



PONTIFICIA UNIVERSIDAD CATÓLICA DE CHILE  
ESCUELA DE INGENIERÍA

# **AGENDAMIENTO DE PACIENTES DE QUIMIOTERAPIA: OPTIMIZACIÓN DE REGLAS DE DECISIÓN**

**SEBASTIÁN ANDRÉS BARRIGA VUYLSTEKE**

Tesis para optar al grado de  
Magíster en Ciencias de la Ingeniería

Profesor Supervisor:

ÁLVARO H. LORCA GÁLVEZ

ALEJANDRO E. CATALDO CORNEJO

Santiago de Chile, Enero 2023

© MMXXIII, SEBASTIÁN ANDRÉS BARRIGA VUYLSTEKE



PONTIFICIA UNIVERSIDAD CATÓLICA DE CHILE  
ESCUELA DE INGENIERÍA

# AGENDAMIENTO DE PACIENTES DE QUIMIOTERAPIA: OPTIMIZACIÓN DE REGLAS DE DECISIÓN

**SEBASTIÁN ANDRÉS BARRIGA VUYLSTEKE**

Miembros del Comité:

ÁLVARO H. LORCA GÁLVEZ

ALEJANDRO E. CATALDO CORNEJO

MARGARITA CASTRO ANICH

JOSÉ T. MARQUINEZ VACAREZZA

JULIO A. VERGARA AIMONE

Tesis para optar al grado de

Magíster en Ciencias de la Ingeniería

Santiago de Chile, Enero 2023

© MMXXIII, SEBASTIÁN ANDRÉS BARRIGA VUYLSTEKE

*Por la vida y sus vueltas*

## AGRADECIMIENTOS

La culminación de una etapa como esta no se alcanza sin antes agradecer a todos aquellos que hicieron de esta experiencia universitaria una de increíble aprendizaje personal y profesional. Espero de todo corazón poder poner al servicio de la sociedad todo lo aprendido, y que la vida me permita seguir estando para quienes lo necesiten.

Gracias a mis profesores guía, Álvaro y Alejandro, por su apoyo y motivación en este largo camino. Agradezco la positividad con la que me motivaron a buscar formas de aportar un granito de arena en problemas sociales.

A mis padres, Luis y Myriam, por enseñarme que el amor no tiene límites y trasciende la vida misma. No podría haber pedido mejores ejemplos de vida. Es por ustedes que todo lo que hago toma más sentido. "Quizás algún día sea un placer recordar todo esto".

A mi hermano Gonzalo, a Dani, Lisa y Milo. Por siempre estar dispuestos a escucharme, aconsejarme y cuidarme, aún desde lejos. ¡Sigán cumpliendo sus sueños!

A Cami, mi compañera y persona favorita todos estos años. Te admiro muchísimo y estoy muy agradecido de todo lo vivido, eres la mejor. Mención especial a tu mamá Lucía, una segunda madre para mí, y claro, a la Luna y a la Chiqui, las mejores siempre.

A Clo y Nico por recibirme en su casa en lo que sería el comienzo de este hermoso camino universitario, y por dejarme estar más cerca de la linda familia que han formado.

A mis amigos: Caco, Cata, Haase, Iván, Javi, Jorquera, Maca, Pipe, Seba y Tisco. Porque su preocupación genuina y constante apoyo, en las buenas y en las malas, han sido clave para estar aquí hoy. Mención especial a Caco por todas esas reuniones para discutir mi investigación que me empujaron a seguir adelante cuando se veía todo cuesta arriba.

Este trabajo contó con el apoyo financiero de la Agencia Nacional de Investigación y Desarrollo (ANID) mediante la Beca de Magíster Nacional N° 22201224.

## ÍNDICE DE CONTENIDOS

AGRADECIMIENTOS	iv
ÍNDICE DE FIGURAS	viii
ÍNDICE DE TABLAS	xiii
RESUMEN	xvii
ABSTRACT	xviii
1. INTRODUCCIÓN	1
1.1. Contexto del problema . . . . .	1
1.2. El problema desde la Investigación Operativa . . . . .	3
1.2.1. Problema de Agendamiento o Asignación intra-día . . . . .	5
1.3. Preguntas y Objetivos de la Investigación . . . . .	8
1.4. Estructura de la Tesis . . . . .	9
2. MODELACIÓN DEL PROBLEMA	10
2.1. Descripción del modelo a utilizar . . . . .	10
2.2. Incertidumbres a tratar en esta investigación . . . . .	14
3. METODOLOGÍA PROPUESTA	15
3.1. Simulador del proceso . . . . .	15
3.1.1. Métricas de rendimiento . . . . .	16
3.1.2. Generación de pacientes . . . . .	17
3.2. Generación de agendamientos . . . . .	17
3.2.1. Reglas de decisión . . . . .	17
3.2.2. Modelo de optimización . . . . .	18
4. DEFINICIÓN DE LOS CASOS DE ESTUDIO	23
4.1. Datos a considerar . . . . .	23

4.2. Estudio de factibilidad . . . . .	25
5. RESULTADOS COMPUTACIONALES DE LOS CASOS DE ESTUDIO	30
5.1. Reglas básicas de decisión . . . . .	30
5.1.1. Análisis por regla . . . . .	31
5.1.2. Comparación entre reglas . . . . .	34
5.2. Experimentos adicionales . . . . .	41
5.2.1. Modificaciones a la Función Objetivo . . . . .	42
5.2.2. Prohibición de Pacientes . . . . .	45
5.2.3. Aumento de Gap de agendamiento para combinaciones de pacientes . . . . .	50
5.2.4. Mezcla de técnicas: APM y Gap . . . . .	55
5.3. Discusión . . . . .	59
6. CONCLUSIONES Y TRABAJO FUTURO	63
6.1. Conclusiones . . . . .	63
6.2. Trabajo futuro . . . . .	66
REFERENCIAS	67
ANEXOS	72
A. Visualización de agendamientos por regla y set . . . . .	73
A.1. Set 1 . . . . .	73
A.2. Set 2 . . . . .	75
A.3. Set 3 . . . . .	78
A.4. Set 4 . . . . .	81
A.5. Set 5 . . . . .	83
B. Métricas de experimento con funciones objetivo . . . . .	85
C. Tabla de combinaciones para experimentos . . . . .	88
D. Métricas de experimento de prohibiciones . . . . .	90
D.1. Set 1 . . . . .	90
D.2. Set 4 . . . . .	94
E. Métricas de experimento gap . . . . .	97

E.1. Set 1 . . . . .	97
E.2. Set 4 . . . . .	101
F. Métricas de experimento conjunto HPM y gap . . . . .	104
F.1. Set 1 . . . . .	104
F.2. Set 4 . . . . .	108

## ÍNDICE DE FIGURAS

2.1	Diagrama del modelo base de optimización. . . . .	13
3.1	Diagrama de flujo de la simulación. . . . .	15
3.2	Ejemplo de un agendamiento de pacientes realizado por el modelo. . . . .	19
4.1	Estudio de factibilidad: casos infactibles. . . . .	26
4.2	Estudio de factibilidad: funciones objetivo. . . . .	27
5.1	Comparación entre reglas para <i>Real Makespan</i> . . . . .	35
5.2	Comparación entre reglas para costos de empuje. . . . .	36
5.3	Comparación entre reglas para costos de inactividad. . . . .	37
5.4	Comparación entre reglas para costos extra. . . . .	38
5.5	Comparación entre reglas para costos extra irregulares. . . . .	39
5.6	Comparación entre reglas para <i>Total Costs</i> . . . . .	40
5.7	Comparación entre reglas para <i>Total Weighted Costs</i> . . . . .	41
5.8	Costos totales de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para el Set 1. . . . .	45
5.9	Costos ponderados de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para el Set 4. . . . .	46
5.10	Costos totales de pacientes con cáncer de alto requerimiento con <i>gap</i> +2 en el Set 1. . . . .	51
5.11	Costos totales ponderados de pacientes con cáncer de alto requerimiento con <i>gap</i> +2 en el Set 4. . . . .	52

5.12	Costos totales de pacientes con cáncer de alto requerimiento con <i>gap</i> +2 y regla APM para Set 1. . . . .	56
5.13	Costos totales de pacientes con cáncer de alto requerimiento con <i>gap</i> +2 y regla APM para Set 4. . . . .	56
A.1	Agendamiento Set 1 con regla Regla Valor Esperado (RVE). . . . .	73
A.2	Agendamiento Set 1 con Regla Límite Inferior. . . . .	74
A.3	Agendamiento Set 2 con Regla Valor Esperado. . . . .	75
A.4	Agendamiento Set 2 con Regla Límite Inferior. . . . .	76
A.5	Agendamiento Set 2 con Regla Límite Superior. . . . .	77
A.6	Agendamiento Set 3 con Regla Valor Esperado. . . . .	78
A.7	Agendamiento Set 3 con Regla Límite Inferior. . . . .	79
A.8	Agendamiento Set 3 con Regla Límite Superior. . . . .	80
A.9	Agendamiento Set 4 con Regla Valor Esperado. . . . .	81
A.10	Agendamiento Set 4 con Regla Límite Inferior. . . . .	82
A.11	Agendamiento Set 5 con Regla Valor Esperado. . . . .	83
A.12	Agendamiento Set 5 con regla Regla Límite Inferior. . . . .	84
D.1	Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 1. . . . .	90
D.2	Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 1. . . . .	91
D.3	Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 1. . . . .	91

D.4	Costos extra irregulares de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 1. . . . .	92
D.5	Costos totales de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 1. . . . .	92
D.6	Costos totales ponderados de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 1. . . . .	93
D.7	Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 4. . . . .	94
D.8	Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 4. . . . .	94
D.9	Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 4. . . . .	95
D.10	Costos extra irregulares de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 4. . . . .	95
D.11	Costos totales de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 4. . . . .	96
D.12	Costos totales ponderados de pacientes con cáncer de alto requerimiento con <i>slots</i> PM prohibidos para Set 4. . . . .	96
E.1	Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 1. . . . .	97
E.2	Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 1. . . . .	98
E.3	Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 1. . . . .	98

E.4	Costos extra irregulares de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 1. . . . .	99
E.5	Costos totales de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 1. . . . .	99
E.6	Costos totales ponderados de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 1. . . . .	100
E.7	Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 4. . . . .	101
E.8	Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 4. . . . .	101
E.9	Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 4. . . . .	102
E.10	Costos extra irregulares de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 4. . . . .	102
E.11	Costos totales de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 4. . . . .	103
E.12	Costos totales ponderados de pacientes con cáncer de alto requerimiento con extra <i>gap</i> para Set 4. . . . .	103
F.1	Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 1. . . . .	104
F.2	Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 1. . . . .	105
F.3	Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 1. . . . .	105

F.4	Costos extra irregulares de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 1. . . . .	106
F.5	Costos totales de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 1. . . . .	106
F.6	Costos totales ponderados de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 1. . . . .	107
F.7	Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 4. . . . .	108
F.8	Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 4. . . . .	108
F.9	Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 4. . . . .	109
F.10	Costos extra irregulares de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 4. . . . .	109
F.11	Costos totales de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 4. . . . .	110
F.12	Costos totales ponderados de pacientes con cáncer de alto requerimiento con regla APM y extra <i>gap</i> para Set 4. . . . .	110

## ÍNDICE DE TABLAS

1.1	Definición resumida de subproblemas del agendamiento de quimioterapias. . .	3
4.1	Frecuencias y requerimientos de protocolos asociados a distintos tipos de cáncer. . . . .	24
4.2	Características principales de los grupos de cáncer considerados en este estudio.	24
4.3	Definición de casos de estudio. . . . .	28
4.4	Definición de casos de estudio: sampleo Sets 2 y 3. . . . .	29
5.1	Resultados promedio (desviación estándar) métricas RLS. . . . .	31
5.2	Resultados promedio (desviación estándar) métricas RVE. . . . .	33
5.3	Resultados promedio (desviación estándar) métricas RLS. . . . .	34
5.4	Tabla resumen de los mejores resultados por métrica por cada regla para experimento funciones objetivo. Signo asterisco implica empate. . . . .	43
5.5	ID pacientes y sus frecuencias en las combinaciones que obtuvieron mejor resultado que RVE en experimento prohibiciones. . . . .	47
5.6	Cantidad de pacientes de los conjuntos que obtuvieron mejor resultado que RVE en experimento prohibiciones. . . . .	48
5.7	Mejor combinación para cada tamaño de conjunto: costos totales Set 1 experimento prohibiciones. Costo total caso base 110,91. . . . .	48
5.8	Mejor combinación para cada tamaño de conjunto: costos ponderados Set 1 experimento prohibiciones. En rojo las métricas que no son mejores que el caso base (174,92). . . . .	49

5.9	Mejor combinación para cada tamaño de conjunto: costos totales Set 4 experimento prohibiciones. En rojo las métricas que no son mejores que el caso base (70,43). . . . .	49
5.10	Mejor combinación para cada tamaño de conjunto: costos ponderados Set 4 experimento prohibiciones. En rojo las métricas que no son mejores que el caso base (109,05). . . . .	50
5.11	ID pacientes y sus frecuencias en las combinaciones que obtuvieron mejor resultado que RVE en experimento <i>gap</i> . . . . .	52
5.12	Cantidad de pacientes de los conjuntos que obtuvieron mejor resultado que RVE en experimento <i>gap</i> . . . . .	53
5.13	Mejor combinación para cada tamaño de conjunto: costos totales Set 1 experimento <i>gap</i> . Costo total caso base 110,91. . . . .	53
5.14	Mejor combinación para cada tamaño de conjunto: costos ponderados Set 1 experimento <i>gap</i> . Costo total caso base 174,92. . . . .	54
5.15	Mejor combinación para cada tamaño de conjunto: costos totales Set 4 experimento <i>gap</i> . En rojo las métricas que no son mejores que el caso base (70,43). . . . .	54
5.16	Mejor combinación para cada tamaño de conjunto: costos ponderados Set 4 experimento <i>gap</i> . En rojo las métricas que no son mejores que el caso base (109,05). . . . .	55
5.17	ID pacientes y sus frecuencias en las combinaciones que obtuvieron mejor resultado que RVE en experimento APM Gap. . . . .	57
5.18	Cantidad de pacientes de los conjuntos que obtuvieron mejor resultado que RVE en experimento APM Gap. . . . .	57

5.19	Mejor combinación para cada tamaño de conjunto: costos totales Set 1 experimento APM Gap. En rojo las métricas que no son mejores que el caso base (110,91). . . . .	58
5.20	Mejor combinación para cada tamaño de conjunto: costos ponderados Set 1 experimento APM Gap. En rojo las métricas que no son mejores que el caso base (174,92). . . . .	58
5.21	Mejor combinación para cada tamaño de conjunto: costos totales Set 4 experimento APM Gap. En rojo las métricas que no son mejores que el caso base (70,43). . . . .	59
5.22	Mejor combinación para cada tamaño de conjunto: costos ponderados Set 4 experimento APM Gap. En rojo las métricas que no son mejores que el caso base (109,05). . . . .	59
B.1	Resultados Set 1 para experimento funciones objetivo. En verde el menor costo por métrica. . . . .	85
B.2	Resultados Set 2 para experimento funciones objetivo. En verde el menor costo por métrica. . . . .	86
B.3	Resultados Set 3 para experimento funciones objetivo. En verde el menor costo por métrica. . . . .	86
B.4	Resultados Set 4 para experimento funciones objetivo. En verde el menor costo por métrica. . . . .	87
B.5	Resultados Set 5 para experimento funciones objetivo. En verde el menor costo por métrica. . . . .	87
C.1	Combinaciones y sus respectivas asociaciones con los ID de los pacientes. Parte 1. . . . .	88

C.2 Combinaciones y sus respectivas asociaciones con los ID de los pacientes.  
Parte 2. . . . . 89

## RESUMEN

El cáncer es una enfermedad que anualmente mata a millones de personas. El número de pacientes que la padecen se encuentra en crecimiento sostenido, con particular riesgo en los países más desarrollados (Fondo de Investigación Mundial de Cáncer, 2021). Para su tratamiento, una de las técnicas médicas tradicionales es la quimioterapia, la que consta de infusiones de drogas específicas durante distintos ciclos, los cuales definen los protocolos de atención del tratamiento.

