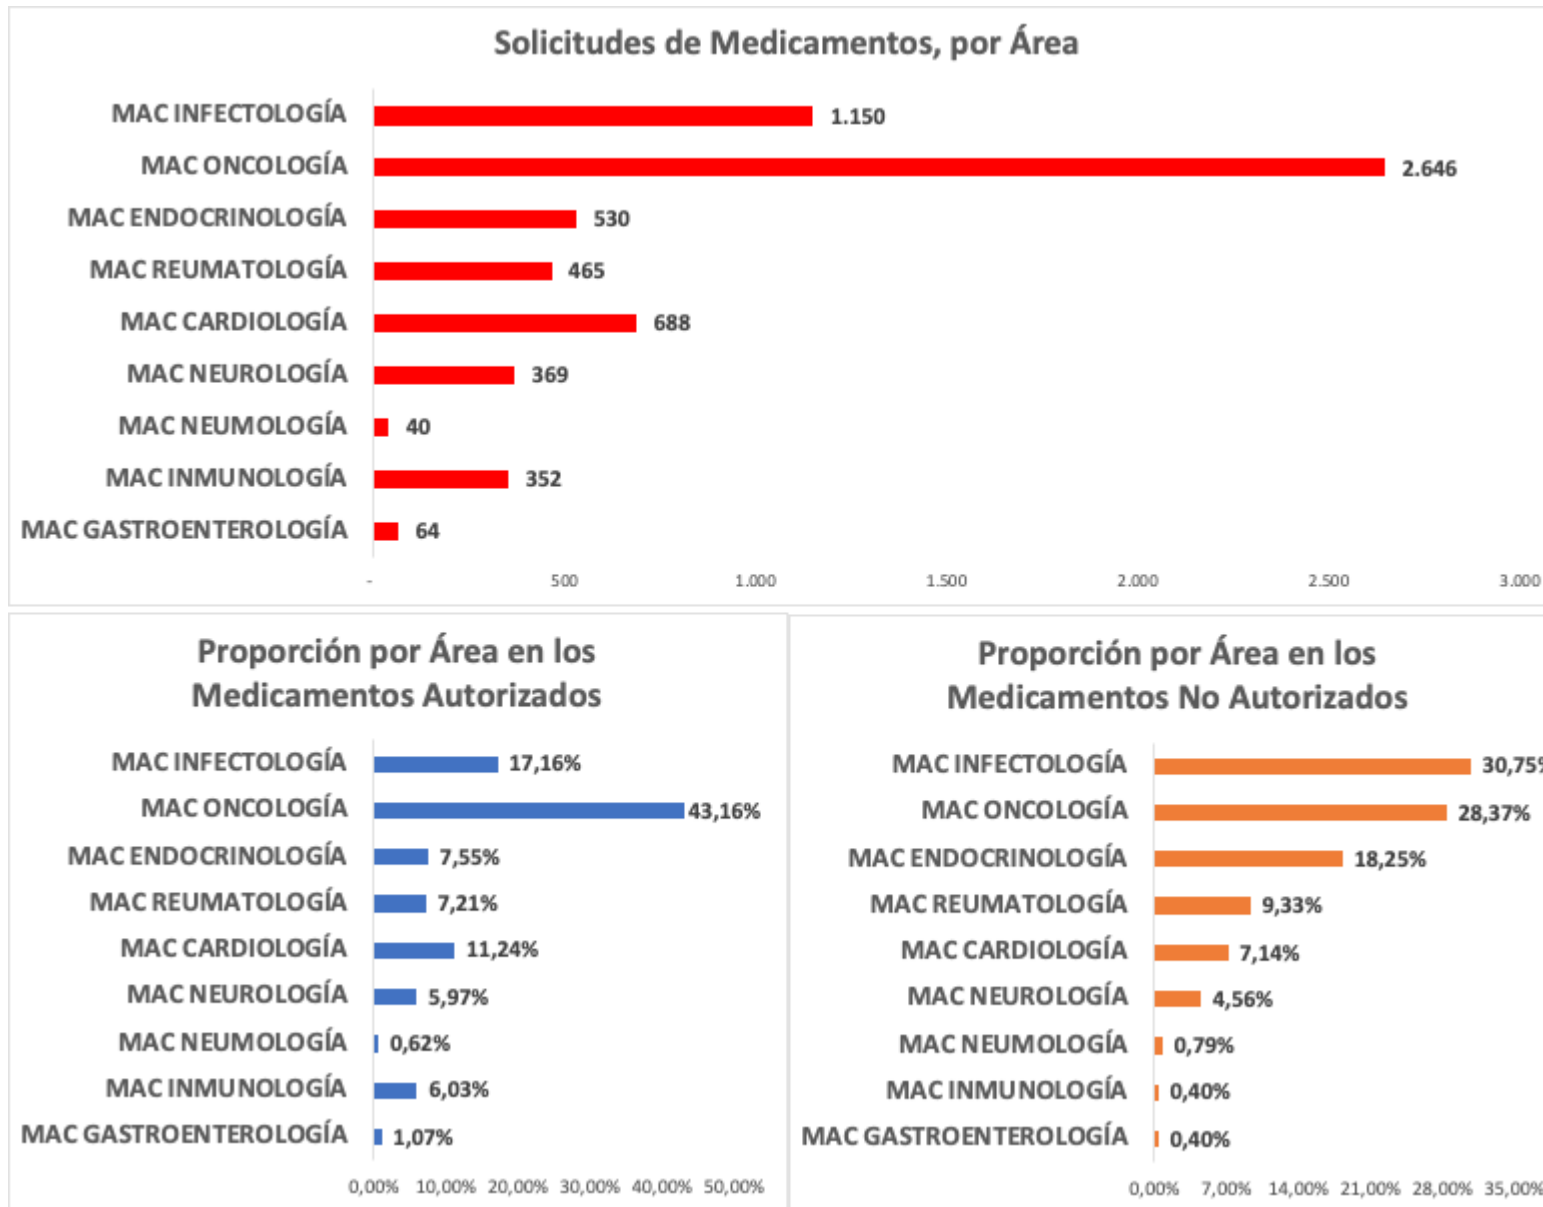


Protesis de cadera - Artrosis

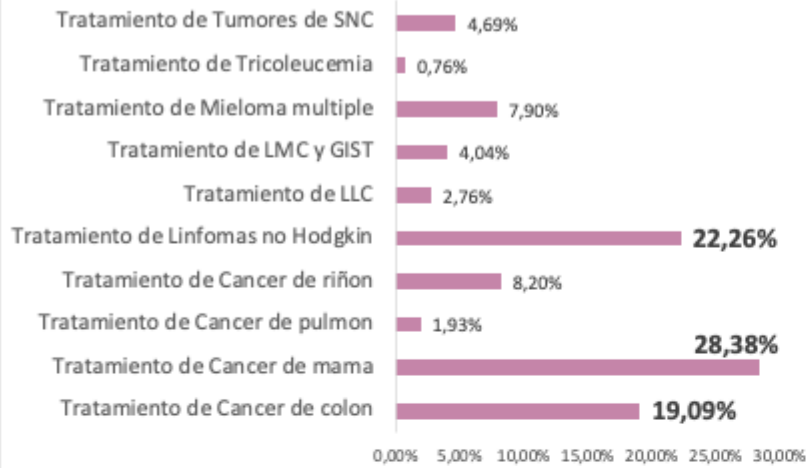


Protesis de cadera - Fractura

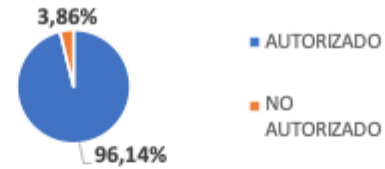




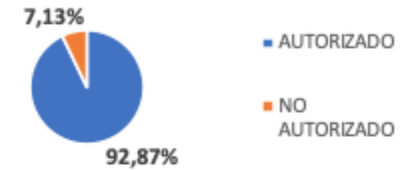
Solicitudes de Medicamentos Oncológicos, por Prestación