El agendamiento de pacientes de quimioterapia presenta una alta dificultad matemática y computacional, además de la necesidad de poder ser implementable de forma sencilla.

El problema se puede separar en dos: planificación inter-día y agendamiento intra-día. En esta investigación se aborda el último mediante análisis de reglas básicas de decisión, y se pone a prueba su rendimiento con técnicas de optimización y simulación conjuntas. Se utilizaron datos agregados de un centro de cáncer de Chile, y mediante ellos se generaron casos de estudio representativos para validar las distintas reglas y técnicas utilizadas.

En particular, se comprobó el buen rendimiento que presenta la regla de asignar a todos los pacientes en base a su tiempo esperado de atención, por sobre asumir casos pesimistas u optimistas según sus distintos tipos de cáncer. Además, sumando técnicas de penalización, prohibición y el uso de ciertos resguardos conservadores, se logró generar mejores reglas de decisión. Estas, si bien en su naturaleza continúan siendo simples y por ende fáciles de implementar, presentan mejoras por sobre la regla básica de agendar utilizando los tiempos esperados de atención de cada cáncer.

El principal aporte de esta investigación radica en una propuesta metodológica de optimización y simulación, la que es aplicable tanto en problemas de agendamiento, en particular de quimioterapia, pero también potencialmente en otras áreas o industrias.

**Palabras Claves:** agendamiento, quimioterapia, optimización, simulación.

## ABSTRACT

Cancer is a disease that annually kills millions of people. The number of patients suffering from it is steadily growing, with particular risk in the most developed countries (World Cancer Research Fund, 2021). For its treatment, one of the traditional medical techniques is chemotherapy, which consists of infusions of specific drugs during different cycles, which define the care protocols of the treatment.

The scheduling of chemotherapy patients presents a high mathematical and computational difficulty, in addition to the need to be able to be implemented in a simple way.

The problem can be separated into two: inter-day planning and intra-day scheduling. In this research, the latter is addressed through analysis of basic decision rules, and its performance is tested with joint optimization and simulation techniques. Aggregated data from a cancer center in Chile were used, and through them representative case studies were generated to validate the different rules and techniques used.

In particular, the good performance of the rule of assigning all patients based on their expected care time was verified, over assuming pessimistic or optimistic cases according to their different types of cancer. In addition, adding penalization, prohibition and some conservative safeguards, it was possible to generate better decision rules. In fact, although they continue to be simple in nature and therefore easy to implement, they present improvements over the basic rule of scheduling using the expected times of care for each cancer.

The main contribution of this research lies in a methodological proposal of optimization and simulation, which is applicable in scheduling problems, particularly chemotherapy, but also potentially in other areas or industries.

**Keywords:** scheduling, chemotherapy, optimization, simulation.

## **1. INTRODUCCIÓN**

Este capítulo introduce el problema de agendamiento de pacientes de quimioterapia y detalla los alcances de este trabajo. En la sección 1.1 se contextualiza sobre el gran desafío que implica agendar pacientes de quimioterapia, incluso en la actualidad. En la sección 1.2 se motiva y define el problema a estudiar y cómo se relaciona con el mundo de la investigación operativa. En la sección 1.3 se listan las preguntas y objetivos de investigación; y finalmente en la sección 1.4 se presenta la estructura general del resto de la tesis.

### **1.1. Contexto del problema**

No debiera resultar en sorpresa para nadie el hecho de que en los últimos años, las tasas de enfermos de cáncer per cápita en el mundo han ido en considerable aumento, en particular en el caso de países de mayor desarrollo (Organización Mundial de la Salud, 2017; Fondo de Investigación Mundial de Cáncer, 2021) o en vías de desarrollo, como Chile (Ministerio de Salud Chile, 2018), lo que se suele asociar a los estilos de vida preponderantes en estos lugares. El cáncer en sí es una enfermedad desafiante, pues sus tratamientos son fuertes y requieren de una implementación muy metódica. Existen diversos tratamientos para este, entre los que destacan la radioterapia y la quimioterapia como los que suelen tener mejores resultados, siendo por ello también los más populares (National Library of Medicine, 2019).

En particular, la quimioterapia se define mediante protocolos de tratamientos determinados para cada paciente por su oncólogo tratante, teniendo en cuenta su nivel de gravedad y tipo de cáncer. Los protocolos definen las drogas a suministrar y sus respectivas dosis por una parte, y por otra, el número de ciclos y sesiones asociados a cada una de ellas. También se definen fechas máximas de inicio del tratamiento, las que se espera se puedan seguir lo más fielmente posible. Además, según la cantidad de droga y dosis a infundir

al paciente, se determinarán ciertos tiempos de atención esperados, aunque es común que dichos tiempos varíen según el estado de salud del paciente durante la infusión.

El problema de agendamiento de pacientes de quimioterapia puede separarse en dos subproblemas, el de planificación inter-día y el de asignación o agendamiento intra-día, cada uno con sus respectivas complejidades que los hacen dignos de ser tratados incluso por separado.

Respecto al problema de la planificación de tratamientos, es decir, la calendarización inter-día, se debe seguir lo más fielmente posible las recomendaciones del médico tratante, pudiendo de lo contrario resultar en graves perjuicios a la calidad del tratamiento y con ello a la salud del paciente (Lara et al., 2016). La principal dificultad de este subproblema es que, en el caso general, los plazos entre cada sesión no serán los mismos. Así, puede haber un paciente que deba tener su primera atención dentro de esta semana (lunes a viernes), mientras que en cuanto tenga este primer tratamiento, el segundo debe ser dos días después, y el tercero cuatro días después, y así sucesivamente. Por lo anterior, y dado que se deben respetar estos plazos, se vuelve un problema de calendarización muy complejo, pues debe intentar asegurarse que agendar al paciente para un cierto día de esta semana también le asegure un cupo de atención para ciertos días específicos en el corto plazo.

Por otra parte, existe el subproblema del agendamiento, es decir, la decisión de asignación de recursos intra-día para el paciente. En esta arista se definen la hora de inicio de tratamiento, enfermeros/as tratantes y sillones de infusión, entre otras, las que hacen que el problema crezca mucho en dimensión. Las principales dificultades que existen en la realidad con esto son principalmente las fuentes de incertidumbre asociadas a los estados de salud de pacientes. Así, una primera incertidumbre es la asociada al nivel de gravedad del paciente en el día de la sesión. Un paciente que llega en un peor estado requerirá de mayor supervisión por parte de enfermeros/as, por lo que será más demandante dicho turno. Otra fuente de incertidumbre son los tiempos de atención. Por ejemplo, un paciente a la mitad de su sesión puede sentirse mareado, por lo que solicita asistencia y se define que

se reducirá la velocidad de infusión de las drogas, demorando con ello un mayor tiempo al esperado (y agendado) originalmente. Así también, si el estado de salud del paciente empeora radicalmente, podría decidir suspenderse la sesión en cualquier momento, y con ello detener el ciclo de tratamiento para redirigir al paciente a exámenes y control con su médico tratante. De la misma forma, otras fuentes de incertidumbre son la inasistencia de pacientes a sus sesiones, inasistencia del personal de salud e impuntualidad en hora de llegada de pacientes, entre otras.

La tabla 1.1 presenta un resumen de cada uno de los subproblemas expuestos.

Tabla 1.1. Definición resumida de subproblemas del agendamiento de quimioterapias.

Elemento/Subproblema	Inter-día	Intra-día
<b>Agentes y Recursos</b>	Pacientes, días laborales y capacidad máxima por día	Enfermeros, sillas y pacientes
<i>Input</i>	Grupo de pacientes por semana/mes/año	Grupo de pacientes por día
<b>Decisiones</b>	Día de sesión para cada paciente	Asignación de enfermero, silla y módulo a cada paciente
<i>Output</i>	Calendario con todos los pacientes asignados para cada sesión de tratamiento	Agenda de los tratamientos para el día

## 1.2. El problema desde la Investigación Operativa

Según lo definido en la sección anterior, no llama la atención que este sea un problema que haya sido estudiado por la comunidad de la Investigación Operativa, que se enfoca precisamente en la resolución de problemas complejos como este. Basta indagar un poco para darse cuenta de que existe una infinidad de *papers* sobre planificación y agendamiento, aunque la gran mayoría enfocados en áreas productivas y no precisamente en temas de salud. Sin embargo, en los últimos años esto ha ido cambiando, existiendo variadas técnicas, determinísticas y estocásticas, exactas y heurísticas, para abordar problemas asociados al área de salud, y específicamente a la quimioterapia.

Desde una primera mirada más amplia, es decir, buscando resolver calendarizaciones y asignaciones generales, si se ignoran por un momento las aplicaciones directas en temas de quimioterapia, existe una extensa literatura que lo aborda. Algunos de los puntos que se mencionan desde ya hace muchos años son por ejemplo el hecho de que, si se desea hacer algo realmente aplicable en la vida real, el usuario vaya a ser parte del proceso de la propuesta (Podgorelec y Kokol, 1997; Wiers, 1997), pues facilitará enormemente su proceso de adopción. Si no se le hace parte del proceso, es probable que no cambie su método de toma de decisiones, y con ello el potencial aporte de la herramienta entregada no llegará a buen puerto. En el ámbito de la salud, Ben Bachouch et al. (2012) definen que los problemas enfrentados (tanto calendarización como agendamiento) deben ser abordados en términos estratégicos y operacionales. Gallivan et al. (2002) y Marquinez et al. (2019) recalcan un punto clave en contextos en los que puedan llegar pacientes urgentes, que es el hecho de mantener una cierta capacidad de reserva. Lo complejo de tratar matemáticamente problemas de salud resulta en que muchas veces puede parecer beneficioso a nivel de sistema, por ejemplo, el rechazar a un paciente tardío, pero Shehadeh et al. (2020) recalcan que se debe tomar en cuenta lo perjudicial que dicha decisión puede ser para la salud del paciente. En cuanto a la estocasticidad, pareciera existir una falta de caracterizaciones de comportamientos de los pacientes. Sin embargo, algunos estudios como el de Kong et al. (2020) investigan la relación entre las características de los pacientes y la hora de asignación de su tratamiento con la probabilidad de no asistir, ya que por ejemplo las horas de mitad del día o de más tarde podrían tener tasas de inasistencia distintas que las de más temprano. Respecto a otras incertidumbres como la impuntualidad, a nivel de modelación y sistemas, Pan et al. (2019) proponen que es precisamente el gran factor que afecta el rendimiento de un sistema de salud en general. Por otra parte, Shehadeh et al. (2020) respecto al comportamiento de los pacientes y su impuntualidad, plantea que la mayoría de los pacientes tiende a llegar temprano o previo a la cita médica.

En cuanto a técnicas de resolución para estos problemas de agendamientos o calendarizaciones no necesariamente aplicados al área de la salud, se encuentran las siguientes: programación entera (Ben Bachouch et al., 2012; Bastos et al., 2019), generación de

restricciones (Bastos et al., 2019), programación dinámica (Sauré et al., 2020), programación estocástica (Shuang et al., 2019; Pan et al., 2019; Pan et al., 2020; Tsai y Teng, 2014), e incluso optimización distribucionalmente robusta (Kong et al., 2020). Además, hay distintos paradigmas desde los cuales abordar estos problemas. Por ejemplo, tomando en cuenta los tiempos de espera (Carreras-García et al., 2020) o teniendo como regla respetar el orden inicial asignado de los pacientes (Shehadeh et al., 2020), entre otros.

Si se analizan en concreto las técnicas de la Investigación Operativa que se usan para resolver problemas de quimioterapias, se encuentra: optimización entera (Turkcan et al., 2012; Sadki et al., 2011; Heshmat y Eltawil, 2018; Lv et al., 2017; Santibanez et al., 2012; Heshmat et al., 2017), programación dinámica (Ramos et al., 2020), programación estocástica (Castaing et al., 2016; Alvarado y Ntaimo, 2018), *constraint programming* (Hahn-Goldberg et al., 2014), y optimización robusta (Issabakhsh et al., 2020). En el mismo contexto, varios *papers* también abordan los problemas mediante heurísticas (Sevinc et al., 2013; Turkcan et al., 2012; Sadki et al., 2011; Riff et al., 2016; Issabakhsh et al., 2020). Cabe destacar de que una gran oportunidad que se presenta en las investigaciones es la puesta en práctica: salvo por las investigaciones de Majidi et al. (1993) y Santibanez et al. (2012), no se encuentran muchos más registros de implementaciones de modelos de investigación operativa en estos tópicos. Para mayor información de este problema y sus líneas potenciales de investigación, revisar Dobish (2003) y Heshmat y Eltawil (2016).

En particular, esta investigación se enfocará en el subproblema del agendamiento intra-día, por lo que a continuación se presenta una revisión un poco más detallada de él.

### **1.2.1. Problema de Agendamiento o Asignación intra-día**

Como fue mencionado en el inciso anterior, este problema presenta una alta dimensionalidad, siendo esta una dificultad que deberá enfrentar prácticamente cualquiera de los modelos que se investiguen al respecto. Además, cuenta con un conjunto de restricciones físicas, como el uso de una única silla por cada paciente durante todo el tratamiento de un

mismo día o el hecho de que no se puede pausar la sesión y continuarla luego, así como también otras restricciones que podrían ser menos fuertes, como el contar con turnos de duración o dificultad similar para distintos enfermeros/as. Por otra parte, la existencia de incertidumbre sin duda alguna presenta un aumento enorme de complejidad para tratar este problema. En particular, cuando un paciente demora más de lo agendado, repercute en todas las asignaciones posteriores, aumentando tiempos de espera y empeorando la calidad de servicio. Por otra parte, si por ejemplo se considera cuando un paciente empeora su estado de salud y debe suspender su sesión, también tiene efectos negativos en el sistema, puesto que permanecerán desocupados recursos que podrían estar siendo aprovechados en atender a más pacientes.

Para ahondar en este problema, una forma común es preguntarse qué se busca con él, además de cumplir con restricciones de factibilidad. En otras palabras, cuáles son los objetivos que se presentan, matemáticamente, para evaluar que un agendamiento es bueno o es mejor que otro. Históricamente, en la literatura, esto ha sido abordado mediante la minimización del *makespan* de atenciones (tiempo de cierre de todas las sesiones), del no-uso de recursos en el sistema, de tiempos de espera de pacientes, de uso de horas extra (Ramos et al., 2020), entre otros. Por otra parte, también se han planteado objetivos de maximizar ganancias, cantidad de personas atendidas o porcentajes de utilización del sistema (Sauré et al., 2020).

Turkcan et al. (2012), Gruber et al. (2003), y Chabot y Fox (2005) plantean que en la resolución de este problema es fundamental incluir los recursos limitados (sillones y enfermeros/as), o de lo contrario habrá grandes retrasos en las atenciones. Si bien parece evidente, uno podría preferir no considerarlos, al menos durante la asignación matemática misma, ya que nos ahorrará muchas dimensiones del problema, y luego podría intentarse la asignación mediante heurísticas. Si bien esto podría funcionar, ya que usualmente se consideran sillones y enfermeros/as como recursos intercambiables o equivalentes en cierto sentido, como comentan los autores referenciados esto podría resultar en graves problemas de implementación. A pesar de lo anterior, Heshmat et al. (2017), mediante técnicas

computacionales de agrupación (*i.e. clustering*) logran reducir la dimensionalidad del problema y luego adaptar sus resultados para que sean utilizables directamente, por lo que tampoco debiese ser una idea que se descarte del todo.

Existen dos formas principales de realizar las asignaciones. Una es una asignación dinámica, en la que a medida que los pacientes van llamando al centro de atención para solicitar una hora de quimioterapia son asignados instantáneamente. La ventaja de esta modalidad es que presenta un mejor servicio al paciente, pues disminuye la incertidumbre por parte de este. Sin embargo, la gran desventaja que puede presentar es que se terminen realizando peores asignaciones, dado que como fue comentado no importa solo el corto plazo (primera atención), sino que también es sumamente relevante que se cumplan las fechas de las siguientes atenciones. Así, otros centros plantean un enfoque en que juntan una cierta cantidad de pacientes, y al finalizar cada semana, teniendo ya todo el conjunto de pacientes por atender, realizan la asignación.