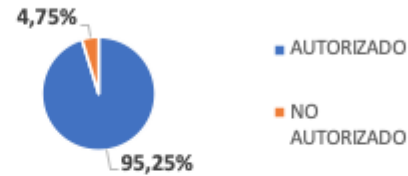
Tratamiento de Cancer de mama



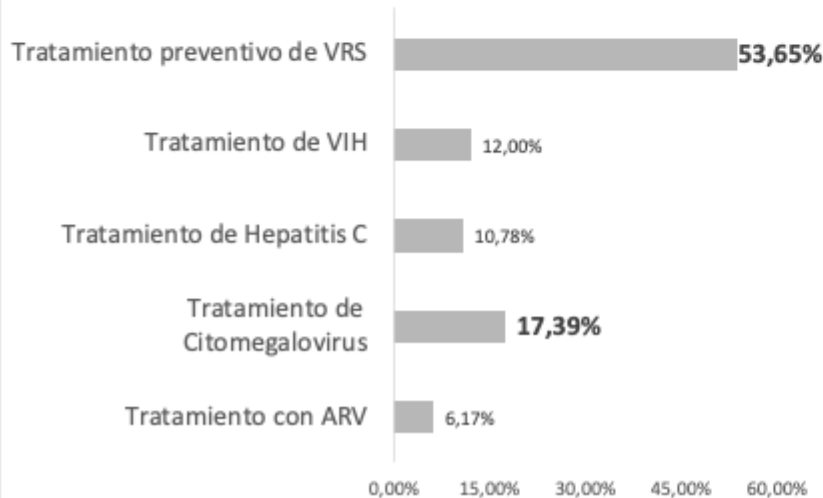
Tratamiento de Cancer de colon



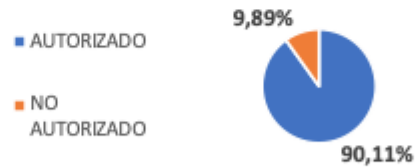
Linfomas no Hodgkin



Solicitudes de Medicamentos de Infectología, por Prestación

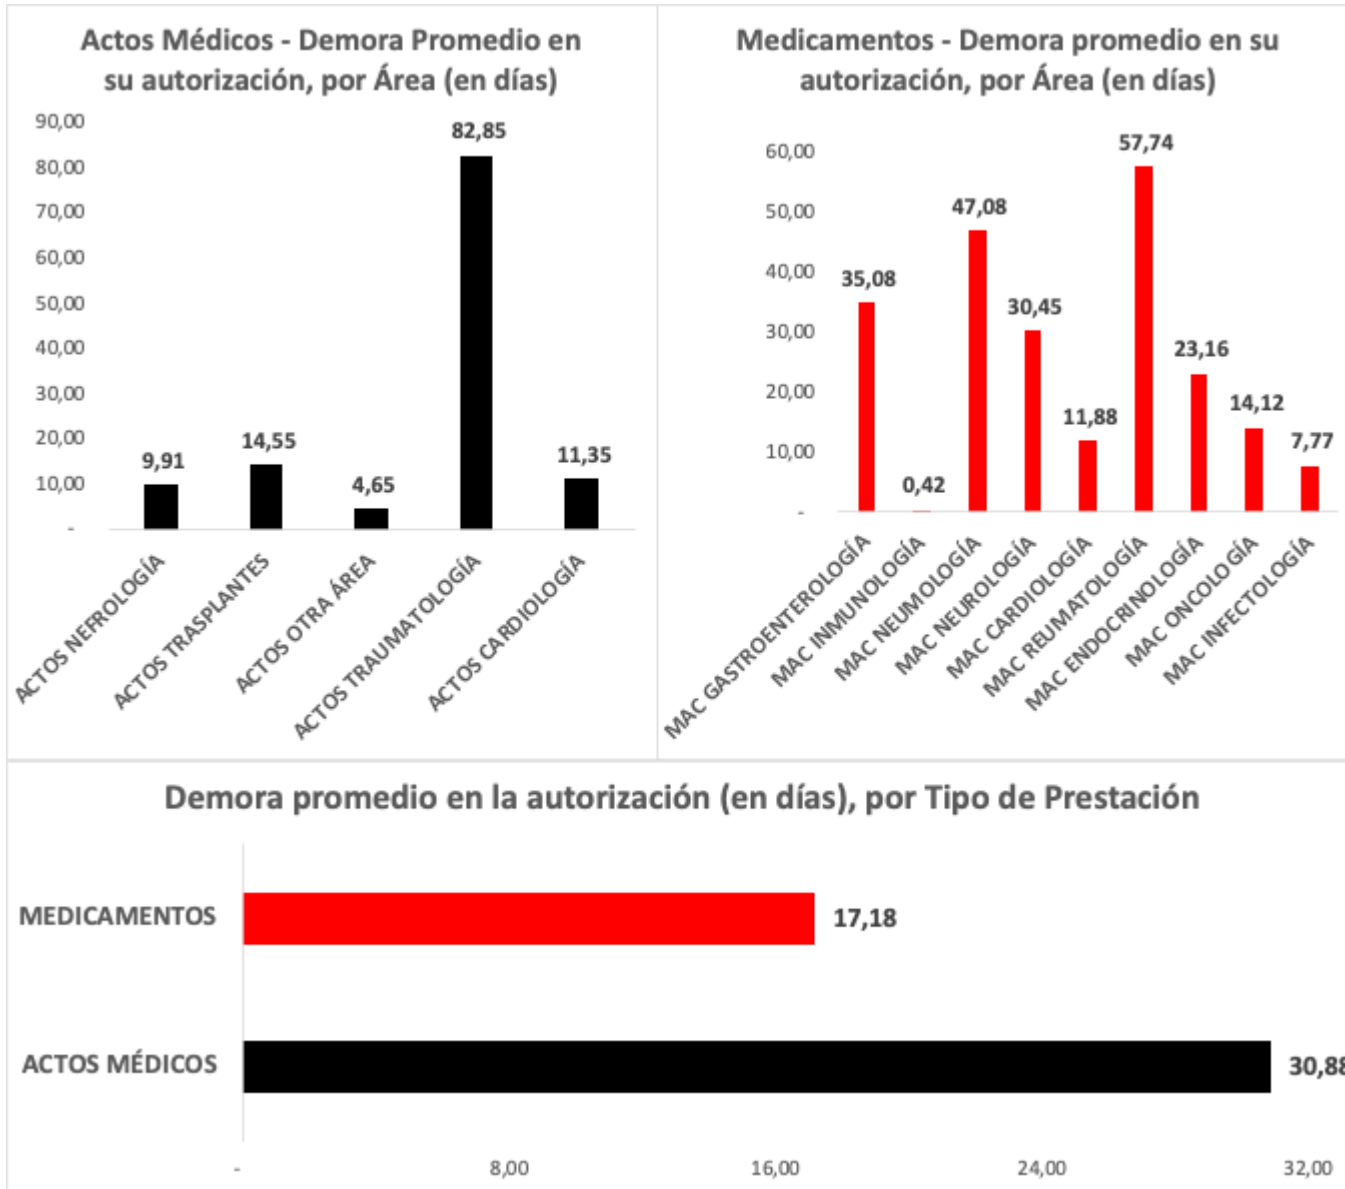


Tratamiento preventivo de VRS

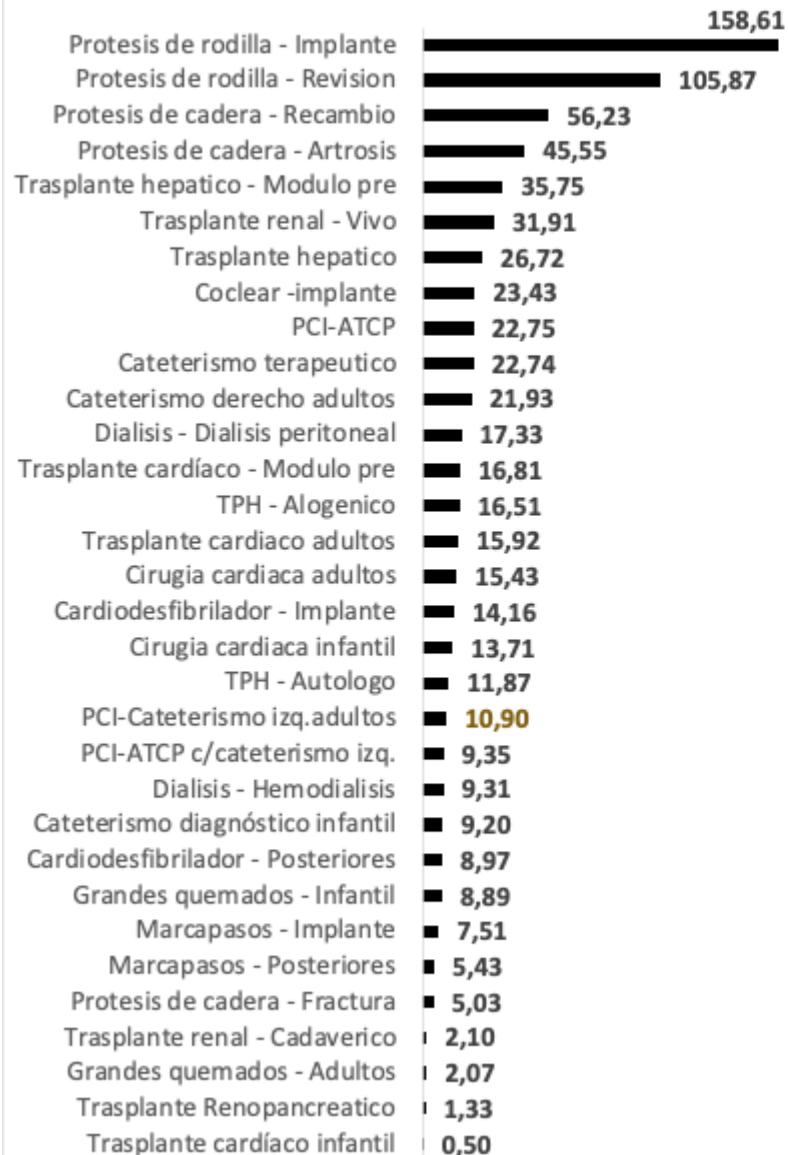


Tratamiento de Citomegalovirus

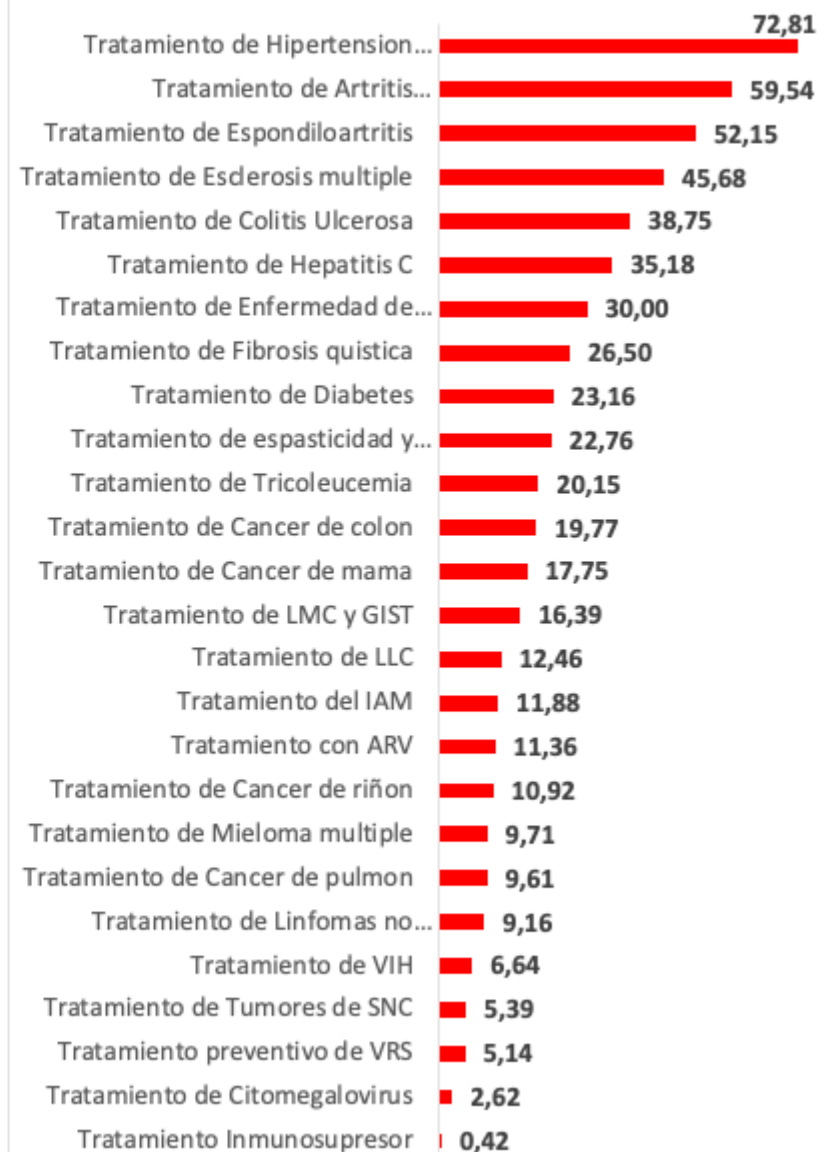




Actos Médicos Demora promedio por Prestación

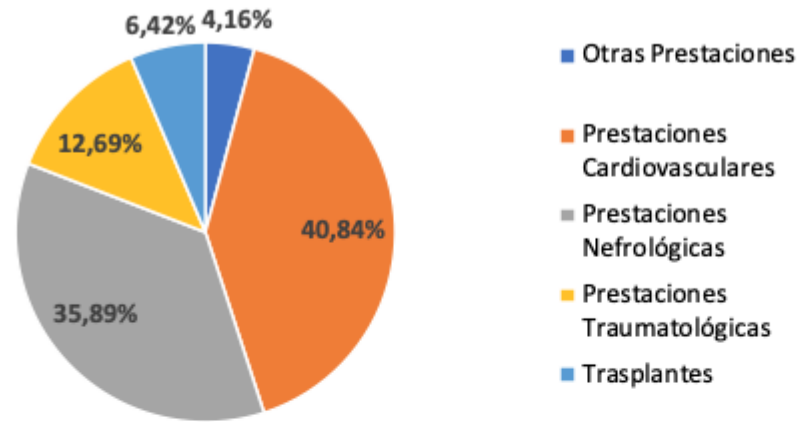


Tratamiento con Medicamentos Demora promedio por Prestación

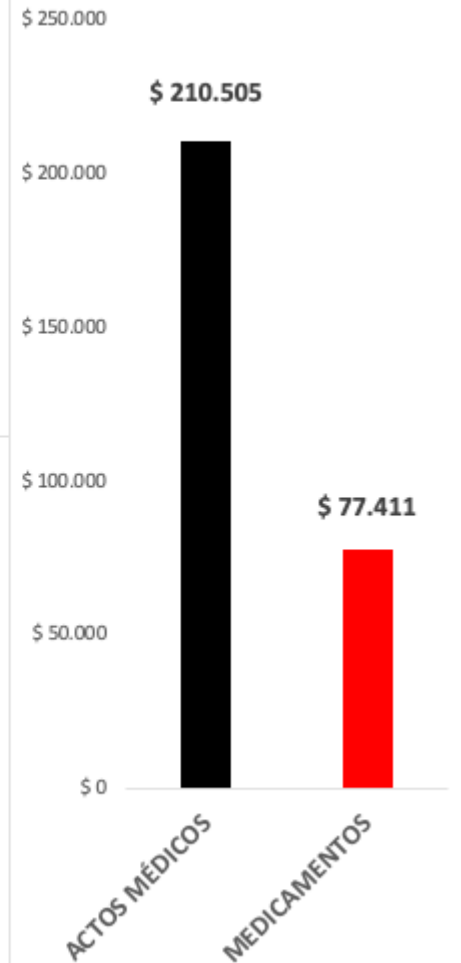


	Importe Total		Importe Promedio
Acto Médico	\$ 10.119.590.924		\$ 210.505
Otras Prestaciones	\$ 421.094.426	4,16%	\$ 332.356
Prestaciones Cardiovasculares	\$ 4.132.907.591	40,84%	\$ 160.333