Cabe mencionar también algunas otras decisiones de modelación interesantes, como la de considerar solamente la cola derecha de la incertidumbre de tiempos de atención (Issabakhsh et al., 2020), o en particular con respecto a enfermeros/as, Turkcan et al. (2012) y Alvarado y Ntaimo (2018) abordan el problema considerando la gravedad de los pacientes que atiende cada enfermero/a.

Una arista pocas veces considerada es el proceso de preparación de las drogas para la infusión (Sadki et al., 2011; Ramos et al., 2020), aunque con respecto a este último un estudio de Sevinc et al. (2013) plantea que actualmente existen países que cuentan con maquinaria automatizada que fabrica las drogas y por ende ya no debiera ser un problema tan grande. Sin embargo, esta no es la realidad de todos los países, y aún así sería relevante analizar la programación de dicha maquinaria para que alcance a realizar todo lo necesario a tiempo. Otra alternativa para abordar puede ser el considerar en el agendamiento la hora médica previa a la primera sesión del ciclo con el oncólogo, tal como en Sadki et al. (2011).

### 1.3. Preguntas y Objetivos de la Investigación

Primeramente se presentan las principales preguntas que motivaron la investigación, las que se pueden resumir en:

- (i) ¿Qué tanto tiempo del centro hospitalario se pierde haciendo una asignación determinística de pacientes de quimioterapia, en oposición a una que considere la estocasticidad?
- (ii) ¿Existirán reglas simples de decisión determinísticas para hacer los agendamientos que presenten resultados razonablemente buenos en este contexto?

La hipótesis que se plantea es que sí existirán reglas de decisión determinísticas sencillas que puedan obtener buenos resultados en sus agendamientos, en particular en contextos realistas con presencia de estocasticidad en los tiempos de atención.

Con esto, se procede a definir los objetivos de la tesis, que buscan contestar ambas preguntas de investigación planteadas. El último objetivo se considera el objetivo principal de investigación, pues será el que englobará finalmente las respuestas a las preguntas planteadas.

- (i) Replicar un modelo de optimización determinístico de agendamiento de pacientes de quimioterapia, a modo de *benchmark*.
- (ii) Diseñar una propuesta de reformulación del modelo para que pueda ser usado potencialmente por otras metodologías de optimización más complejas.
- (iii) Proponer una metodología para crear instancias representativas de pacientes de quimioterapia.
- (iv) Encontrar, dentro de un conjunto de reglas simples de decisión, cuáles presentan mejores resultados globales, y derivar a partir de ellas otras técnicas de manipulación de los agendamientos con tal de obtener mejores resultados.

Con esto, los principales aportes que se espera de esta investigación son

- (i) Propuesta de un modelo de agendamiento de pacientes de quimioterapia que cuente con ventajas de implementabilidad para otras técnicas de optimización más avanzadas.
- (ii) Metodología de optimización y simulación basada en datos históricos para enfrentar el problema de agendamiento de pacientes de quimioterapia mediante la generación y adaptación de reglas de decisión.

#### **1.4. Estructura de la Tesis**

El resto de esta investigación se desarrolla de la siguiente forma. En la sección 2 se detallará el problema específico a resolver, junto con el modelo de base que se utilizará. Luego, en la sección 3 se presenta la propuesta de solución, con sus diferentes aristas consideradas. Finalmente, se presentará un caso de estudio en la sección 4 con sus resultados en la sección 5 y se cerrará con conclusiones y pasos futuros en la sección 6.

## 2. MODELACIÓN DEL PROBLEMA

En este capítulo se presenta una descripción matemática detallada acerca del modelo determinístico que se utilizó como base para todas las técnicas de resolución propuestas. En la sección 2.1 se presenta el modelo formulado por Turkcan et al. (2012), siendo a la fecha uno de los principales referentes en el contexto del problema de quimioterapias. Luego, en la sección 2.2 se definen las incertidumbres que se trataron a lo largo de la investigación.

### 2.1. Descripción del modelo a utilizar

Originalmente, Turkcan et al. (2012) propone un modelo para resolver el problema de planificación inter-día, y otro para la asignación intra-día. En particular, acá se utiliza el segundo, el que cuenta con la siguiente notación:

#### Variables de decisión

- $Y_{ijkst}$ : variable binaria que toma valor 1 si el tratamiento del paciente  $i$  comienza por enfermero/a  $j$  en silla  $k$  en el slot  $s$  del día  $t$ , 0 en otro caso.

#### Variables auxiliares

- $M_{jt}$ : tiempo de completación de todos los tratamientos asignados a enfermero/a  $j$  en día  $t$
- $C_t^{max}$ : tiempo de completación general de todos los tratamientos del día  $t$

#### Parámetros

- $R_{it}$ : tiempo de tratamiento requerido por paciente  $i$  en el día  $t$
- $S$ : número de slots de cada día
- $T$ : número de días a considerar
- $K$ : número de sillas a considerar
- $N_t$ : número de enfermeros/as a considerar en día  $t$

- $A_{it}$ : *acuity* de cada paciente  $i$  en el día  $t$
- $A^{max}$ : máximo *acuity* que cada enfermero/a puede atender durante cada *slot*

### Conjuntos

- $P_t$ : pacientes del día  $t$

El modelo matemático en el que se basó esta investigación es el siguiente:

$$\min \sum_{t=1}^T C_t^{max} \quad (2.1)$$

$$\sum_{j=1}^{N_t} \sum_{k=1}^K \sum_{s=1}^{S-R_{it}+1} Y_{ijkst} = 1 \quad \forall i \in P_t, t \in \{1, \dots, T\} \quad (2.2)$$

$$\sum_{i \in P_t} \sum_{j=1}^{N_t} \sum_{u=\max\{s-R_{it}+1, 1\}}^{\min\{S-R_{it}+1, s\}} Y_{ijkut} \leq 1 \quad k \in \{1, \dots, K\}, s \in \{1, \dots, S\}, t \in \{1, \dots, T\} \quad (2.3)$$

$$\sum_{i \in P_t} \sum_{k=1}^K \sum_{u=\max\{s-R_{it}+1, 1\}}^{\min\{S-R_{it}+1, s\}} A_{it} Y_{ijkut} \leq A^{max} \quad (2.4)$$

$$s \in \{1, \dots, S\}, j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\}$$

$$\sum_{i \in P_t} \sum_{k=1}^K Y_{ijkst} \leq 1 \quad j \in \{1, \dots, N_t\}, s \in \{1, \dots, S\}, t \in \{1, \dots, T\} \quad (2.5)$$

$$\sum_{k=1}^K \sum_{s=1}^{S-R_{it}+1} Y_{ijkst}(s + R_{it} - 1) \leq M_{jt} \quad \forall i \in P_t, j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\} \quad (2.6)$$

$$M_{jt} \leq C_t^{max} \quad j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\} \quad (2.7)$$

$$Y_{ijkst} \in \{0, 1\} \quad (2.8)$$

$$\forall i \in P_t, j \in \{1, \dots, N_t\}, k \in \{1, \dots, K\}, s \in \{1, \dots, S\}, t \in \{1, \dots, T\}$$

$$M_{jt} \in \mathbb{R} \quad \forall j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\} \quad (2.9)$$

$$C_t^{max} \in \mathbb{R} \quad \forall t \in \{1, \dots, T\} \quad (2.10)$$

Se observa que la función objetivo del modelo es minimizar los tiempos totales de completación de todos los días, y dado que cada día es independiente del anterior, es decir, no existen restricciones que relacionen el día  $t$  con  $t + 1$ , entonces el modelo busca minimizar el *makespan* de cada día por separado, que es como fue considerado a lo largo de esta investigación. Cada paciente que tiene tratamiento en el día  $t$  ( $i \in P_t$ ) es asignado a un enfermero/a ( $j$ ), una silla ( $k$ ) y un módulo de tiempo ( $s$ ) por la restricción (2.2). En particular, dicha sumatoria no recorre todo el conjunto de *slots* debido a que no puede comenzar el tratamiento de un paciente cuando ya no queden módulos suficientes para que finalice su tratamiento ese día.

La restricción (2.3) asegura que máximo un paciente será asignado a una misma silla durante el mismo *slot*, y a su vez, por los límites de la sumatoria sobre *slots*, que ese también será el único paciente asignado a esa silla durante todos los *slots* de su tratamiento. La gravedad total que puede atender cada enfermero/a por módulo no puede superar el límite definido, lo que se refleja en la restricción (2.4). Cabe destacar de que por los límites de la sumatoria sobre *slots*, esto aplica para todo el tratamiento del paciente, por lo que se considera que se atenderá por un único enfermero/a todo su tratamiento. La restricción (2.5) asegura que cada enfermero/a puede comenzar máximo un tratamiento por cada *slot*. La restricción (2.6) define los tiempos de completación de cada enfermero/a, mientras que el total del *makespan* diario se define en la restricción (2.7). Finalmente, (2.8) son las restricciones de integralidad de las variables y (2.9) y (2.10) la naturaleza de variables para las variables auxiliares. Se nota en este último caso que están definidas en el mundo de los números reales, a pesar de que en la práctica tomarán valores enteros siempre producto de las restricciones que las definen.

Históricamente, este modelo ha sido muy utilizado y citado en otras investigaciones. Su gran ventaja, como se puede observar, es la presencia de una única familia de variables de decisión  $Y$ , las que son multidimensionales y ayudan a resolver un problema muy complejo de una forma mucho más fácil de interpretar.

La figura 2.1 recopila lo anteriormente explicado en un diagrama resumen del modelo considerado.

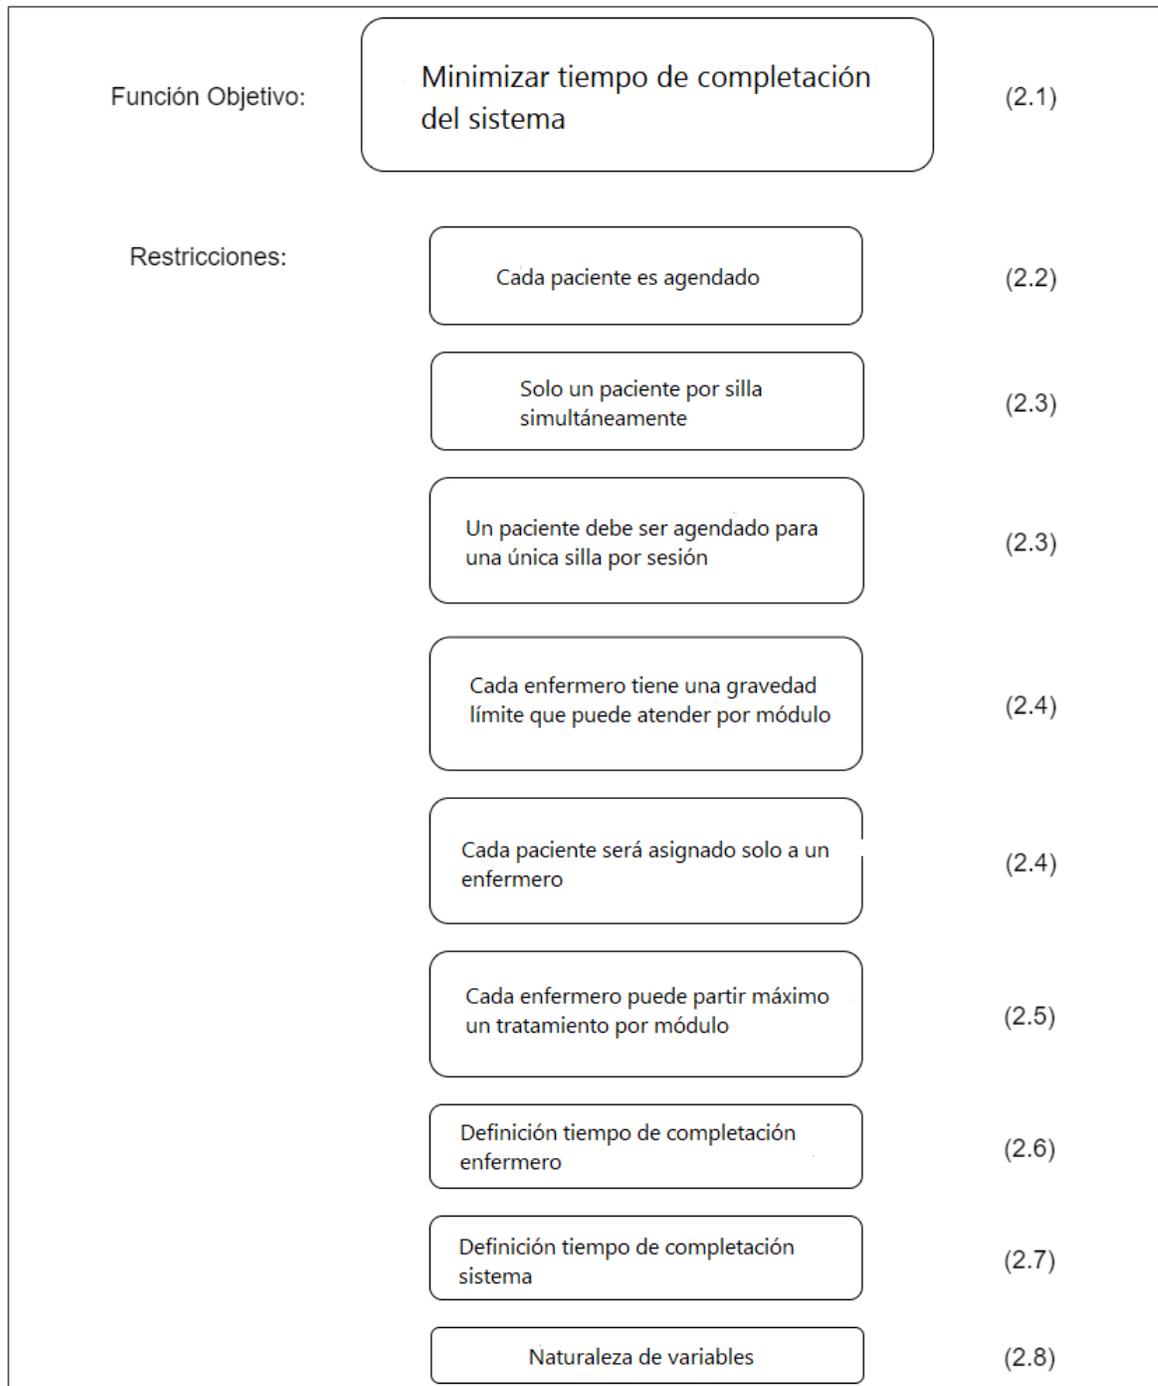


Figura 2.1. Diagrama del modelo base de optimización.

## **2.2. Incertidumbres a tratar en esta investigación**

En esta tesis se tomó en cuenta la diversidad de los pacientes y sus respectivos cánceres, en particular respecto a sus tiempos esperados de duración de atención, por ser precisamente esta la fuente principal de demoras y altos costos en sistemas hospitalarios que entregan el servicio de quimioterapias. Se podría tender a considerar la generación misma de pacientes como una incertidumbre, pero al ser estas definidas de forma externa al modelo, se entenderán solamente los tiempos de atención como incertidumbres a tratar en la investigación, los que se tomaron en cuenta directamente mediante el modelo de toma de decisiones mediante optimización. En particular, se consideró que las realizaciones de los tiempos de atención pueden demorar más (en caso de que los pacientes puedan estar sintiéndose mal y se disminuya la velocidad de infusión) o menos. El último punto es relevante a tener en cuenta, ya que si bien no es tan común el hecho de que a los pacientes se les aumente la velocidad de la infusión de las drogas requeridas, sí como fue explicado en la revisión bibliográfica es posible que una persona en cualquier momento del tratamiento se sienta tan mal que deba parar. Así, como solo se busca realizar las asignaciones intradía, no se vuelve crucial poder distinguir aquellos pacientes que tuvieron que dejar su ciclo de tratamiento, y solamente es importante poder saber cómo está funcionando el respectivo agendamiento del día a nivel sistema.