Prestaciones Nefrológicas	\$ 3.631.579.645	35,89%	\$ 415.370
Prestaciones Traumatológicas	\$ 1.284.629.434	12,69%	\$ 132.874
Trasplantes	\$ 649.379.828	6,42%	\$ 248.044
Tratamiento con medicamentos	\$ 1.916.470.473		\$ 77.411
Hemato-oncológicos	\$ 240.830.249	12,57%	\$ 81.170
Infectológicos	\$ 57.777.847	3,01%	\$ 64.484
Neurológicos	\$ 162.392.381	8,47%	\$ 67.776
Oncológicos	\$ 721.259.195	37,63%	\$ 158.449
Otras Prestaciones	\$ 134.822.708	7,03%	\$ 23.875
Reumatológicos	\$ 420.874.185	21,96%	\$ 132.936
Trasplante Renal	\$ 178.513.908	9,31%	\$ 34.778
Total general	\$ 12.036.061.397		\$ 165.262

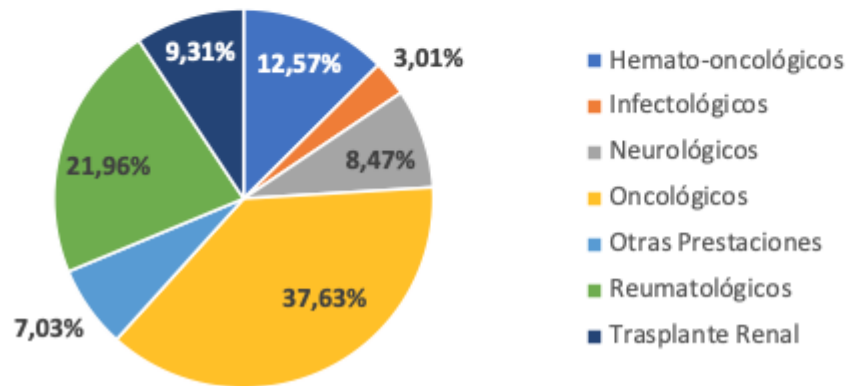
Gasto total en Actos Médicos, por Área



Importe promedio, por Tipo de Prestación



Gasto total en Medicamentos, por Área



Actos Médicos - Importe promedio por Área

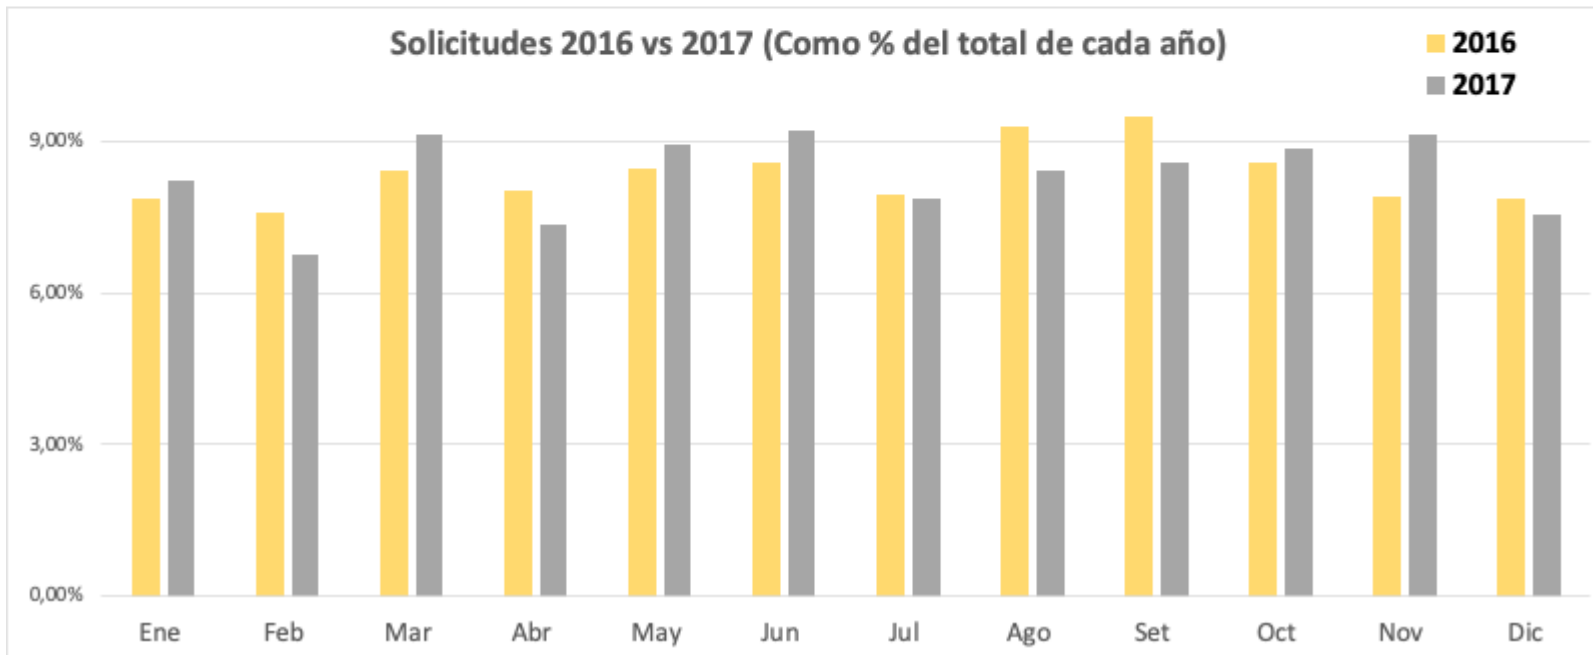
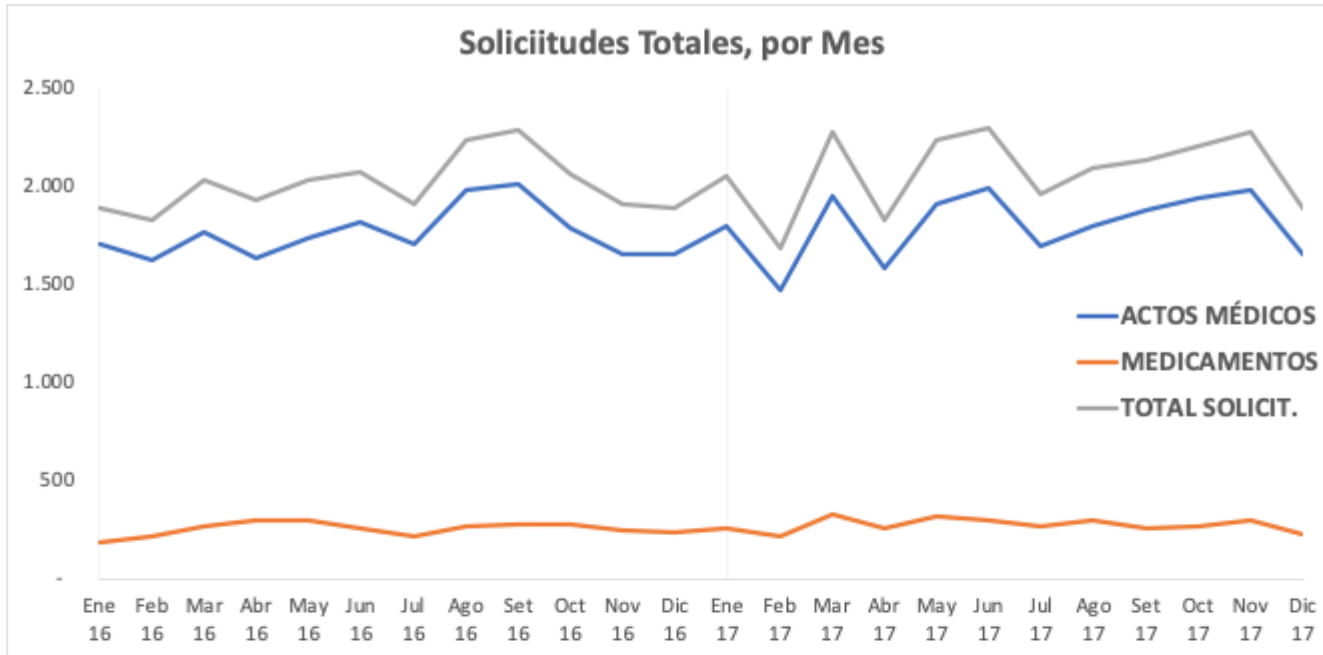