En resumen, lo que se hace es:

- (i) Se toma un conjunto de pacientes definido, con sus respectivos tipos de cáncer asociados y los tiempos esperados de atención, medidos en módulos.
- (ii) Para ese grupo de pacientes, se generan límites porcentuales (*i.e. bounds*) de tiempos máximo y mínimo de atención, con un parámetro de entrada que define cuánto porcentaje bajo y sobre el valor esperado estarán dichos límites.
- (iii) Se genera un agendamiento para ese grupo de pacientes, mediante alguna regla o modelo.
- (iv) Se pone a prueba ese agendamiento propuesto para una cierta cantidad de escenarios asociados al mismo conjunto de pacientes. En este paso se retornan las métricas de rendimiento. Cabe destacar de que los escenarios que se utilizan para las distintas reglas para cada caso de estudio serán los mismos, para tener un punto de comparación.

### 3.1.1. Métricas de rendimiento

Para poder comparar los distintos modelos y reglas de decisión para generar agendamientos para un *set* específico de pacientes, se definen las siguientes métricas:

- Costo de Empuje (*i.e. push*): es aquel que se genera cuando un paciente se demora más de lo agendado, y repercute en el paciente que usaría dicha silla después.
- Costo de Inactividad (*i.e. idle*): se calcula como todos los módulos en que una silla permanece vacía cuando aún no termina su uso del día. Pueden ser estructurales (propios de las asignaciones determinísticas, por falta de enfermeros/as por ejemplo), o producto de la variabilidad de atenciones de cada paciente.
- *Makespan* real: esta métrica se define como el módulo final de atención de todo el centro, independiente de la silla o enfermero/a. Es lo que mide la función objetivo del modelo original de Turkcan et al. (2012), pero acá se calcula producto de la variabilidad de los tiempos de atención. Para efectos del modelo, existirá

un límite de módulos dado por la configuración del caso de estudio, mientras que en las simulaciones se tomará el supuesto de que no es posible reagendar pacientes para otro día y que se deben terminar sus atenciones siempre.

- Costo extra: son todos los módulos que se utilizan por sobre las horas regulares de atención del centro. Existen dos tipos: horas extra regulares (que pueden ser dadas por los modelos mismos de asignación), y horas extra irregulares (que son las que, dada la simulación, demoran por sobre las horas extra regulares).

### **3.1.2. Generación de pacientes**

Para la generación de pacientes se recomienda utilizar alguna base de datos histórica de algún centro de cáncer. Así, se pueden generar distintos casos de estudio relevantes y representativos de la realidad de dicho centro, o incluso se podrían modificar sus frecuencias con tal de intentar analizar algún fenómeno particular.

## **3.2. Generación de agendamientos**

Para poder generar los agendamientos de los pacientes, se requiere de reglas de decisión (o potencialmente modelos de optimización). Cabe destacar de que algo que ocurre con los problemas de agendamiento en particular, es que encontrar una solución factible (que se pueda llevar a cabo), no suele ser algo tan complejo. Así es como muchos hospitales hoy en día funcionan en base a agendamientos hechos "a mano" por los mismos profesionales de la salud. A continuación se detallan los dos niveles de decisión que se proponen.

### **3.2.1. Reglas de decisión**

Estas pueden ser básicas o más complejas. Las primeras consisten en que todos los pacientes son agendados considerando exactamente la misma regla. Por ejemplo, a todos se les considera se demoran su tiempo esperado, su límite inferior, su límite superior, o

cualquiera de los rangos intermedios (tiempo esperado más un módulo, tiempo esperado menos un módulo, etc.). Por otra parte, una regla más compleja podría ser aquella en que se define una regla básica para la mayoría, mientras que se eligen ciertos pacientes según algún criterio, y a estos se les asigna de forma diferenciada. Algunos de esos criterios podrían ser tener un mayor o menor valor esperado de atención, por ejemplo.

Dentro de las posibilidades de acción con los pacientes no está solamente el tomar la regla de cuántos módulos consideraremos por sobre o por debajo de su valor esperado, sino que también se puede prohibir ciertos módulos para el comienzo de su atención. Esto se justifica en cuanto a que los problemas de *scheduling* pueden presentar altísimos niveles de simetrías, conllevando ello a la existencia de múltiples soluciones que, si bien pueden tener la misma función objetivo, no necesariamente tendrán el mismo comportamiento en cuanto a las métricas resultantes de la simulación.

### **3.2.2. Modelo de optimización**

Dada la regla de decisión definida, se utiliza el modelo de optimización definido en la sección 2 de Turkcan et al. (2012) para realizar el agendamiento mismo. Dicho modelo toma como *input* la regla asociada a cada paciente, y genera sus requerimientos de atención, con los que toma la decisión óptima de cómo estructurar la asignación paciente-enfermero-silla a cada módulo. A continuación la figura 3.2 representa un ejemplo de cómo se observa el agendamiento realizado por el modelo, donde cada color es un enfermero, cada fila (vertical) es una silla, y cada columna (horizontal) es un *slot* distinto.

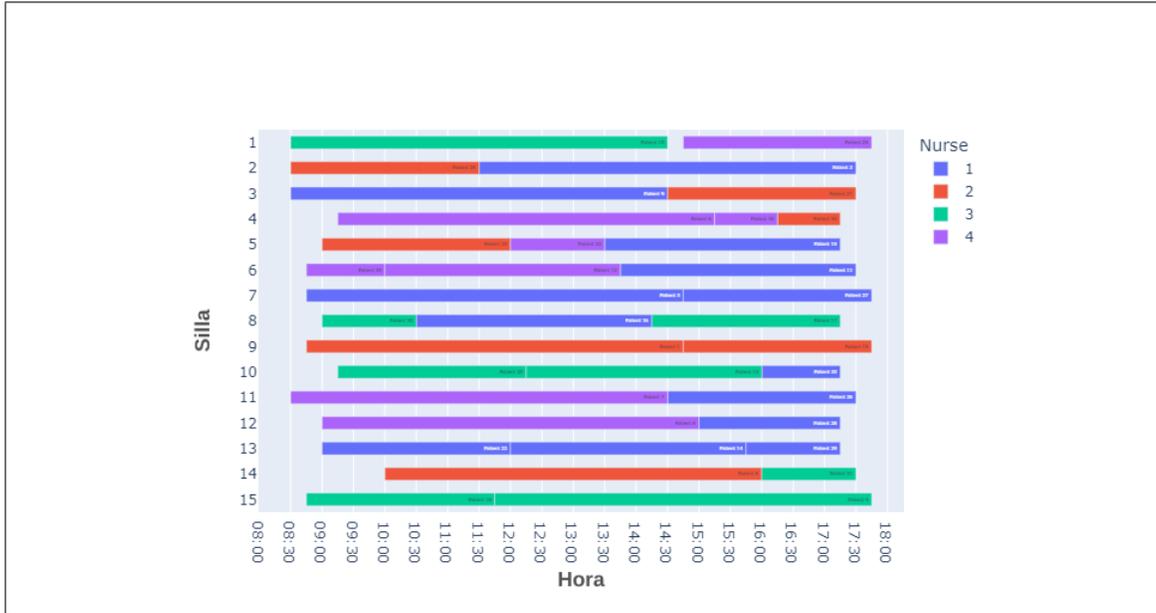


Figura 3.2. Ejemplo de un agendamiento de pacientes realizado por el modelo.

### 3.2.2.1. Reformulación problema base

Por otra parte, y si bien con el modelo presentado en el capítulo 2 se tiene una base sólida, la presencia de parámetros potencialmente inciertos en los subíndices de sus restricciones podría llegar a presentar algún problema para la implementación de algunas técnicas más avanzadas de optimización. Por lo anterior, y con el ánimo de poder generalizar esta formulación de forma más directa, en este inciso se presenta una reformulación al modelo, la que presenta como ventaja la no aparición de dichos parámetros en los subíndices. En otras palabras, se hizo una transformación del parámetro relativo a los tiempos de atención, *i.e.*  $R_{it}$ , que estaba presente en los subíndices de las sumatorias, para que ya no esté ahí y por ende puedan aplicarse otras técnicas de optimización que requieren que los parámetros estocásticos estén representados de forma lineal.

Para las restricciones (2.2) y (2.6) que su última sumatoria va de  $s = 1$  hasta  $s = S - R_{it} + 1$ , se define un parámetro binario  $\beta_{it}^s : \forall i \in P_t, t \in \{1, \dots, T\}, s \in \{1, \dots, S\}$  que cumple  $\sum_{s=1}^S \beta_{it}^s = S - R_{it} + 1 : \forall i \in P_t, t \in \{1, \dots, T\}$  y también  $\beta_{it}^s \geq \beta_{it}^{s+1} : \forall i \in$

$P_t, t \in \{1, \dots, T\}, s \in \{1, \dots, S - 1\}$ , todos parámetros conocidos de antemano.

$$(2.2) \rightarrow \sum_{j=1}^{N_i} \sum_{k=1}^K \sum_{s=1}^S \beta_{it}^s \cdot Y_{ijkst} = 1 \quad \forall i \in P_t, t \in \{1, \dots, T\} \quad (3.1)$$

$$(2.6) \rightarrow \sum_{k=1}^K \sum_{s=1}^S \beta_{it}^s \cdot Y_{ijkst}(s + R_{it} - 1) \leq M_{jt} \quad \forall i \in P_t, j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\} \quad (3.2)$$

Por otra parte, para las restricciones (2.3) y (2.4), definiremos los parámetros binarios  $\lambda_{it}^{sw} = 1 : \forall w \in \{1, \dots, \sum_{s=1}^S \beta_{it}^s\}, s \in w, \dots, R_{it} + w - 1, i \in P_t, t \in \{1, \dots, T\}$ . Dado que tampoco sirve tener a los parámetros  $\beta$  como límite de la sumatoria, se reformula nuevamente y se llega a lo siguiente:

$$(2.3) \rightarrow \sum_{i \in P_t} \sum_{j=1}^{N_t} \sum_{w=1}^S \beta_{it}^{sw} \cdot \lambda_{it}^{sw} \cdot Y_{ijkwt} \leq 1 \quad k \in \{1, \dots, K\}, s \in \{1, \dots, S\}, t \in \{1, \dots, T\} \quad (3.3)$$

$$(2.4) \rightarrow \sum_{i \in P_t} \sum_{k=1}^K \sum_{w=1}^S \beta_{it}^{sw} \cdot \lambda_{it}^{sw} \cdot A_{it} Y_{ijkwt} \leq A^{max} \quad (3.4)$$

$$s \in \{1, \dots, S\}, j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\}$$

A pesar de que lo anterior reformula correctamente el modelo, aún no se llega al objetivo de la reformulación, en cuanto a que existen relaciones no lineales entre los parámetros que dependen del tiempo de atención, dígase  $R, \lambda$  y  $\beta$ . Sin embargo, es posible notar dos cosas relevantes. Primero, que  $\lambda_{it}^{sw} \cdot \beta_{it}^{sw} = \lambda_{it}^{sw}$  en todos sus subíndices por construcción de la variable  $\lambda$ , por lo que dicha no linealidad realmente no está presente. Segundo, que la restricción (2.6) podía ser reformulada inicialmente de otra forma, sin requerir del parámetro binario  $\beta$ . Para hacerlo simplemente fue necesario cambiar arbitrariamente los límites superiores de la sumatoria, dejándolos en  $S$ , lo que va a seguir estando bien definido producto de las otras restricciones del modelo. Así, tomando:

$$\sum_{k=1}^K \sum_{s=1}^S Y_{ijkst}(s + R_{it} - 1) \leq M_{jt} \quad \forall i \in P_t, j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\} \quad (3.5)$$

Se da por finalizada la reformulación, obteniendo entonces el modelo completo reformulado:

$$Z = \min \sum_{t=1}^T C_t^{max} \quad (3.6)$$

$$\sum_{j=1}^{N_t} \sum_{k=1}^K \sum_{s=1}^S \beta_{it}^s \cdot Y_{ijkst} = 1 \quad \forall i \in P_t, t \in \{1, \dots, T\} \quad (3.7)$$

$$\sum_{i \in P_t} \sum_{j=1}^{N_t} \sum_{w=1}^S \lambda_{it}^{sw} \cdot Y_{ijkwt} \leq 1 \quad k \in \{1, \dots, K\}, s \in \{1, \dots, S\}, t \in \{1, \dots, T\} \quad (3.8)$$

$$\sum_{i \in P_t} \sum_{k=1}^K \sum_{w=1}^S \lambda_{it}^{sw} \cdot A_{it} Y_{ijkwt} \leq A^{max} \quad (3.9)$$

$$s \in \{1, \dots, S\}, j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\}$$

$$\sum_{i \in P_t} \sum_{k=1}^K Y_{ijkst} \leq 1 \quad j \in \{1, \dots, N_t\}, s \in \{1, \dots, S\}, t \in \{1, \dots, T\} \quad (3.10)$$

$$\sum_{k=1}^K \sum_{s=1}^S Y_{ijkst} (s + R_{it} - 1) \leq M_{jt} \quad \forall i \in P_t, j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\} \quad (3.11)$$

$$M_{jt} \leq C_t^{max} \quad j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\} \quad (3.12)$$

$$Y_{ijkst} \in \{0, 1\} \quad (3.13)$$

$$\forall i \in P_t, j \in \{1, \dots, N_t\}, k \in \{1, \dots, K\}, s \in \{1, \dots, S\}, t \in \{1, \dots, T\}$$

$$M_{jt} \in \mathbb{R} \quad \forall j \in \{1, \dots, N_t\}, t \in \{1, \dots, T\} \quad (3.14)$$

$$C_t^{max} \in \mathbb{R} \quad \forall t \in \{1, \dots, T\} \quad (3.15)$$

Con los parámetros binarios definidos por los conjuntos:

$$\beta_{it}^s : \left( \beta_{it}^s \geq \beta_{it}^{s+1}, \quad s = 1, \dots, S-1 \right) \wedge \left( \sum_{s=1}^S \beta_{it}^s = S - R_{it} + 1 \right)$$

$$\forall i \in P_t, t \in \{1, \dots, T\}, s \in \{1, \dots, S\}$$

$$\lambda_{it}^{sw} : \left( \sum_{s=w}^S \lambda_{it}^{sw} = R \right) \wedge \left( \lambda_{it}^{s,s} = \beta_{it}^s \right) \wedge \left( \lambda_{it}^{sw} \geq \lambda_{it}^{s+1,w}, \quad s \in \{w, \dots, S-1\} \right)$$

$$\forall i \in P_t, t \in \{1, \dots, T\}, s \in \{1, \dots, S\}, w \in \{1, \dots, S\}$$

Ahora sí se cuenta con un modelo que cuenta con los parámetros inciertos con relaciones lineales y presentes de forma explícita en las restricciones, y ya no en los distintos subíndices de ellas. Este modelo es apto para que, en investigaciones futuras, pueda ser utilizado por una mayor cantidad de técnicas de optimización a las que los parámetros inciertos en los subíndices no le permitían.

## **4. DEFINICIÓN DE LOS CASOS DE ESTUDIO**

En este capítulo se presentarán los datos y casos de estudio a considerar en la investigación. En la sección 4.1 se muestran y explican los datos a considerar, su origen e información relevante, mientras que en la sección 4.2 se presenta la metodología de generación de los casos de estudio a investigar.