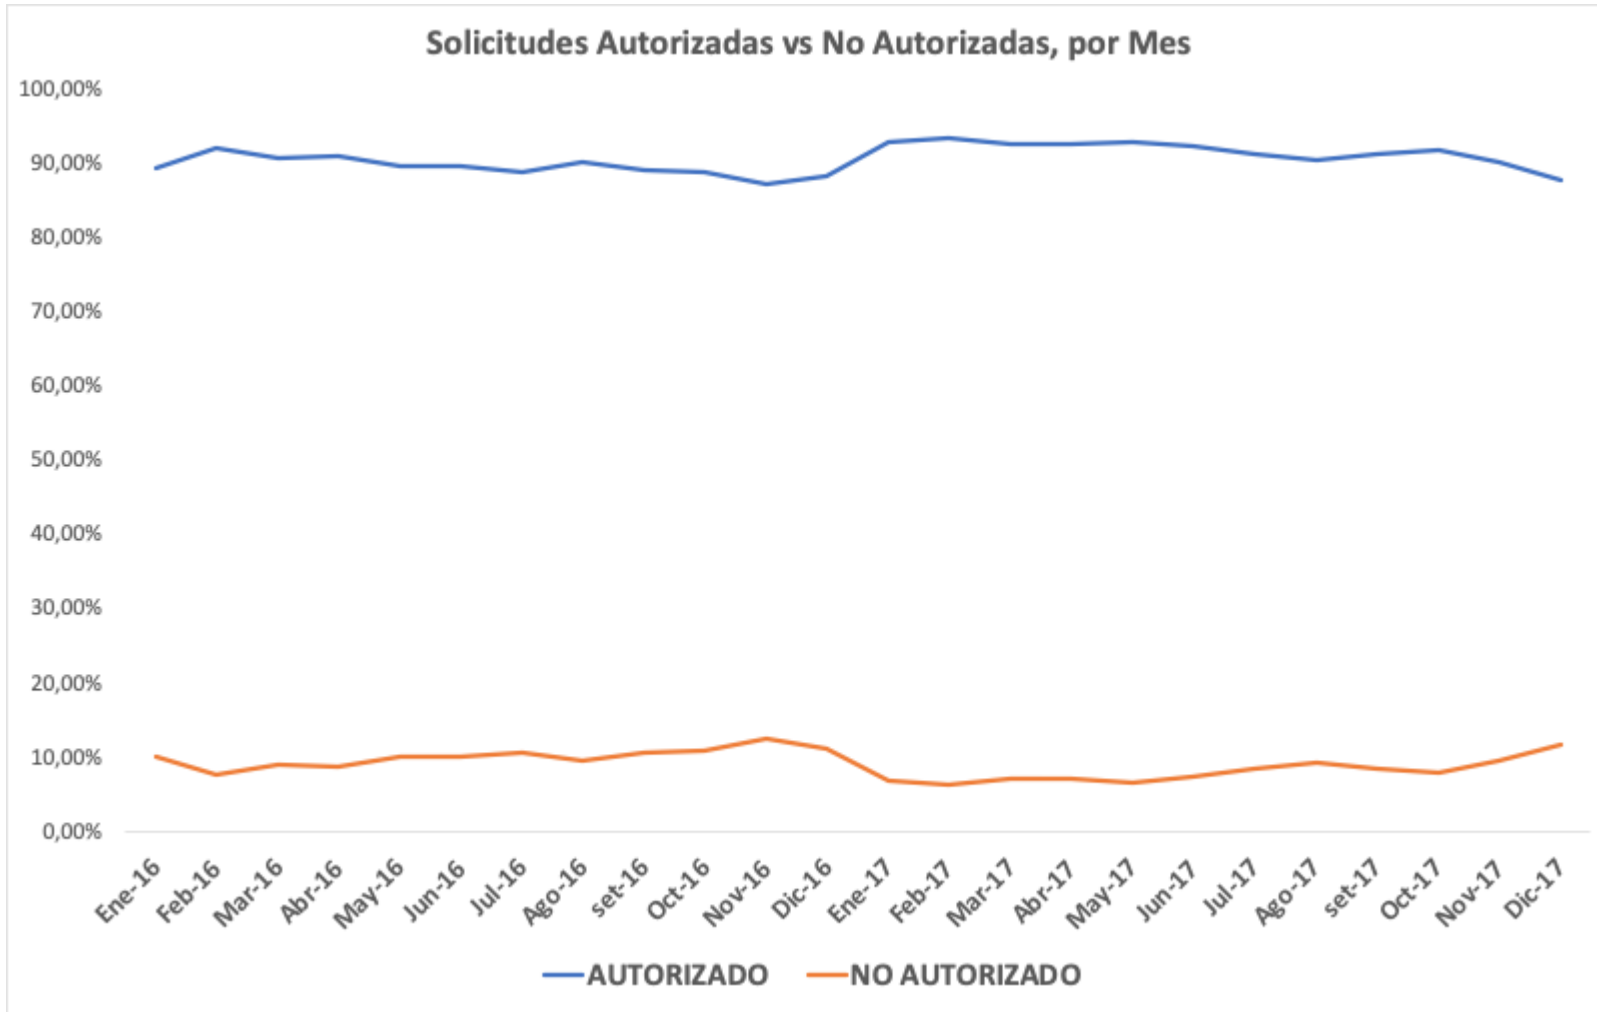
Medicamentos - Importe promedio por Área



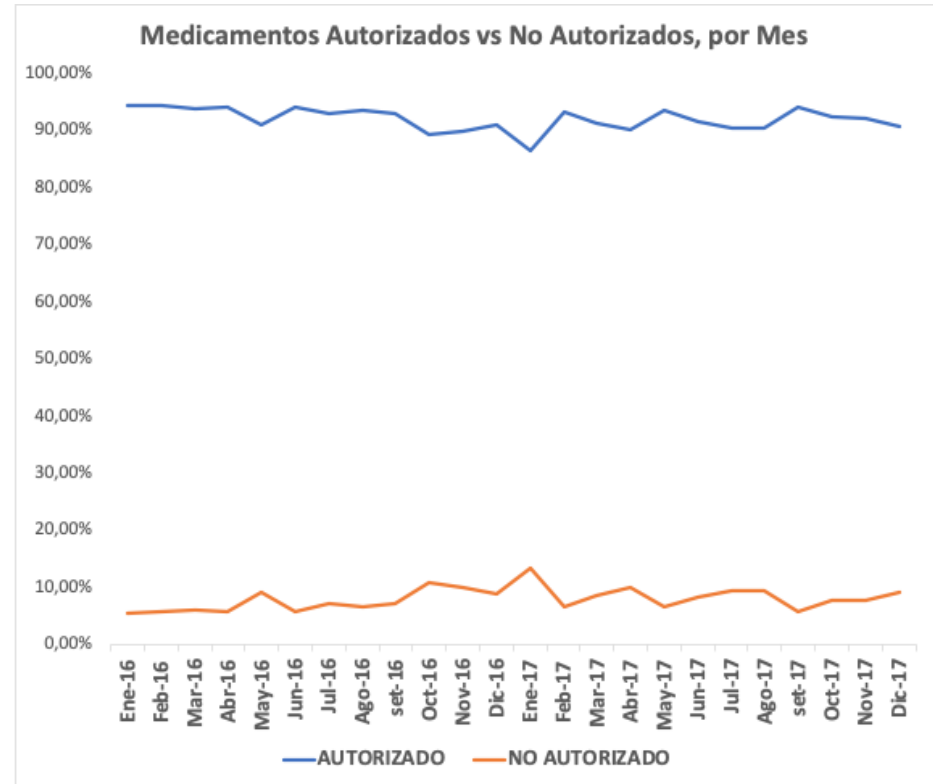
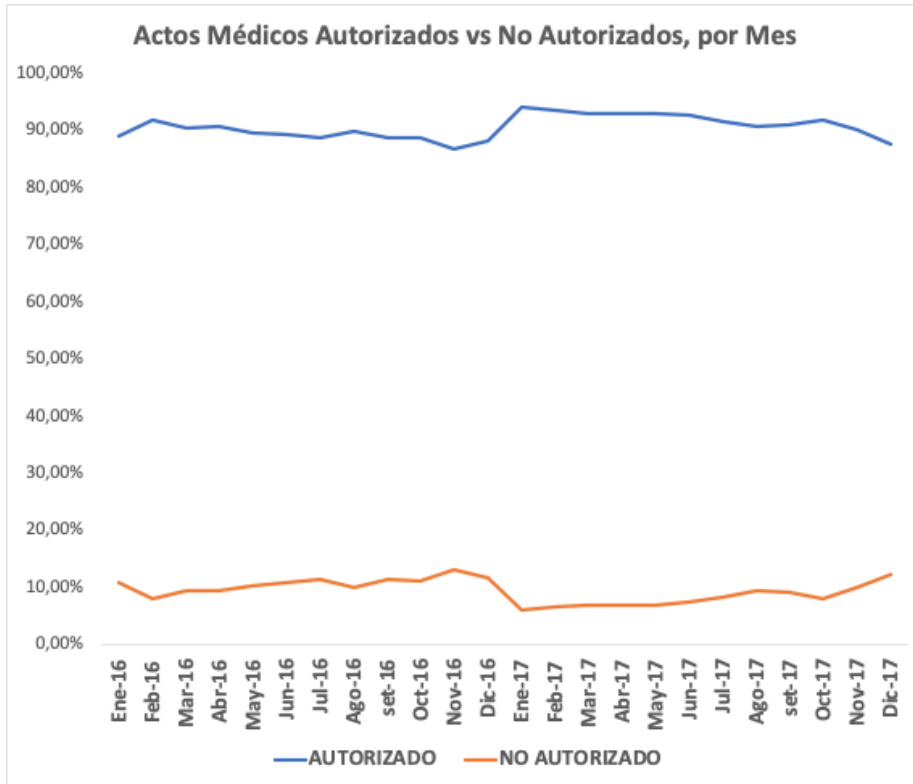
Análisis Temporal