### **4.1. Datos a considerar**

Como se comentó en la subsección 3.1.2, es ideal contar con datos históricos de algún centro de cáncer, con tal de poder generar casos de estudio representativos o interesantes de analizar. En particular, en esta investigación se utilizan datos extraídos de Sufan et al. (2022) asociados al Hospital del Centro del Cáncer UC, con datos desde agosto 2016 a octubre 2017. Esta instancia considera la existencia de 15 enfermeros/as y 4 sillas de atención, además de 48 módulos de atención, cada uno de 15 minutos, dentro de los cuales los últimos 8 son horas extra regulares. Por sobre aquello, se consideraron horas extra irregulares. Para que la generación de pacientes fuese lo más representativa posible, se extrajo información del mismo estudio, en la que se definen los porcentajes de pacientes que padecen cada tipo de cáncer, además de la duración esperada de cada protocolo asociado a cada cáncer. La tabla 4.1 presenta un resumen de lo anterior.

Además, para definir los casos en los que se probaron las distintas reglas y modelos de decisión, se procedió a realizar una etapa de estudio de factibilidad, para validar que los tamaños y complejidades de las instancias fuesen acorde a las capacidades consideradas para el hospital. Para mayor facilidad de manejo de los datos, se confluyeron los distintos tipos de cáncer en siete conjuntos, agrupando todos aquellos tipos que tenían valores esperados de sesiones iguales, lo que se representa en la tabla 4.2.

Tabla 4.1. Frecuencias y requerimientos de protocolos asociados a distintos tipos de cáncer.

<b>Tipo de Cáncer</b>	<b>Número de pacientes</b>	<b>% del total</b>	<b>Capacidad</b>
Ano	3	0,17%	16
Cabeza/Cuello	24	1,34%	8
Colon	245	13,66%	16
Esófago	122	6,80%	25
Gástrico	176	9,82%	16
Recto	90	5,02%	20
Pulmonar	322	17,96%	14
Mama	126	7,03%	15
Ovarios/Útero	54	3,01%	15
Colorrectal	459	25,60%	16
Melanoma	67	3,74%	8
Testículos	29	1,62%	16
Sarcomas	21	1,17%	18
Otros tipos de cáncer	55	3,07%	-
<b>Total</b>	<b>1793</b>	<b>100%</b>	<b>-</b>

Tabla 4.2. Características principales de los grupos de cáncer considerados en este estudio.

<b>Grupo</b>	<b>Porcentaje</b>	<b>Módulos</b>	<b>Tipos de Cáncer considerado</b>
Cáncer 1	6,80%	25	Esófago
Cáncer 2	5,02%	20	Recto
Cáncer 3	1,17%	18	Sarcomas
Cáncer 4	50,87%	16	Ano, Colon, Gástrico, Colorrectal, Testículo
Cáncer 5	10,04%	15	Ovarios/Útero, Mama
Cáncer 6	17,96%	14	Pulmonar
Cáncer 7	5,08%	8	Cabeza/Cuello, Melanoma
Otros	3,07%	-	-

## 4.2. Estudio de factibilidad

Tomando los grupos expuestos en la tabla anterior, se procedió a realizar un estudio de factibilidad con el fin de determinar los rangos de *input* que se permiten para cada parámetro.

Esto se realizó con el siguiente procedimiento:

- (i) Se define un rango para cada parámetro sobre el cual se itera. En particular, para el número de pacientes se decidió probar [20, 25, 30, 35, 37, 40, 42, 45, 48], mientras que para los porcentajes de generación de *bounds* por sobre y debajo de los valores esperados de atención, [10, 20, 30].
- (ii) Cada una de estas tuplas de número de pacientes - porcentaje se corrió para 50 escenarios con pacientes distintos, sampleados a partir de las frecuencias reportadas en la tabla 4.1. Se guardaron las funciones objetivos alcanzadas en cada corrida, además de la cantidad de escenarios que resultaron infactibles.
- (iii) Se tomaron dos reglas básicas: considerar que los pacientes demoran su valor esperado (*i.e.*: *expected* o Regla de Valor Esperado RVE) y una regla muy conservadora, en que cada cual se demora el máximo posible (según el parámetro de porcentaje ya explicado, *i.e.*: *upper bound* o Regla Límite Superior RLS).

Cabe recordar que la función objetivo considerada es la original del modelo de Turkcan et al. (2012), es decir, el *makespan* que alcanza el sistema en aquel día. Los resultados del estudio, para su primera parte asociada a la cantidad de escenarios infactibles se presentan en la figura 4.1.

Esto entrega información valiosa acerca de los tamaños que puede manejar el modelo con la capacidad considerada de 4 enfermeros/as, 15 sillas y 48 módulos de 15 minutos (08:30 a 20:30 horas). Se puede separar el análisis en dos: Regla de Valor Esperado (RVE) y Regla Límite Superior (RLS). Para efectos del primero, como se observa, hasta alrededor de 40 pacientes no tiene mucho problema en encontrar factibilidad, es decir,

se puede considerar justo ahí un estado no exigido del sistema, pero al borde de serlo, al menos considerando solamente la factibilidad. Tanto con 40 como 42 pacientes se denota un estado levemente saturado para efectos de esta misma dimensión. Si se sigue probando con tamaños de instancias más grandes, se observa que ya con 45 a 48 pacientes se vuelve prácticamente inviable la atención, ya que más de la mitad de los escenarios o configuraciones internas se vuelven infactibles. Por otra parte, considerando los casos de la RLS, hace mucho sentido que a medida que se considera un *bound* más grande, más conservadora es la solución y por ende más rápidamente se vuelve infactible. Así, considerando ambos extremos, con 30% se alcanza total infactibilidad en alrededor de 35 pacientes, mientras que con 10% este punto se alcanza cercano a los 45 pacientes.

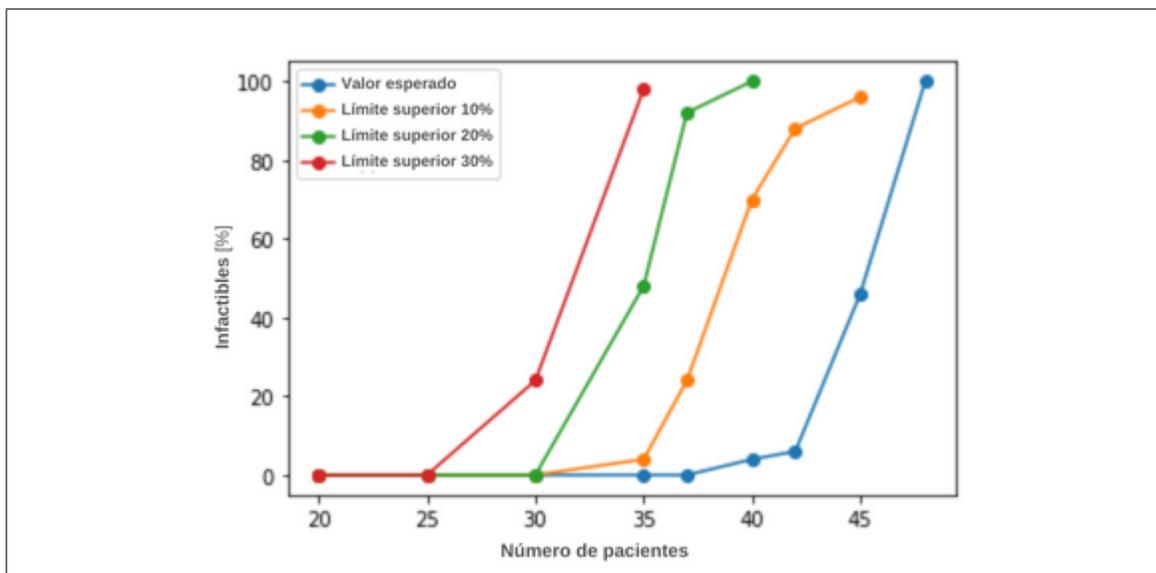


Figura 4.1. Estudio de factibilidad: casos infactibles.

En la figura 4.2 se presenta la segunda arista del estudio, relativo a los resultados de las funciones objetivo del experimento.

Al observar cómo se comportan las funciones objetivo respectivas, es posible notar que ya sobre 35 pacientes se generan funciones objetivo promedio superiores a la cantidad de horas disponibles sin recurrir a horas extra para cualquier regla. Esto entrega información acerca de la saturación del sistema en dicho caso. Así, a diferencia de la conclusión

extraída del análisis de las infactibilidades, 40 pacientes sí pareciera ser un estado bastante exigido, pues recordemos que la instancia considera 48 módulos como máximo, siendo las 8 últimas horas extra, por lo que tener resultados en dicha cercanía implica que se están usando prácticamente todas las horas extra posibles siempre.

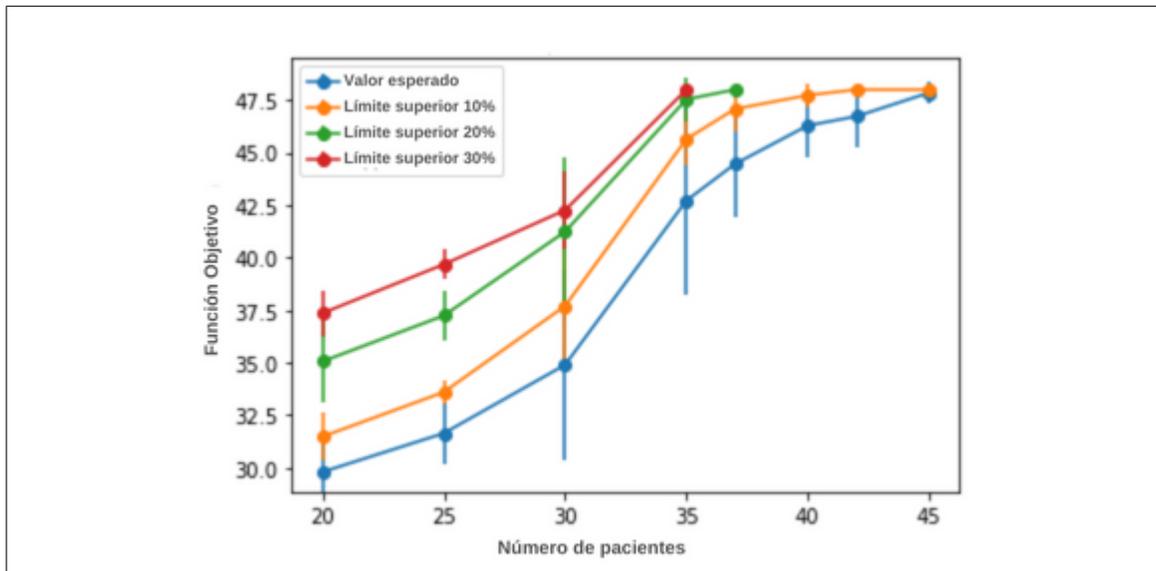


Figura 4.2. Estudio de factibilidad: funciones objetivo.

Como fue comentado, el objetivo de este estudio era comprender de forma numérica cuáles son los rangos en los cuales un sistema está o no en un estado saturado. Como fue observado, no existe en este caso solo una métrica para evaluar dicho estado. Con estos resultados, se determinaron los casos de estudio a ser evaluados durante la investigación. En particular, estos *sets* de datos corresponden a conjuntos representativos en dos dimensiones, todos siendo considerados con un porcentaje de 20% para la generación de *bounds* de tiempos de atención por paciente.

La primera dimensión que se consideró es la cantidad de pacientes, con lo que se definió primero un estándar de 37 pacientes, con tal de que fuese un sistema relativamente exigido pero no extremo. En esta dimensión se presentó una variación, generando así otro conjunto con menos pacientes (*i.e.* estado poco exigido) y otro con más pacientes (*i.e.* estado muy exigido). Por otra parte, se torna relevante también no solamente la cantidad

de pacientes, sino que la composición interna de estos pacientes. Así, se decidió dividir los tipos de cáncer en uno de altos requerimientos, y otro de bajos, y se modificaron sus porcentajes de representación para su respectivo *sampling*.

Los datos de los distintos casos de estudio se exponen en la tabla 4.3.

Tabla 4.3. Definición de casos de estudio.

<i>Descripción del Set</i>	<i>Representativo</i>	<i>Pacientes con alto requerimiento</i>	<i>Pacientes con bajo requerimiento</i>	<i>Baja demanda</i>	<i>Alta demanda</i>
<b>Grupos de Cáncer</b>	<b>Set 1</b>	<b>Set 2</b>	<b>Set 3</b>	<b>Set 4</b>	<b>Set 5</b>
Cáncer 1	3	75%	25%	2	3
Cáncer 2	2			2	2
Cáncer 3	1			1	1
Cáncer 4	18	25%	75%	17	20
Cáncer 5	4			4	4
Cáncer 6	7			6	8
Cáncer 7	2			2	2
<b>Número de pacientes</b>	37	37	37	34	40

El Set 1 es un conjunto de pacientes representativo, es decir, replica las frecuencias históricas ajustadas para una cantidad dada de pacientes, en este caso, 37. Luego, el Set 2 consistió en un muestreo de una mayoría (75%) de pacientes de requerimientos altos, es decir, los grupos de cáncer 1, 2 y 3, y el Set 3 es equivalente pero para los grupos de cáncer restantes o de bajo requerimiento. Finalmente, los Sets 4 y 5 son escenarios representativos (al igual que el Set 1), pero de muy baja y muy alta demanda, respectivamente. La ventaja de contar con estos casos de estudio es que, por un lado, se observan los resultados de los algoritmos en casos representativos, pero también se expusieron a casos de mayor o menor demanda, tanto por la cantidad de pacientes como por la combinación interna de esos pacientes y sus necesidades. Luego del muestreo, se definieron los Sets 2 y 3 tal como se presenta en la tabla 4.4.

Tabla 4.4. Definición de casos de estudio: sampleo Sets 2 y 3.

<i>Descripción del Set</i>	<i>Pacientes con alto requerimiento</i>	<i>Pacientes con bajo requerimiento</i>
<b>Grupos de Cáncer</b>	<b>Set 2</b>	<b>Set 3</b>
Cáncer 1	8	2
Cáncer 2	7	2
Cáncer 3	6	4
Cáncer 4	6	2
Cáncer 5	4	12
Cáncer 6	3	8
Cáncer 7	3	7
<b>Número de pacientes</b>	<b>37</b>	<b>37</b>

Con todo lo anterior, ya se cuenta con una serie de conjuntos de pacientes agrupados y representativos basados en la fuente de datos utilizada. Además, en este capítulo fue posible definir una metodología de generación de casos de estudio, la que basándose en factibilidad y resultados del problema tratado, permite definir los límites dentro de los cuales, con las herramientas que se tengan, se puede experimentar de manera razonable.

## 5. RESULTADOS COMPUTACIONALES DE LOS CASOS DE ESTUDIO

En este capítulo se presentan los resultados de los experimentos computacionales realizados con los distintos casos de estudio definidos en la sección 4. Primeramente, en la sección 5.1 se presentan las reglas básicas a considerar, y su respectivo análisis de resultados. Posteriormente, en la sección 5.2 se adicionan otros experimentos y técnicas de resolución en búsqueda de encontrar mejoras ante la mejor de las reglas básicas encontrada. Finalmente, la sección 5.3 presenta una discusión acerca de los principales hallazgos de los experimentos.

### 5.1. Reglas básicas de decisión

Como fue explicado en la sección anterior, el objetivo computacional es poder analizar distintas reglas de decisión para cada uno de los casos de estudio, pudiendo con ello llegar a la formulación de una regla que, si bien pueda adaptarse a la incertidumbre de mejor forma, no sea excesivamente conservadora. En este contexto, las reglas elegidas para el análisis inicial fueron:

- (i) Regla de Valor Esperado (RVE o *Expected*): consiste en realizar el agendamiento tomando en cuenta que cada paciente se demorará exactamente su valor esperado de *slots*.
- (ii) Regla Límite Superior (RLS o *Upper bound*): siendo la regla más conservadora, esta asume que todo paciente demorará exactamente el máximo posible.
- (iii) Regla Límite Inferior (RVS o *Lower bound*): al opuesto de la regla anterior, esta asumirá un caso excesivamente optimista en que todos demoren lo mínimo que pueden demorarse en su atención.

Luego de hecha la asignación con cada una de las reglas anteriores, se procede a simular 1000 veces el flujo del día completo, computando los costos asociados en cada uno de estos escenarios a la asignación. Todo proceso computacional realizado fue hecho en un

computador con un procesador Intel(R) Core(TM) i5-7200U CPU @ 2.50GHz y 12 GB RAM y con el *solver* Gurobi 9.5 para resolver los modelos de optimización matemática.

### 5.1.1. Análisis por regla

A continuación se comienza con un análisis individual por cada una de las reglas básicas utilizadas, con tal de entender mejor cada una de ellas en su potencial uso en los casos simulados.

#### 5.1.1.1. Regla Límite Superior

La tabla 5.1 muestra los resultados de las métricas de los cinco *sets* de estudio mediante la asignación con la regla de Límite Superior (RLS) o de considerar los máximos tiempos posibles de cada paciente.

Tabla 5.1. Resultados promedio (desviación estándar) métricas RLS.

Set	Tiempo	Función Objetivo	Makespan Real	Costo de Empuje	Costo de Inactividad	Costo Extra	Costo Extra Irregular
1					infactible		
2					infactible		
3	170	46	43,5 (1,54)	0 (0,00)	111,02 (12,85)	7,59 (4,25)	0 (0,00)
4	145	48	45,09 (19,2)	0 (0,00)	114,24 (11,30)	11,64 (11,64)	0 (0,00)
5					infactible		

Es posible notar que no todos los casos de estudio son factibles de resolver con una regla tan conservadora como esta, lo que de primera nos entrega una intuición de que en casos tanto de mucha demanda como de configuraciones internas de pacientes con muchos requerimientos, esta no será una opción. Además de lo anterior, se observa que por construcción siempre tendrá costos de empuje de cero, pues la regla está asumiendo que cada paciente demora lo máximo que puede demorar y le agenda para ello, por lo que jamás ocurrirá que un paciente demore más de lo agendado, afectando a los que vengan después. Por otra parte, el gran costo que implica esta regla conservadora, incluso más que

la infactibilidad en muchos casos, tiene relación con los altos costos de inactividad, pues al considerar siempre el peor de los escenarios para cada paciente, deja también muchos *slots* vacíos en la práctica.

En cuanto al *makespan* real obtenido de las simulaciones, es similar pero siempre inferior al obtenido de la función objetivo. Esto ocurre debido a que, dado que se está asignando de la forma más conservadora posible y la asignación debe ser factible, no podrá ocurrir que en la simulación existan pacientes que se atrasen más de lo agendado, empujando el *makespan* a crecer aún más.

Relativo a los costos extra, se observa que en ambos casos se incurre en ellos, lo que hace sentido al ver sus respectivas funciones objetivo por sobre los 40 *slots*. Por otra parte, por construcción jamás esta regla incurrirá en costos extra irregulares, pues aquellos supondrían una demora mayor a la agendada.

Por último, en lo que respecta a los tiempos de resolución, resulta interesante observar que el Set 4 (*i.e.*: Baja demanda, 34 pacientes) resultara más lento de resolver que el Set 3 que posee 37 pacientes. Es posible que esto ocurra debido a que para el caso de estudio con menos pacientes importará, para el modelo, mucho más el agendamiento de todas las sillas, pues se busca minimizar el *makespan* total agrupado. Así, si se cuenta con algún paciente que demore mucho y se tome todo el día en una de las sillas, por decir un ejemplo, para el modelo no será tan difícil agendar a todo el resto de los pacientes a lo largo de las otras sillas, ya que habrá muchas alternativas de configuraciones de asignación que tendrán la misma función objetivo.

#### **5.1.1.2. Regla de Valor Esperado**

La tabla 5.2, mediante la asignación de los tiempos esperados para cada paciente, muestra las distintas métricas resultantes para cada *set*.

Tabla 5.2. Resultados promedio (desviación estándar) métricas RVE.

Set	Tiempo	Función Objetivo	Makespan Real	Costo de Empuje	Costo de Inactividad	Costo Extra	Costo Extra Irregular
1	156	45	49,05 (1,87)	14,41 (6,07)	64,99 (9,84)	29,67 (8,41)	1,84 (2,11)
2	217	47	53,11 (1,69)	22,68 (8,07)	50,75 (9,77)	47,01 (11,40)	13,96 (6,62)
3	192	39	44,06 (1,57)	12,85 (5,19)	53,85 (7,66)	9,75 (5,03)	0 (0,0)
4	199	42	45,19 (1,86)	13,37 (5,26)	45,26 (7,26)	11,76 (5,52)	0,04 (0,19)
5	181	46	51,01 (1,79)	19,7 (7,35)	57,8 (10,88)	43,03 (10,32)	5,52 (3,90)

Esta regla presenta factibilidad en los cinco casos de estudio propuestos. Al notar los resultados reales del *makespan*, este sube en promedio entre 3 y 6 puntos por sobre la función objetivo. En cuanto a los costos, se observa que si bien son bastante variables entre los distintos *sets*, los que más diferencias presentan son los costos extra regulares e irregulares. Dada la función objetivo, pareciera que el Set 3 es el más sencillo de resolver, además de que presenta el menor *makespan* y costos de empuje y extras en general. Sin embargo, en cuanto a los costos de inactividad se encuentra en la mitad. Como recordatorio, el Set 3 es aquel que al igual que el 1 y el 2 presenta 37 pacientes, pero esta vez con una mayor proporción de pacientes con requerimientos más bajos. Esto hace sentido con la interpretación de que se vuelva más sencilla su resolución, pues serán menos *slots* que asignar, y a su vez pacientes con menor variabilidad. Por esta razón, tanto función objetivo como todos los otros costos se presentan en menores niveles.

En cuanto a los tiempos de resolución, llama la atención nuevamente que el *set* con menores costos no es aquél más sencillo computacionalmente de resolver. Sin embargo, por el mismo argumento esbozado anteriormente, es probable que menores funciones objetivos también exijan más al *solver* para tener que ajustar a todos los pacientes dentro de ese rango. En cualquier caso, los tiempos van entre 150 y 220 segundos, lo que no presentaría mayores diferencias en la práctica para realizar las asignaciones diarias.

### 5.1.1.3. Regla Límite Inferior

La tabla 5.3 muestra los resultados de cada caso de estudio con sus respectivas métricas utilizando la regla de considerar los mínimos tiempos posibles de cada paciente, es decir, un caso muy optimista.

Tabla 5.3. Resultados promedio (desviación estándar) métricas RLS.

Set	Tiempo	Función Objetivo	Makespan Real	Costo de Empuje	Costo de Inactividad	Costo Extra	Costo Extra Irregular
1	137	35	49,46 (2,06)	83,58 (13,91)	25,8 (2,73)	29,74 (8,61)	2,24 (2,24)
2	226	37	53,18 (1,64)	98,29 (14,50)	21,85 (1,13)	45,67 (11,74)	14,31 (6,50)
3	157	31	43,94 (1,64)	74,28 (11,98)	26,06 (1,23)	9,2 (4,83)	0 (0,00)
4	131	33	45,46 (2,02)	67,05 (11,43)	29,62 (2,47)	12,82 (5,92)	0,11 (0,39)
5	159	36	51,76 (2,17)	101,85 (15,15)	23,08 (1,96)	40,84 (10,41)	6,81 (4,47)

Esta regla se define como la más optimista posible: asume que todo paciente se demorará lo menos posible. Así, hace sentido encontrar funciones objetivo en general mucho más bajas que en el resto, mientras que los tiempos de resolución también rondan los 130-220 segundos, igual que en los casos anteriores. Se observa, además, que los *makespan* reales son, en todos los casos, por sobre 10 *slots* de lo presupuestado teóricamente, visible en la función objetivo. Por ende, no es de extrañar que los costos de empuje también presenten valores muy elevados.

Al igual que en el inciso anterior, pareciera que el Set 3 lleva la delantera en cuanto a la menor exigencia del sistema, aunque en este caso no solo teniendo como excepción los costos de inactividad sino que también los de empuje.

### 5.1.2. Comparación entre reglas

A continuación se realiza un análisis comparativo para cada una de las reglas, con foco en cada una de las métricas obtenidas de las corridas del modelo.

### 5.1.2.1. Real Makespan

En cuanto al *makespan* promedio de las simulaciones, es decir, los tiempos de cierre de los centros hospitalarios o el máximo entre los tiempos de atención de todas las sillas, se pueden observar sus resultados en la figura 5.1.

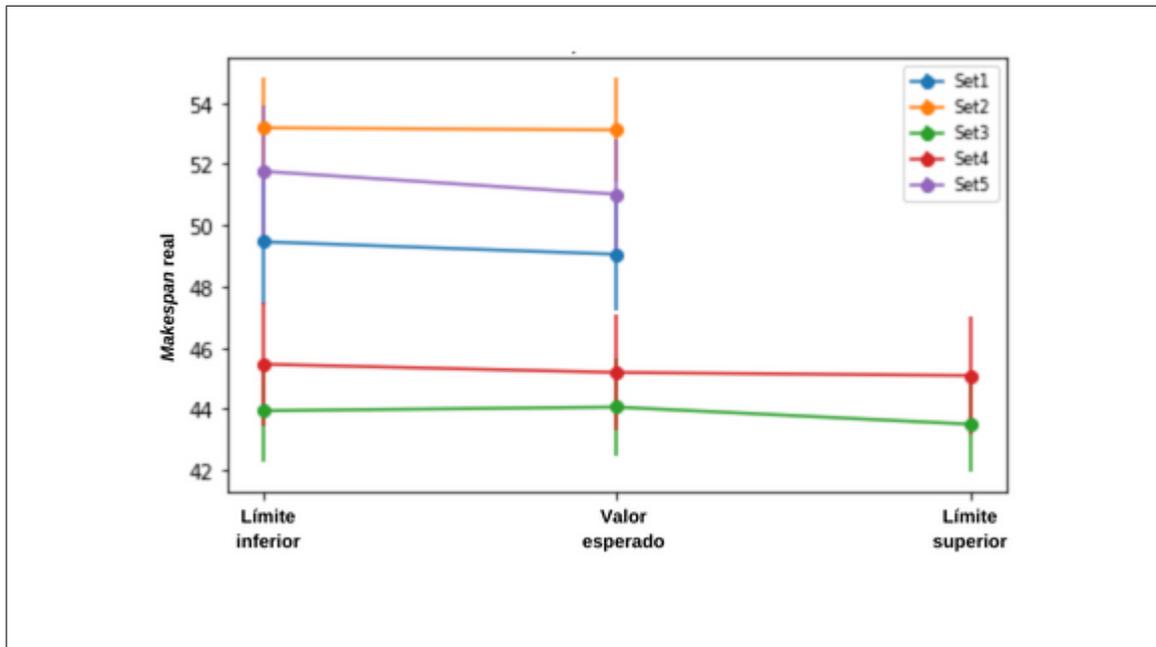


Figura 5.1. Comparación entre reglas para *Real Makespan*.

Resulta interesante observar de que prácticamente no existe diferencia entre las tres reglas para efectos del *makespan* real obtenido de las simulaciones. Es decir, sin importar si se agendaba considerando un tiempo esperado de atención, la cota máxima o la cota mínima, esta métrica terminaba valiendo prácticamente lo mismo en todos los casos. Esto hace sentido al pensar que los pacientes, en la realidad, se están demorando lo mismo, sin importar si se les agendó para más o menos tiempo. Por esta razón, en promedio, el centro hospitalario terminará sus atenciones relativamente a la misma hora, en general.

### 5.1.2.2. Costo de Empuje

En cuanto a los costos de empuje promedio obtenidos por cada regla básica, se presentan sus resultados en la figura 5.2.

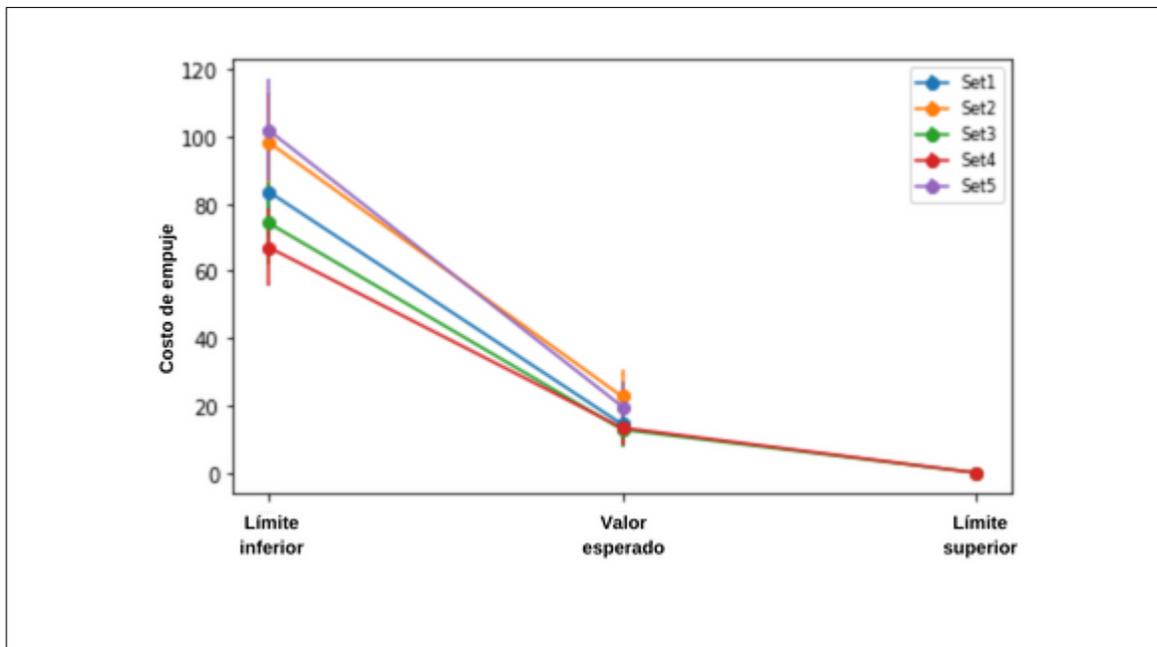


Figura 5.2. Comparación entre reglas para costos de empuje.

Como fue comentado anteriormente, la RLS por construcción poseerá costo cero de empuje. Además de eso, es posible observar que la regla de utilizar la menor cota de cada paciente presenta estos costos muchísimo más altos que RVE, lo que hace mucho sentido en cuanto a que al asumir casos tan optimistas, es probable que la realización de tiempos de atención de dichos pacientes sea prácticamente siempre superior al tiempo agendado, permitiendo con ello que aumenten mucho los costos de empuje.

### 5.1.2.3. Costo de Inactividad

En la figura 5.3 se observan los resultados de la métrica costos de inactividad desagregados por regla básica para cada *set*.

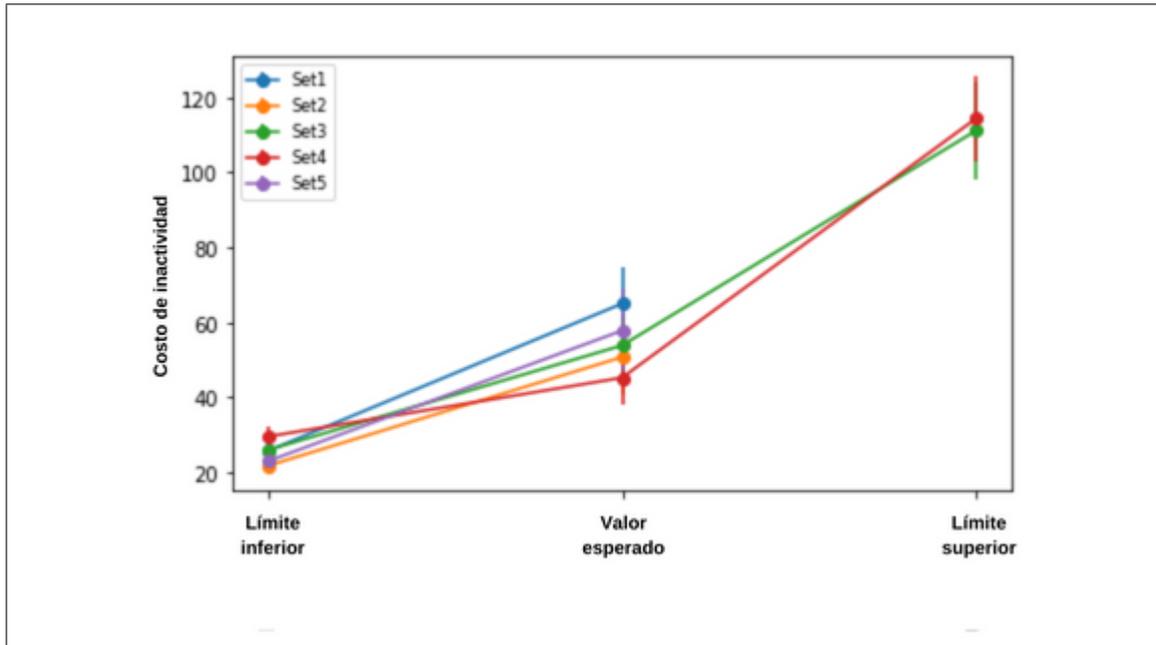


Figura 5.3. Comparación entre reglas para costos de inactividad.