	AUTORIZADO	NO AUTORIZADO	Total general	% Autorizado	% No Autorizado
2016	21.668	2.470	24.138		
Ene 2016	1.699	196	1.895	89,66%	10,34%
Feb 2016	1.693	142	1.835	92,26%	7,74%
Mar 2016	1.850	184	2.034	90,95%	9,05%
Abr 2016	1.767	170	1.937	91,22%	8,78%
May 2016	1.834	207	2.041	89,86%	10,14%
Jun 2016	1.863	211	2.074	89,83%	10,17%
Jul 2016	1.709	208	1.917	89,15%	10,85%
Ago 2016	2.027	216	2.243	90,37%	9,63%
Set 2016	2.045	248	2.293	89,18%	10,82%
Oct 2016	1.837	229	2.066	88,92%	11,08%
Nov 2016	1.666	243	1.909	87,27%	12,73%
Dic 2016	1.678	216	1.894	88,60%	11,40%
2017	22.941	2.048	24.989		
Ene 2017	1.917	142	2.059	93,10%	6,90%
Feb 2017	1.577	110	1.687	93,48%	6,52%
Mar 2017	2.116	165	2.281	92,77%	7,23%
Abr 2017	1.702	134	1.836	92,70%	7,30%
May 2017	2.084	153	2.237	93,16%	6,84%
Jun 2017	2.126	172	2.298	92,52%	7,48%
Jul 2017	1.800	168	1.968	91,46%	8,54%
Ago 2017	1.902	197	2.099	90,61%	9,39%
Set 2017	1.958	185	2.143	91,37%	8,63%
Oct 2017	2.031	177	2.208	91,98%	8,02%
Nov 2017	2.063	219	2.282	90,40%	9,60%
Dic 2017	1.665	226	1.891	88,05%	11,95%
Total general	44.609	4.518	49.127		



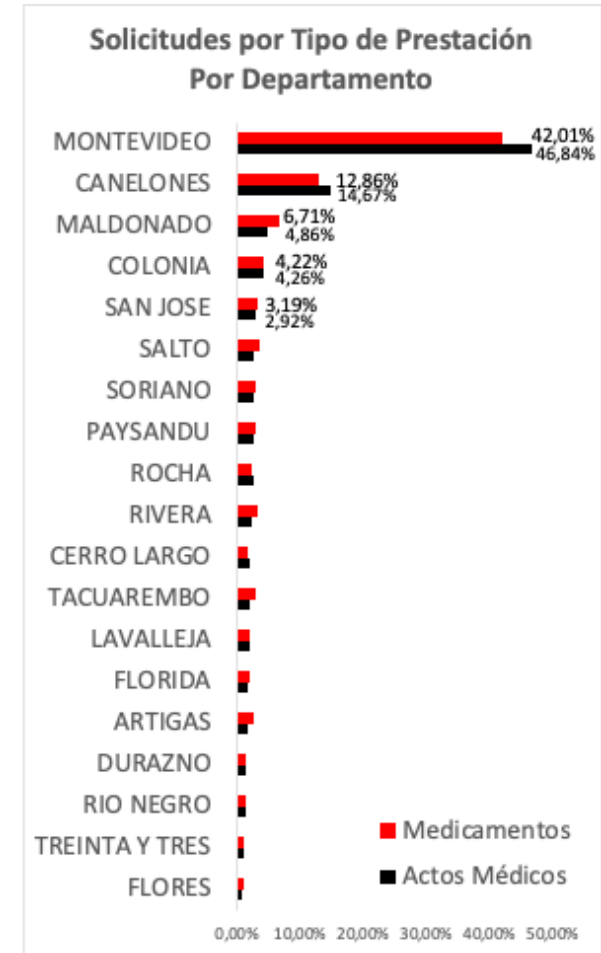
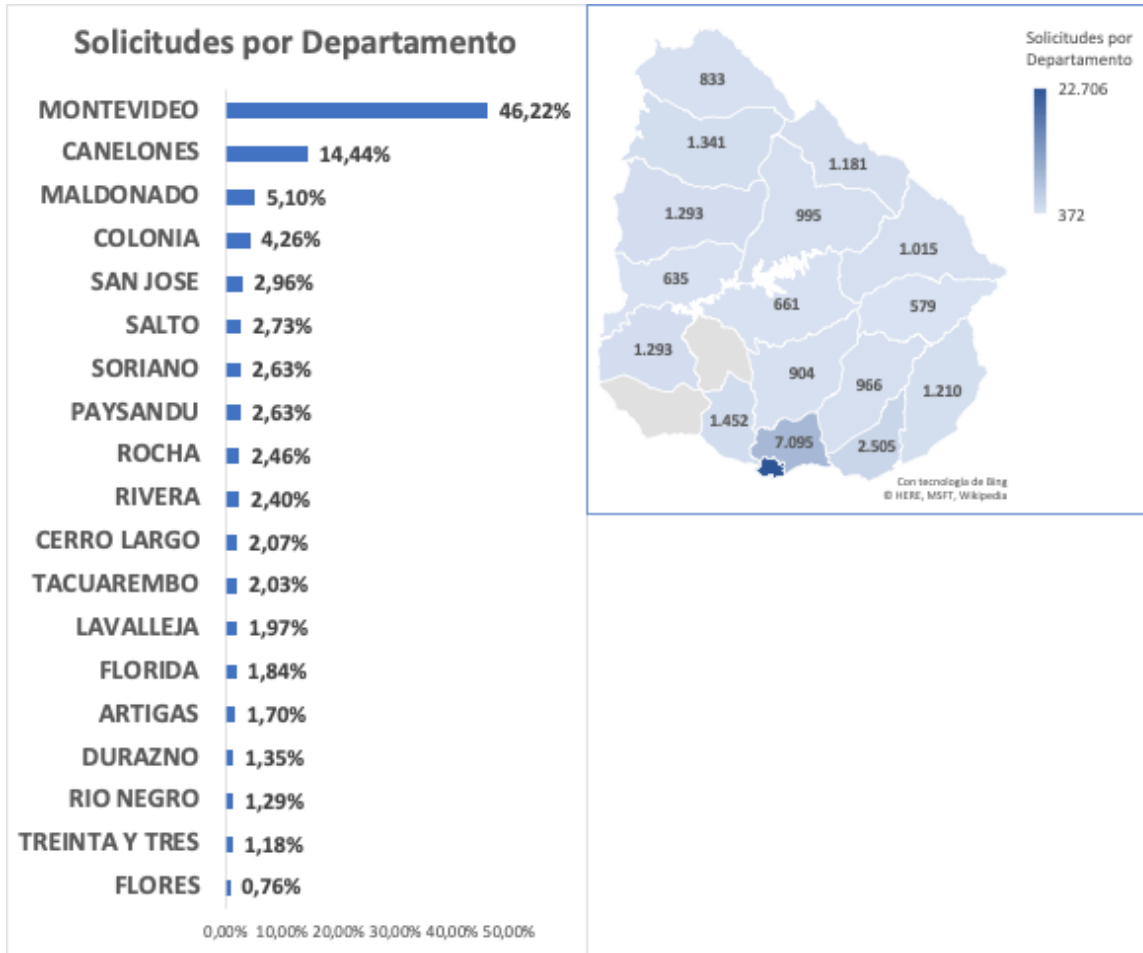