Resulta interesante observar que la RLS es aquella que más costos de inactividad presenta por más del doble con su antecesor (*i.e.* RVE). Esto se entiende en cuanto a que, al ser una regla excesivamente pesimista, asume que todos se demorarán lo máximo posible. Luego, cuando efectivamente se demoran menos, quedan muchísimos espacios vacíos en el sistema, los que se traducen en este aumento de costo. De la mano con esta misma lógica, RLS será la con menores de estos costos, los que son superiores a cero pues se incurren de forma estructural dado que es imposible no tener algunos *slots* vacíos dentro de un día de atención.

#### 5.1.2.4. Costo Extra

Los resultados promedio de cada regla básica a partir de las simulaciones para los costos extra se presentan en la figura 5.4.

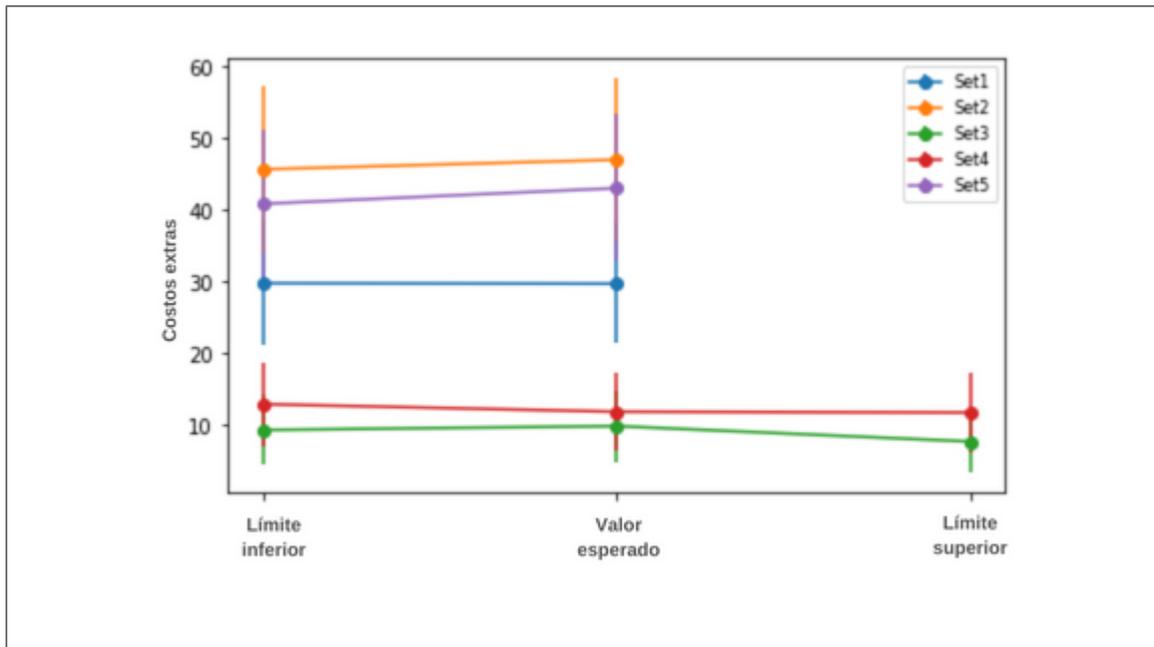


Figura 5.4. Comparación entre reglas para costos extra.

De forma muy parecida al gráfico 5.1 de *makespan* real, se observa que prácticamente no existen diferencias entre las distintas reglas. Esto hace sentido en cuanto a que finalmente un mayor *makespan* en la simulación (*i.e.* *makespan* real), siempre que se pase de los módulos regulares, involucrará también una mayor presencia de costos extra necesariamente. Así, demorarse más implicará incurrir en costos extra, lo que por definición tiene sentido. Entonces, si se observa que el *makespan* suele ser muy parecido incluso entre reglas, hace sentido que lo mismo ocurra con estos costos extra.

#### 5.1.2.5. Costo Extra Irregular

De la mano con la métrica anterior, ocurre exactamente lo mismo: no parece haber diferencias significativas entre reglas para los costos extra irregulares. Así, tanto costos extra como extra irregulares describen correctamente el comportamiento del *makespan* real, ya que son distintas formas de medir lo mismo.

La figura 5.5 presenta, para cada caso de estudio y regla básica, los resultados de la métrica asociada a los costos irregulares extra.

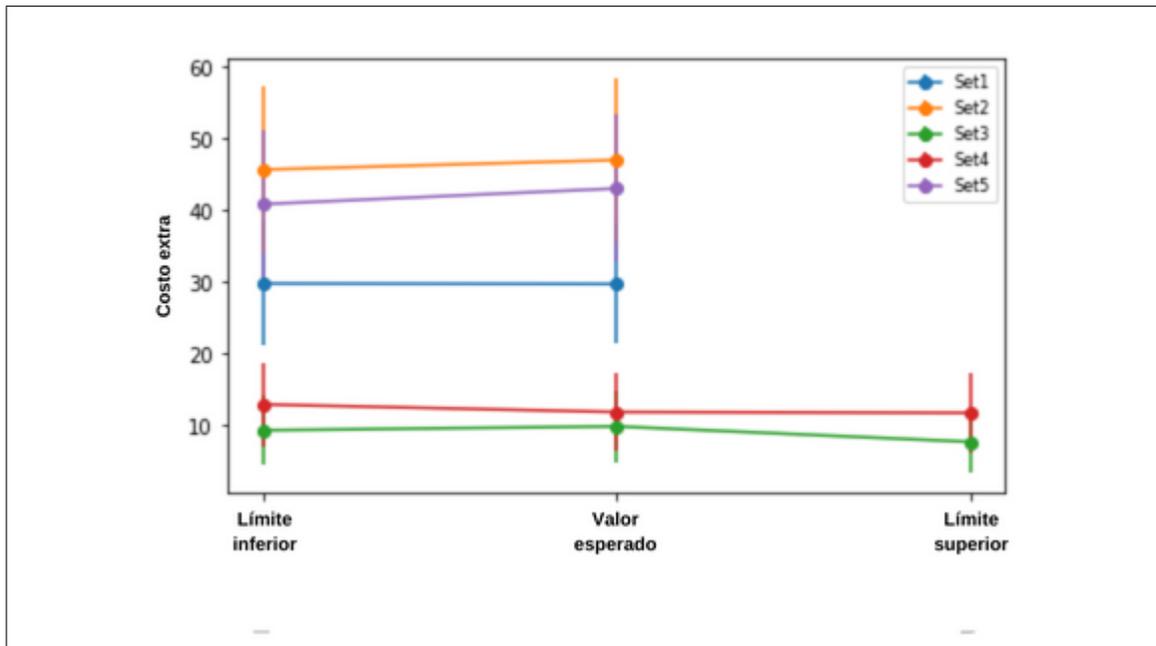


Figura 5.5. Comparación entre reglas para costos extra irregulares.

#### 5.1.2.6. Comparación Costos totales

Debido a que no basta con revisar los costos por separado, en la figura 5.6 se encuentran todos sumados, considerando inicialmente un ponderador de 1 para cada uno. Es decir, se los costos aquí presentados están medidos directamente en *slots*.

En particular, se observa que, para los dos casos de estudio en que RLS es factible, este presenta costos totales mucho más altos que el resto de las reglas, así como también RVE presenta costos más bajos que todo el resto.

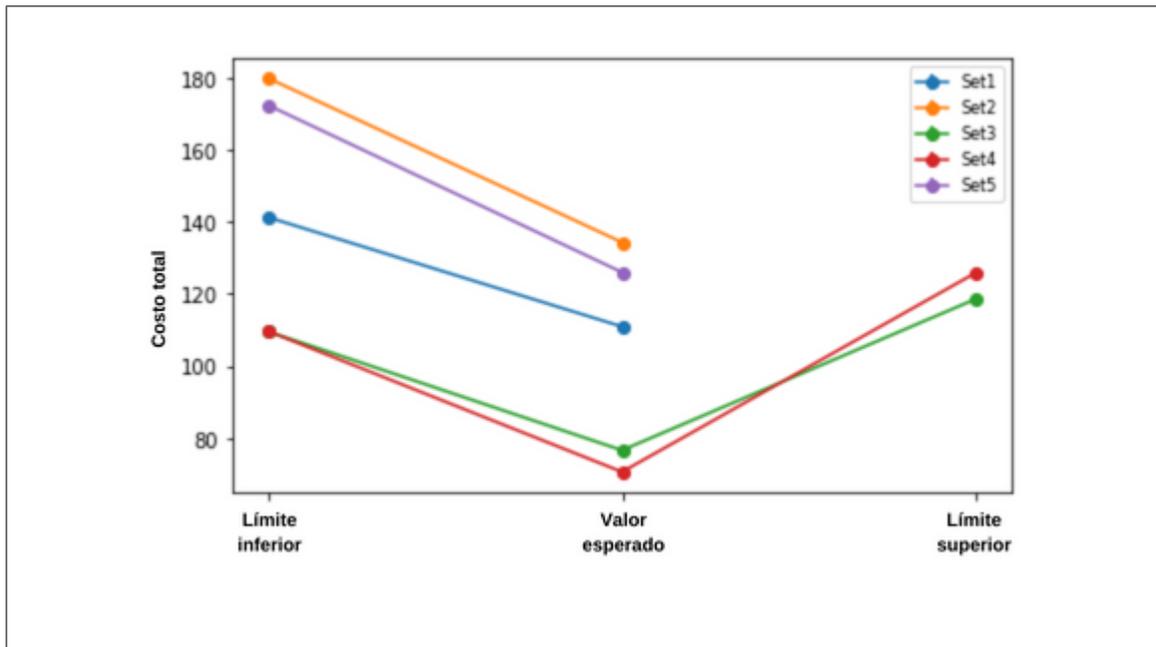


Figura 5.6. Comparación entre reglas para *Total Costs*.

Se podría pensar que no todos los tiempos ni costos debieran pesar lo mismo en la realidad. Con base en las reglas de las filas de espera de Maister (1985), se rescata el hecho de que hacer que un paciente que ya llegó espere por sobre su hora agendada porque aún no se desocupa el sistema es un tiempo mucho más costoso que la espera natural previa a la hora agendada. Lo último es percibido como normal pues aún no comienza su horario de atención, mientras que lo primero afecta gravemente a la percepción del nivel de satisfacción del paciente por el servicio. Por otra parte, las horas extra irregulares deben ser mucho más caras que cualquier otra cosa, pues implican un funcionamiento del centro hospitalario hasta horas no presupuestadas inicialmente. De los argumentos anteriores se propone una serie de ponderadores referenciales, con los que se realiza un cálculo de costos ponderados. En particular, los costos irregulares extra tendrán un ponderador de 4, luego vendrá el empuje con 3, por su alto impacto no solo en el funcionamiento del sistema sino que en la experiencia de cada paciente. Finalmente, los costos extra tendrán un ponderador de 2, y 1 para los costos de inactividad.

Los costos totales ponderados para cada caso se pueden observar en la figura 5.7.

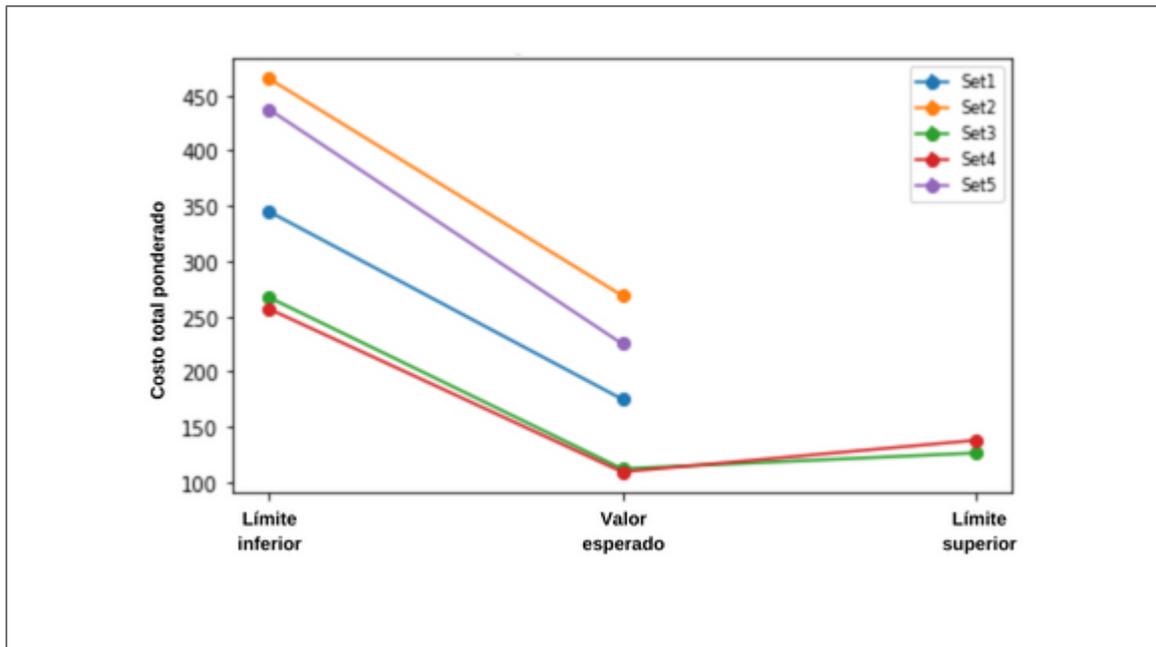


Figura 5.7. Comparación entre reglas para *Total Weighted Costs*.

En el gráfico anterior se observa que, con estas ponderaciones, RLS ya no presenta niveles de costos tan altos en comparación al resto, principalmente por no presentar costos de empuje, con lo que RLI toma la delantera en mayores costos totales ponderados. Además, se mantiene la ventaja en todos los *sets* que presenta la RVE. Además de esto, se percibe que la regla de Límite Superior pareciera no ser tanto peor que la regla de Valor Esperado, al menos a nivel de costos. Sin embargo, el hecho de que esta presente altos niveles de infactibilidad la hace una regla no tan deseable de utilizar en la práctica. Lo anterior demuestra, inicialmente, que esta regla sencilla de asumir que cada paciente demorará su valor esperado (*i.e.* RVE) es en efecto bastante buena en relación a otras más o menos conservadoras, por lo que su uso, si bien se ha demostrado también que supondrá costos extra no presupuestados, pareciera ser mejor que las otras reglas.

## 5.2. Experimentos adicionales

A continuación se presentan distintas técnicas para generar reglas levemente más complejas, pero que son construidas a partir de las mejores reglas básicas ya expuestas en el

inciso anterior. En particular, la subsección 5.2.1 presenta modificaciones en la función objetivo mediante penalizaciones a ciertas asignaciones en el modelo de optimización. Luego, la subsección 5.2.2 presenta una técnica de prohibición de ciertos horarios de agendamiento para ciertos pacientes, y de forma similar, la subsección 5.2.3 hace lo mismo pero en vez de prohibir, toma algunos resguardos de asignaciones por sobre los tiempos esperados para dichos pacientes. Por último, la subsección 5.2.4 busca poner a prueba la mezcla de los mejores resultados de los experimentos de forma conjunta.