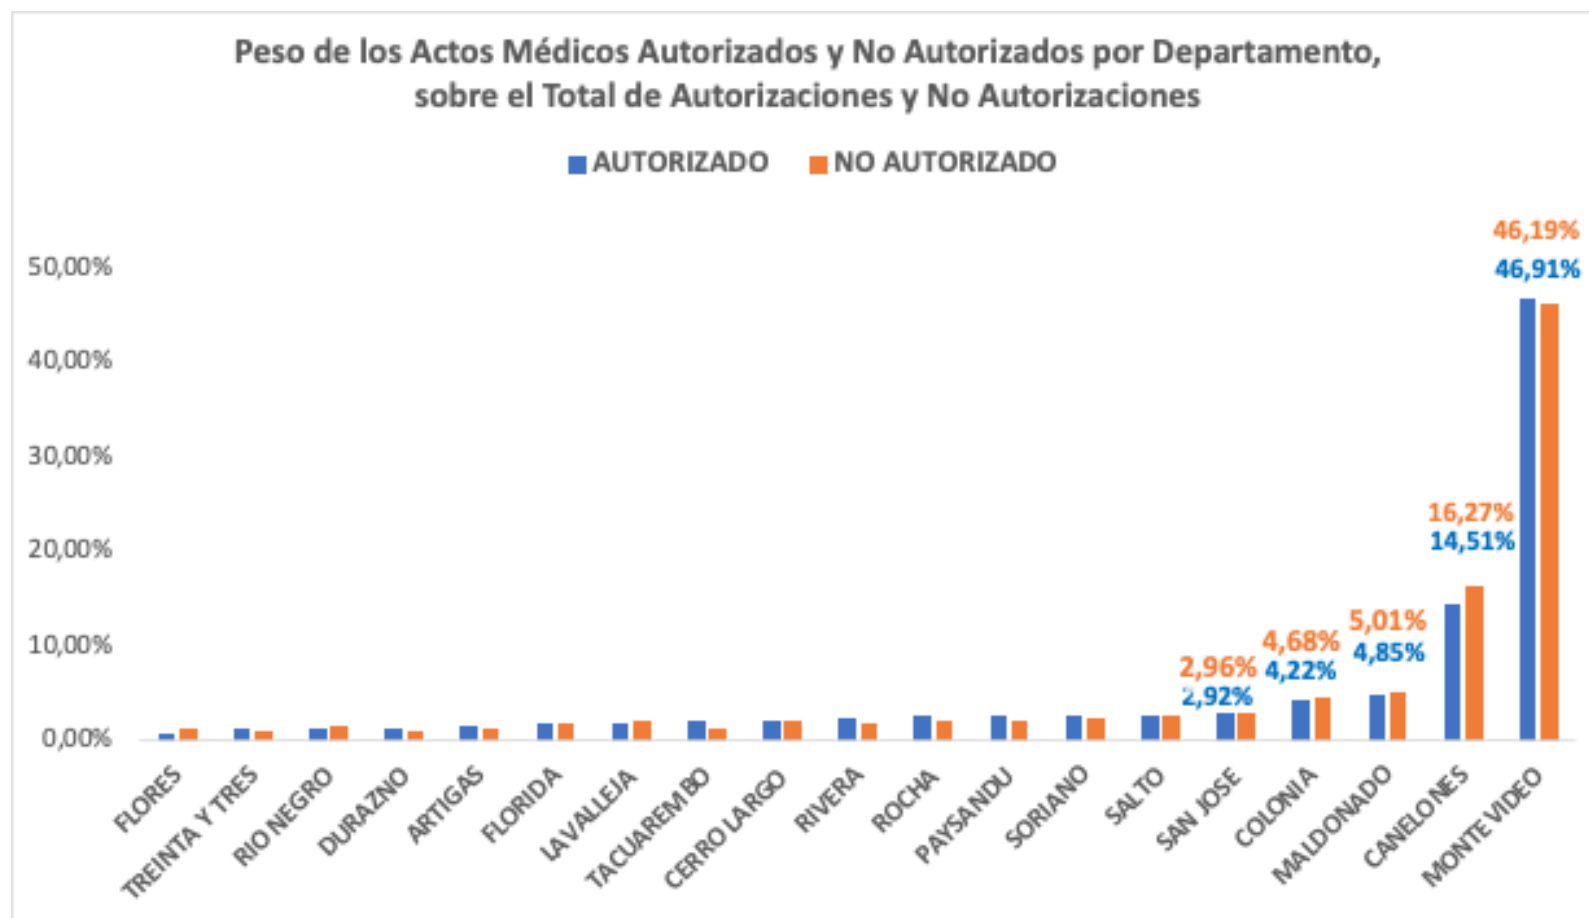
	Acto Médico					Tratamiento con medicamentos				
	NO		TOTAL	% AUT.	% NO AUT.	NO		TOTAL	% AUT.	% NO AUT.
	AUTORIZADO	AUTORIZADO				AUTORIZADO	AUTORIZADO			
2016	18.865	2.245	21.110			2.803	225	3.028		
Ene	1.526	186	1.712	89,14%	10,86%	173	10	183	94,54%	5,46%
Feb	1.493	130	1.623	91,99%	8,01%	200	12	212	94,34%	5,66%
Mar	1.600	168	1.768	90,50%	9,50%	250	16	266	93,98%	6,02%
Abr	1.488	153	1.641	90,68%	9,32%	279	17	296	94,26%	5,74%
May	1.563	180	1.743	89,67%	10,33%	271	27	298	90,94%	9,06%
Jun	1.623	196	1.819	89,22%	10,78%	240	15	255	94,12%	5,88%
Jul	1.513	193	1.706	88,69%	11,31%	196	15	211	92,89%	7,11%
Ago	1.782	199	1.981	89,95%	10,05%	245	17	262	93,51%	6,49%
Set	1.783	228	2.011	88,66%	11,34%	262	20	282	92,91%	7,09%
Oct	1.588	199	1.787	88,86%	11,14%	249	30	279	89,25%	10,75%
Nov	1.442	218	1.660	86,87%	13,13%	224	25	249	89,96%	10,04%
Dic	1.464	195	1.659	88,25%	11,75%	214	21	235	91,06%	8,94%
2017	19.944	1.769	21.713			2.997	279	3.276		
Ene	1.698	108	1.806	94,02%	5,98%	219	34	253	86,56%	13,44%
Feb	1.379	96	1.475	93,49%	6,51%	198	14	212	93,40%	6,60%
Mar	1.819	137	1.956	93,00%	7,00%	297	28	325	91,38%	8,62%
Abr	1.475	109	1.584	93,12%	6,88%	227	25	252	90,08%	9,92%
May	1.782	132	1.914	93,10%	6,90%	302	21	323	93,50%	6,50%
Jun	1.850	147	1.997	92,64%	7,36%	276	25	301	91,69%	8,31%
Jul	1.559	143	1.702	91,60%	8,40%	241	25	266	90,60%	9,40%
Ago	1.636	169	1.805	90,64%	9,36%	266	28	294	90,48%	9,52%
Set	1.712	170	1.882	90,97%	9,03%	246	15	261	94,25%	5,75%
Oct	1.789	157	1.946	91,93%	8,07%	242	20	262	92,37%	7,63%
Nov	1.787	196	1.983	90,12%	9,88%	276	23	299	92,31%	7,69%
Dic	1.458	205	1.663	87,67%	12,33%	207	21	228	90,79%	9,21%
Total general	38.809	4.014	42.823			5.800	504	6.304	92,01%	7,99%

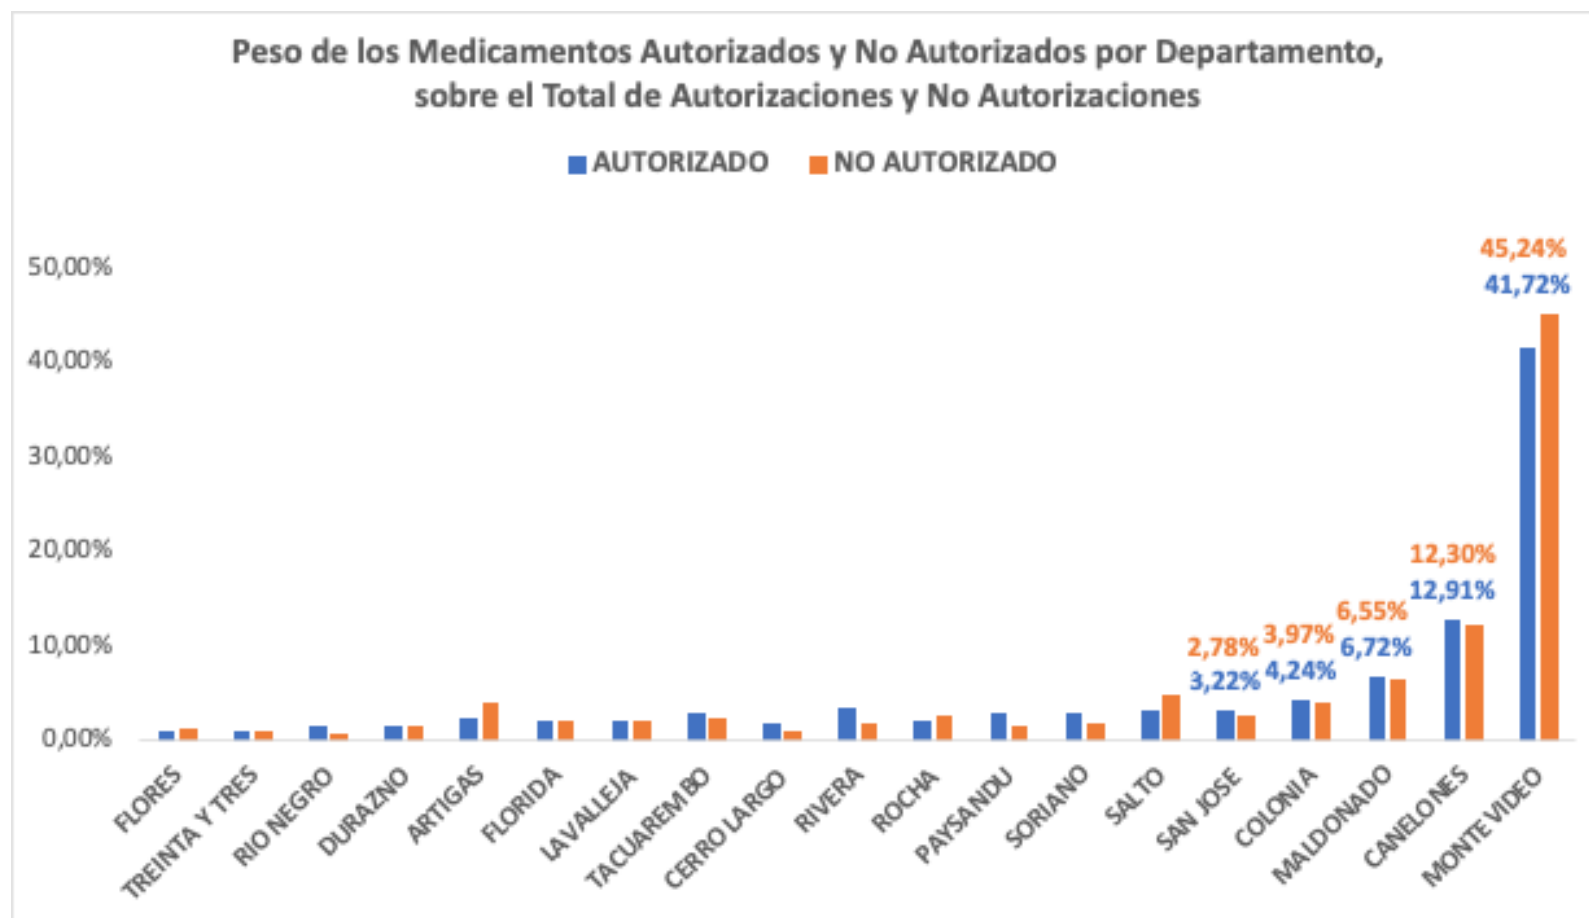


Análisis Territorial

	AUTORIZADO	NO AUTORIZADO	Total general	% AUT	% NO AUT	% TOTAL
Acto Médico	38.809	4.014	42.823			
ARTIGAS	618	51	669	1,59%	1,27%	1,56%
CANELONES	5.631	653	6.284	14,51%	16,27%	14,67%
CERRO LARGO	829	79	908	2,14%	1,97%	2,12%
COLONIA	1.637	188	1.825	4,22%	4,68%	4,26%
DURAZNO	526	44	570	1,36%	1,10%	1,33%
FLORES	249	55	304	0,64%	1,37%	0,71%
FLORIDA	704	75	779	1,81%	1,87%	1,82%
LAVALLEJA	747	84	831	1,92%	2,09%	1,94%
MALDONADO	1.881	201	2.082	4,85%	5,01%	4,86%
MONTEVIDEO	18.204	1.854	20.058	46,91%	46,19%	46,84%
PAYSANDU	1.022	88	1.110	2,63%	2,19%	2,59%
RIO NEGRO	476	66	542	1,23%	1,64%	1,27%
RIVERA	900	74	974	2,32%	1,84%	2,27%
ROCHA	983	88	1.071	2,53%	2,19%	2,50%
SALTO	1.015	109	1.124	2,62%	2,72%	2,62%
SAN JOSE	1.132	119	1.251	2,92%	2,96%	2,92%
SORIANO	1.018	93	1.111	2,62%	2,32%	2,59%
TACUAREMBO	761	54	815	1,96%	1,35%	1,90%
TREINTA Y TRES	476	39	515	1,23%	0,97%	1,20%
Tratamiento con medicamento	5.800	504	6.304			
ARTIGAS	144	20	164	2,48%	3,97%	2,60%
CANELONES	749	62	811	12,91%	12,30%	12,86%
CERRO LARGO	102	5	107	1,76%	0,99%	1,70%
COLONIA	246	20	266	4,24%	3,97%	4,22%
DURAZNO	83	8	91	1,43%	1,59%	1,44%
FLORES	62	6	68	1,07%	1,19%	1,08%
FLORIDA	114	11	125	1,97%	2,18%	1,98%
LAVALLEJA	124	11	135	2,14%	2,18%	2,14%
MALDONADO	390	33	423	6,72%	6,55%	6,71%
MONTEVIDEO	2.420	228	2.648	41,72%	45,24%	42,01%
PAYSANDU	175	8	183	3,02%	1,59%	2,90%
RIO NEGRO	89	4	93	1,53%	0,79%	1,48%
RIVERA	198	9	207	3,41%	1,79%	3,28%
ROCHA	125	14	139	2,16%	2,78%	2,20%
SALTO	192	25	217	3,31%	4,96%	3,44%
SAN JOSE	187	14	201	3,22%	2,78%	3,19%
SORIANO	173	9	182	2,98%	1,79%	2,89%
TACUAREMBO	168	12	180	2,90%	2,38%	2,86%
TREINTA Y TRES	59	5	64	1,02%	0,99%	1,02%
Total general	44.609	4.518	49.127			



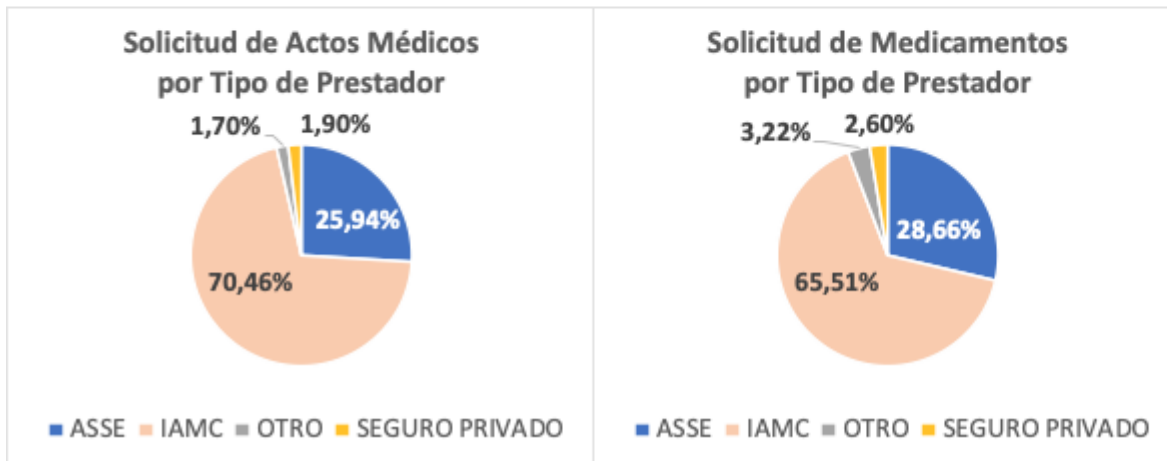
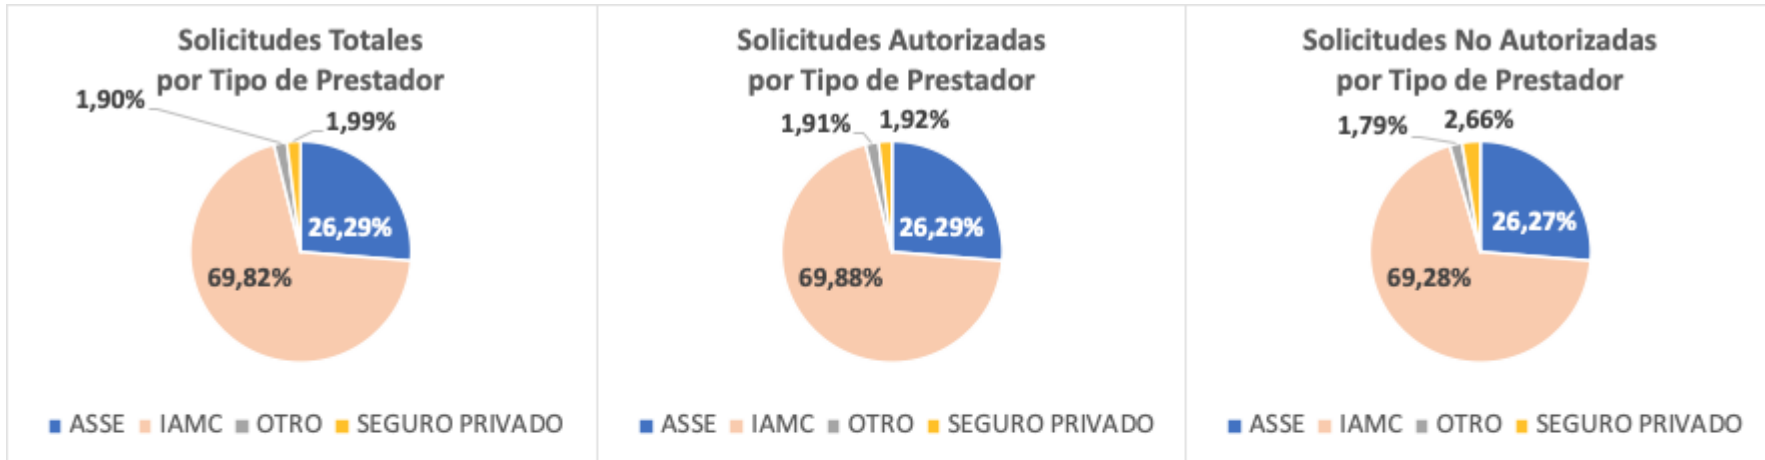




Análisis por Prestador

	AUTORIZADO	NO AUTORIZADO	Total general	% AUT.	% NO AUT.	% Tot.
ASSE	11.729	1.187	12.916	26,29%	26,27%	26,29%
IAMC	31.172	3.130	34.302	69,88%	69,28%	69,82%
OTRO	850	81	931	1,91%	1,79%	1,90%
SEGURO PRIVADO	858	120	978	1,92%	2,66%	1,99%
Total general	44.609	4.518	49.127			

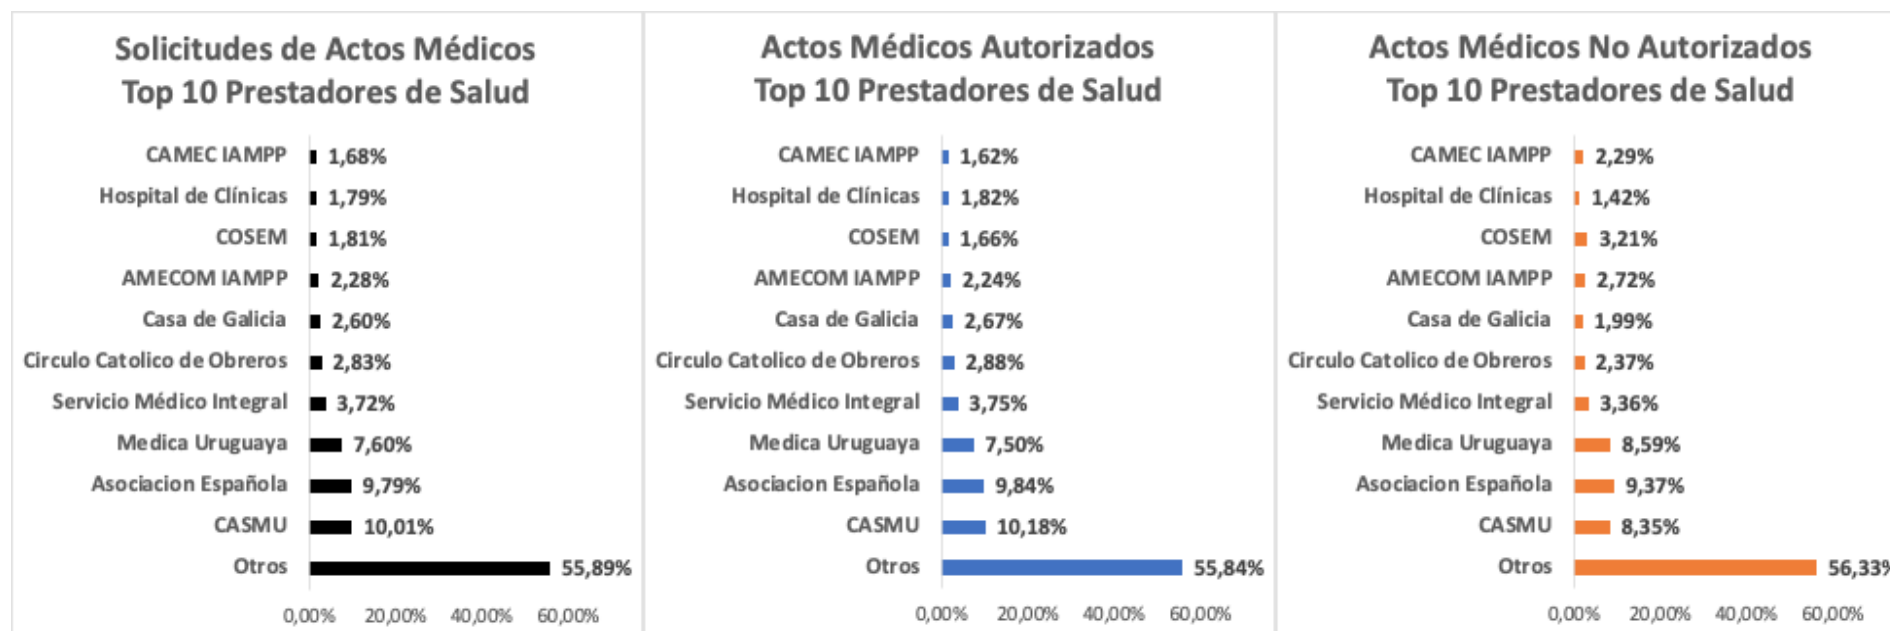
	AUTORIZADO	NO AUTORIZADO	Total general	% AUT.	% NO AUT.	% Tot.
Acto Médico	38.809	4.014	42.823			
ASSE	10.098	1.011	11.109	26,02%	25,19%	25,94%
IAMC	27.345	2.827	30.172	70,46%	70,43%	70,46%
OTRO	660	68	728	1,70%	1,69%	1,70%
SEGURO PRIVADO	706	108	814	1,82%	2,69%	1,90%
Tratamiento con medicamentos	5.800	504	6.304			
ASSE	1.631	176	1.807	28,12%	34,92%	28,66%
IAMC	3.827	303	4.130	65,98%	60,12%	65,51%
OTRO	190	13	203	3,28%	2,58%	3,22%
SEGURO PRIVADO	152	12	164	2,62%	2,38%	2,60%
Total general	44.609	4.518	49.127			



Principales Prestadores de Actos Médicos (según % de solicitudes)

	AUTORIZADO	NO AUTORIZADO	Total general	% AUT	% NO AUT	% SOLICIT.
Otros	21.671	2.261	23.932	55,84%	56,33%	55,89%
CASMU	3.950	335	4.285	10,18%	8,35%	10,01%
Asociacion Española	3.818	376	4.194	9,84%	9,37%	9,79%
Medica Uruguaya	2.909	345	3.254	7,50%	8,59%	7,60%
Servicio Médico Integral	1.457	135	1.592	3,75%	3,36%	3,72%
Circulo Catolico de Obreros	1.119	95	1.214	2,88%	2,37%	2,83%
Casa de Galicia	1.035	80	1.115	2,67%	1,99%	2,60%
AMECOM IAMPP	869	109	978	2,24%	2,72%	2,28%
COSEM	645	129	774	1,66%	3,21%	1,81%
Hospital de Clínicas	708	57	765	1,82%	1,42%	1,79%
CAMEC IAMPP	628	92	720	1,62%	2,29%	1,68%

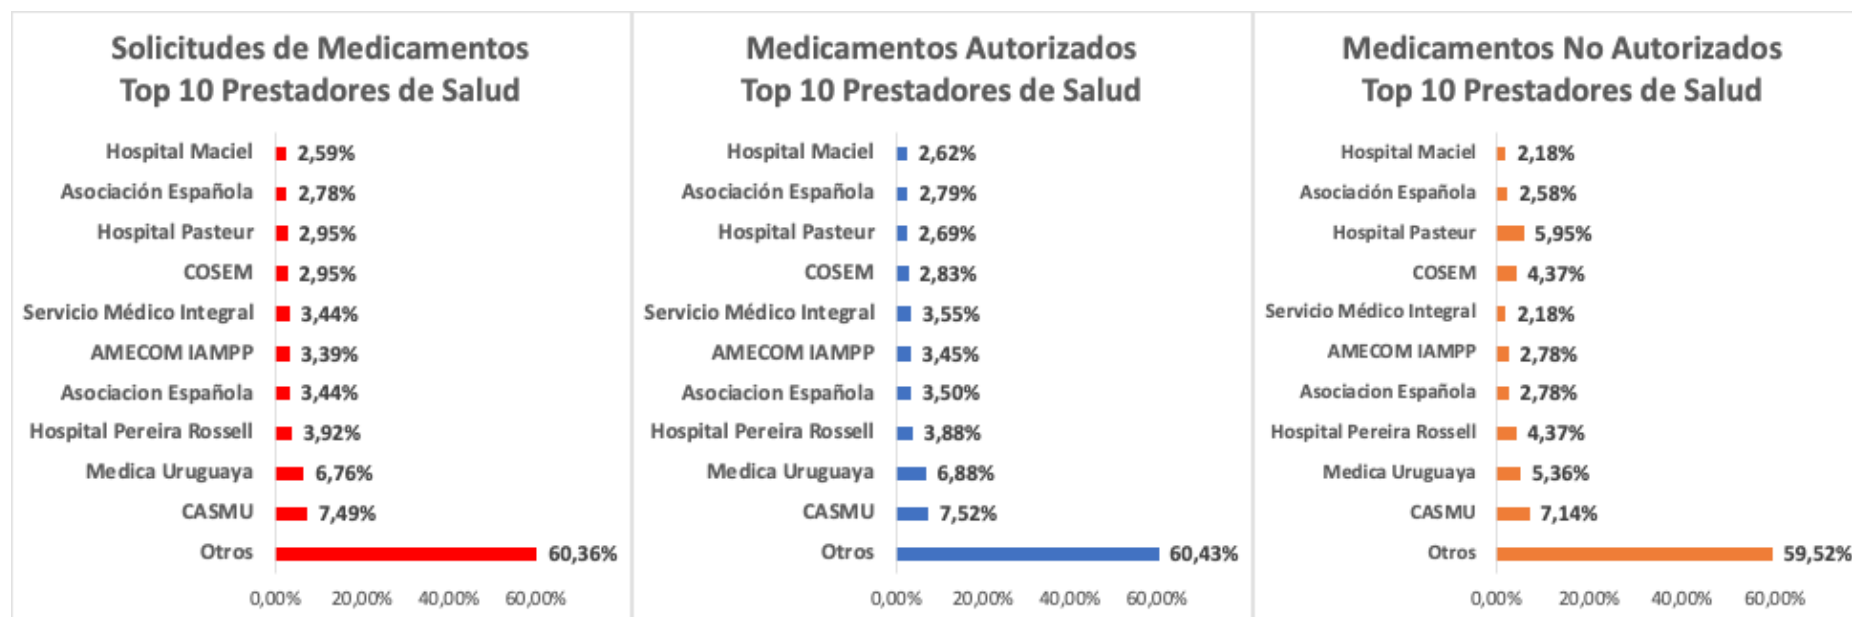
* "Otros": Los más de 130 prestadores restantes.



Principales Prestadores de Medicamentos (según % de solicitudes)

	AUTORIZADO	NO AUTORIZADO	Total general	% AUT	% NO AUT	% SOLICIT.
Otros	3505	300	3805	60,43%	59,52%	60,36%
CASMU	436	36	472	7,52%	7,14%	7,49%
Medica Uruguaya	399	27	426	6,88%	5,36%	6,76%
Hospital Pereira Rossell	225	22	247	3,88%	4,37%	3,92%
Asociacion Española	203	14	217	3,50%	2,78%	3,44%
AMECOM IAMPP	200	14	214	3,45%	2,78%	3,39%
Servicio Médico Integral	206	11	217	3,55%	2,18%	3,44%
COSEM	164	22	186	2,83%	4,37%	2,95%
Hospital Pasteur	156	30	186	2,69%	5,95%	2,95%
Asociación Española	162	13	175	2,79%	2,58%	2,78%
Hospital Maciel	152	11	163	2,62%	2,18%	2,59%

* "Otros": Los más de 100 prestadores restantes.



Análisis por Médico Solicitante

	AUTORIZADO	NO AUTORIZADO	Total general	% AUT.	% NO AUT.	% Solicitado sobre el total	% Acumulado
OSCAR DIEGO MIGUES GONZALEZ	235	46	281	83,63%	16,37%	0,57%	0,57%
LIA MONICA GIAMBRUNO MAROÑO	283	16	299	94,65%	5,35%	0,61%	1,18%
ANTONIO EDUARDO MOMBELLI CACERES	306	7	313	97,76%	2,24%	0,64%	1,82%
MARIA DEL CARMEN - BATLLE REYES	313		313	100,00%	0,00%	0,64%	2,45%
MARTIN HORACIO ZOLESSI BRUQUETAS	271	43	314	86,31%	13,69%	0,64%	3,09%
WALTER DANIEL MAURENTE HERNANDEZ	281	33	314	89,49%	10,51%	0,64%	3,73%
EDUARDO ISRAEL VILENSKY VINOCUR	270	52	322	83,85%	16,15%	0,66%	4,39%
JOSE IGNACIO FREGEIRO MORADOR	283	64	347	81,56%	18,44%	0,71%	5,09%
PATRICIA MARIA MUXI MUÑOZ	354		354	100,00%	0,00%	0,72%	5,82%
VICTOR DAYAN EIDLIN	344	16	360	95,56%	4,44%	0,73%	6,55%
JULIA ELENA MARIA CASARETTO PAGANINI	362	2	364	99,45%	0,55%	0,74%	7,29%
EDUARDO RAFAEL DOGLIANI STARICCO	320	53	373	85,79%	14,21%	0,76%	8,05%
DANIEL HORACIO RIENZI BERGALLI	305	89	394	77,41%	22,59%	0,80%	8,85%
JOSE LUIS CARLOMAGNO DI FIORIDO	384	15	399	96,24%	3,76%	0,81%	9,66%
TABARE RODRIGUEZ MACHADO	388	18	406	95,57%	4,43%	0,83%	10,49%
PABLO ALEJANDRO VAZQUEZ GRENNO	416	14	430	96,74%	3,26%	0,88%	11,36%
FERNANDO MOTTA TECHERA	388	76	464	83,62%	16,38%	0,94%	12,31%
DAYANA V. ACOSTA BENTANCORT	467	30	497	93,96%	6,04%	1,01%	13,32%
PEDRO TRUJILLO LEZAMA	488	23	511	95,50%	4,50%	1,04%	14,36%
IVANNA TERESITA DURO ROSSI	490	30	520	94,23%	5,77%	1,06%	15,42%
SEBASTIAN LLUBERAS GONZALEZ	519	20	539	96,29%	3,71%	1,10%	16,52%
MARIA JOSE SOMMER	748	37	785	95,29%	4,71%	1,60%	18,11%
*	20	881	901	2,22%	97,78%	1,83%	19,95%
ANDRES TUZMAN KLAEZKO	1038	32	1070	97,01%	2,99%	2,18%	22,13%
LEANDRO JUBANY MANFRINI	1156	39	1195	96,74%	3,26%	2,43%	24,56%
JORGE ANTONIO MAYOL ALMERA	1216	36	1252	97,12%	2,88%	2,55%	27,11%
TOMAS DIESTE FRIEDHEIN	1534	47	1581	97,03%	2,97%	3,22%	30,33%
** Otros	31430	2799	34229	91,82%	8,18%	69,67%	100,00%

* Médico solicitante sin registro en el Dataset

**"Otros": Los más de 2100 Médicos solicitantes restantes