### 5.2.1. Modificaciones a la Función Objetivo

Como fue explicado anteriormente, para los primeros experimentos se utilizó la función objetivo original del modelo de Turkcan et al. (2012) (utilizado indistintamente en adelante como, y se obtuvieron algunos resultados aún no suficientes, pero que podrían ser interesantes de ahondar, como que la RVE presentó los mejores resultados entre las tres analizadas. Por lo anterior, surge la duda de si esta misma regla de decisión, aplicada mediante otras funciones objetivo, o en palabras más sencillas, en donde se penalicen o promuevan otras configuraciones internas de agendamientos, podría resultar en mejores resultados. Detrás de esta intuición está el hecho de que las métricas calculadas en las simulaciones no solo se ven afectadas por el *makespan* o tiempo máximo de atención del día, sino que también por interacciones entre las variaciones de los tiempos de atención de los mismos pacientes, con lo que la configuración interna de dichos agendamientos pasa a tomar un rol mucho más relevante. Por lo anterior, se presenta como próximo experimento cuatro nuevas funciones objetivo, en las que se penalizan distintos grupos de pacientes para distintos módulos horarios del día, a modo de analizar el comportamiento de dichas funciones objetivo en el marco de este estudio. Las nuevas funciones son:

- (i) Alto-PM (APM): a los pacientes de grupos de cáncer de mayores requerimientos (*i.e.*: grupos 1, 2 y 3) se les penaliza por comenzar sus tratamientos en los últimos 20 *slots*.

- (ii) Alto-AM (AAM): idéntico al anterior, pero para los inicios de tratamiento que comiencen en los primeros 20 *slots*.
- (iii) Bajo-PM (BPM): contrario al primer punto, al resto de los pacientes (*i.e.*: grupos 5 al 7) se les penaliza por comenzar en los *slots* de más tarde.
- (iv) Bajo-AM (BAM): mismo concepto, pero en los *slots* de más temprano.

En todos los casos, se busca minimizar estos distintos grupos asignados a comenzar en las respectivas horas definidas, siendo cada uno ponderado por su propio límite superior y sumándosele la función objetivo original, es decir, minimizar el *makespan* agendado. Así, por ejemplo, si el paciente 1 tiene un tipo de cáncer 2 (*i.e.*: con valor esperado de atención 20 *slots*), se le multiplicó por 24 (su límite superior considerando un 20%), de tal forma de hacer pesar más a aquellos pacientes que puedan presentar potencialmente un mayor efecto en la agenda, lo que se traduce en considerar para ello la ponderación de su límite superior.

En la tabla 5.4 se presenta un resumen de los resultados de este experimento, en la que se puede observar cuáles fueron las reglas con menores costos para cada una de las métricas calculadas. El detalle de los costos de cada regla por cada *set* está en el Anexo B. El símbolo asterisco implica empate y el guión implica que dicha regla no fue la mejor en esa métrica.

Tabla 5.4. Tabla resumen de los mejores resultados por métrica por cada regla para experimento funciones objetivo. Signo asterisco implica empate.

Mejor Regla por Métrica	APM	BPM	AAM	BAM	RVE
<b>Costs Totales</b>	Sets 1, 2, 3	Set 5	-	-	Set 4
<b>Costos de Empuje</b>	-	Set 2	Sets 1, 5	Sets 3, 4	-
<b>Costos de Inactividad</b>	Set 3	Sets 1, 5	-	-	Sets 2, 4
<b>Costos Extra</b>	Set 3	Sets 1, 2, 5	-	-	Set 4
<b>Costos Extra Irregulares</b>	Sets 3*, 4*	Set 5	-	-	Sets 1, 2, 3*, 4*

A continuación se presentan los principales *insights* que podrían extraerse de este experimento:

- **APM:** presenta los menores costos totales en los *sets* 1, 2 y 3, y muy cercano al mínimo en el 4 y 5. Todos sus costos suelen rondar muy cerca del clásico RVE, ya sea un poco por encima o un poco por debajo.
- **AAM:** presenta costos de empuje consistentemente más bajos que la función objetivo clásica, pero costos totales más altos, pues sus costos de inactividad tienden a ser mucho mayores.
- **BPM:** logra costos totales menores que la función objetivo clásica en los *sets* 1, 2 y 5, mientras que en los otros dos está alrededor de 20 puntos por sobre los costos totales de dicha regla. En cuanto a los costos, los extra irregulares suelen ser considerablemente mayores, mientras que en el resto no se aprecia una tendencia clara. Destaca también que en el Set 5 presenta todos los costos mínimos entre todas las funciones, salvo el de empuje.
- **BAM:** de forma similar a AAM, presenta costos de empuje siempre más bajos que la función clásica, pero sus costos de inactividad llegan a triplicarse en el caso del Set 4.
- **RVE:** la función objetivo original del modelo de Turkcan et al. (2012) se mantiene como una de las mejores opciones, siendo evidente su dominancia en el Set 4, en la que presenta los costos más bajos de todo excepto de empuje. En los extra irregulares también siempre presenta el costo mínimo o muy cercano a él.

De lo anterior, se encuentra una primera propuesta de mejora a la función objetivo original, la que se logra mediante la función APM, es decir, penalizando el agendamiento de pacientes de cáncer de alto requerimiento a iniciar su tratamiento durante la tarde. Aún así, las ventajas de esta función objetivo aún son leves y no aplican en el 100% de los casos.

### 5.2.2. Prohibición de Pacientes

Si bien la penalización pareciera no haber mejorado completamente los resultados de la RVE, sí nos entregó algunos aprendizajes relevantes. Por esa razón, se procedió a realizar un experimento en que no se penalizara, sino que se prohibiera su inicio de agendamiento (*i.e.*:  $Y_s = 0$ ) a ciertos grupos de pacientes. En particular, en la figura 5.8 se observa un ejemplo de las 64 combinaciones existentes (Anexo C) entre tamaño 0 y 6 para los pacientes del Set 1 que tienen un cáncer tipo 1, 2 y 3 (los de mayores requerimientos). Cada posición del eje de las abscisas representa una combinación distinta, teniendo como extremos al 0 siendo el conjunto vacío (es decir, ningún paciente tiene prohibido ningún *slot* de inicio), y el 63 el que a todos los 6 pacientes que tienen cáncer tipos 1, 2 y 3 en este *set* se les prohíbe su inicio de sesión en la primera mitad del día (20 primeros *slots*).

La figura 5.8 es el gráfico de costos totales asociado (el resto en Anexo D), el que permite apreciar que, para este *set*, existe alrededor de la mitad de las combinaciones que logran disminuir los costos frente a la formulación clásica. Esto nos entrega unas primeras luces de disminución de costos algo mejores que las de solamente aplicar la regla APM.

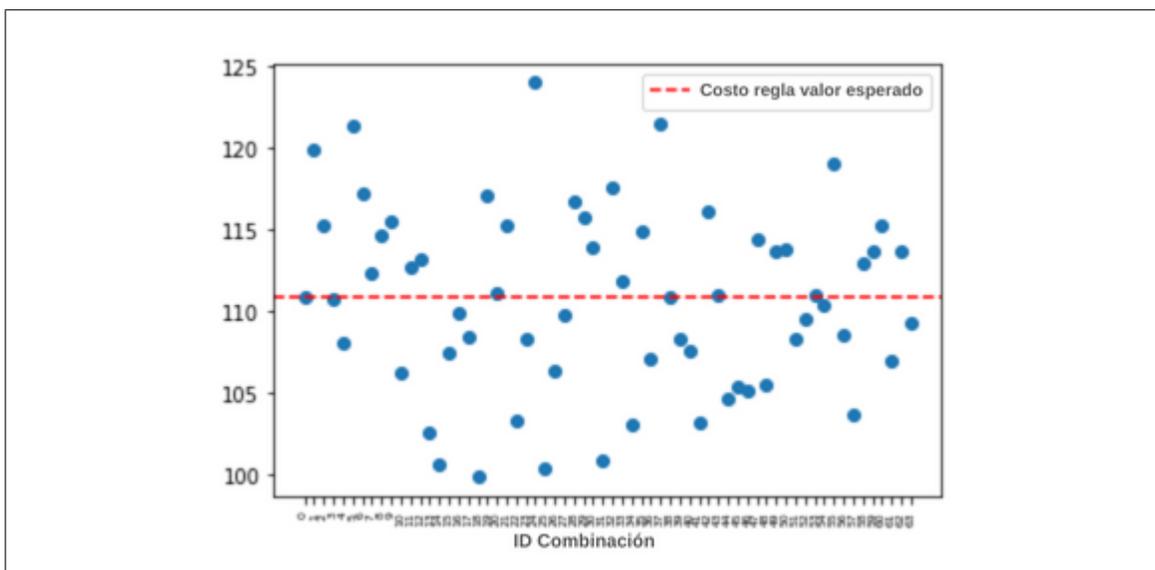


Figura 5.8. Costos totales de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para el Set 1.

El punto con el mejor resultado es la combinación 18, es decir, los pacientes 3 y 6, el primero con tipo de cáncer 1 y el segundo con cáncer 3.

Si bien lo anterior es prometedor, no basta con revisar el comportamiento de esta técnica solamente para un único *set*. Por esto, y dado que el caso de estudio que mayor dificultad parecía presentar en los experimentos anteriores, a continuación se replica la misma metodología pero con el Set 4. En este caso se observa que no existen combinaciones que sean mejores (menores costos) que la formulación clásica, aunque sí destacan algunas a costos muy parecidos y ligeramente por sobre dicha línea de referencia (Anexo D para el detalle de los costos). Sin embargo, al revisar los costos ponderados, es posible notar que hay un par de combinaciones que son ligeramente mejores, como se puede apreciar en la figura 5.9.

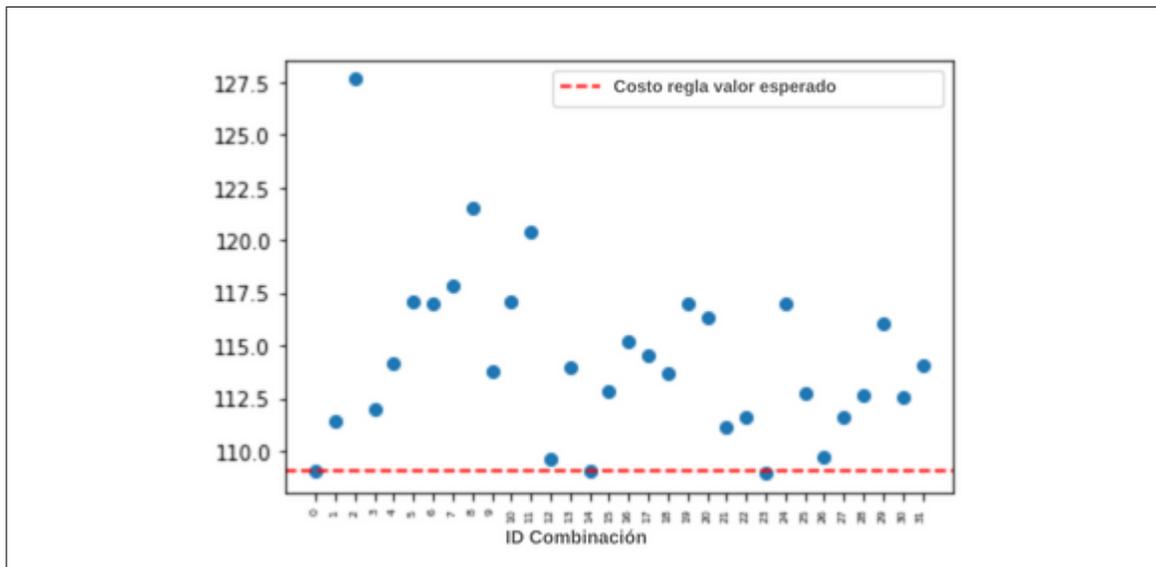


Figura 5.9. Costos ponderados de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para el Set 4.

Los puntos que presentan costos prácticamente iguales al de la función clásica por sí sola son las combinaciones 14 y 23, las que representan la prohibición hecha para los pacientes 3-5 y 2-3-5. Para el caso de este *set*, eso representa prohibir al paciente con tipo

de cáncer 3, además de a uno del cáncer 2 y otro del cáncer 1 (en el caso de la combinación de tamaño tres).

Además de lo anterior, vale la pena observar la tabla 5.5, que muestra cuáles son los pacientes que más fueron parte de los conjuntos con mejores resultados que la asignación sin prohibiciones (*i.e.*: combinación 0), así como también observar cuáles fueron los tamaños de dichos conjuntos en la tabla 5.6. Cabe destacar de que las columnas marcadas con una letra W inicial hacen referencia a los casos de costos totales ponderados.

Tabla 5.5. ID pacientes y sus frecuencias en las combinaciones que obtuvieron mejor resultado que RVE en experimento prohibiciones.

<b>Paciente</b>	<b>WForbid Set 1</b>	<b>Forbid Set 1</b>	<b>WForbid Set 4</b>	<b>Forbid Set 4</b>
1	14	15	0	0
2	14	15	1	0
3	17	18	2	0
4	18	17	0	0
5	15	16	2	0
6	15	16	-	-

Para poder interpretar de mejor forma esto, es necesario recordar de que para el Set 1 los primeros 3 pacientes son Cáncer 1, los siguientes 2 (4-5) Cáncer 2 y el sexto es Cáncer 3, mientras que para el Set 4 la proporción es 2, 2 y 1, respectivamente. Así, se vuelve equivalente para el Set 1 entre prohibir a los pacientes 1, 2 y 3, por ejemplo. Así, se observa que prácticamente se mantienen constantes las proporciones de prohibición de cada grupo, al normalizarlas o promediarlas según su cantidad de pacientes.

La tabla 5.6 resulta muy interesante, en cuanto a que permite, más allá de la composición de los grupos de prohibición, entender los tamaños que más parecen mejorar los resultados. Así, se percibe una clara tendencia a encontrar un punto ideal más central que extremo, ya que los conjuntos de tamaño tres son por lejos los que mejores resultados presentan. En otras palabras, el impacto que suele tener esta técnica de prohibir parece no ser tanta si solo se prohíbe un paciente, y tampoco parece mejorar cuando se empiezan a

prohibir muchos conjuntamente, quizás por estar imponiendo muchas restricciones extra al agendamiento.

Tabla 5.6. Cantidad de pacientes de los conjuntos que obtuvieron mejor resultado que RVE en experimento prohibiciones.

# Pacientes	WForbid Set 1	Forbid Set 1	WForbid Set 4	Forbid Set 4
1	1	2	0	0
2	7	7	1	0
3	12	11	1	0
4	8	8	0	0
5	2	2	0	0
6	0	1	-	-

Para continuar con un análisis aún más profundo, se pueden observar las tablas 5.7 para costos totales y 5.8 para costos ponderados, que muestran para cada tamaño de conjunto, cuál fue la combinación que mejor resultado entregó, y si el valor está en color rojo implica que no fue capaz de presentar menores costos que el punto de comparación base de la función clásica sin prohibiciones.

Tabla 5.7. Mejor combinación para cada tamaño de conjunto: costos totales Set 1 experimento prohibiciones. Costo total caso base 110,91.

Tamaño	Combinación	Costo Total
1	4	108,07
2	3, 6	99,85
3	1, 2, 6	100,31
4	1, 2, 3, 6	104,58
5	1, 2, 3, 4, 5	103,61
6	1, 2, 3, 4, 5, 6	109,28

Tabla 5.8. Mejor combinación para cada tamaño de conjunto: costos ponderados Set 1 experimento prohibiciones. En rojo las métricas que no son mejores que el caso base (174,92).

<b>Tamaño</b>	<b>Combinación</b>	<b>Costo Total Ponderado</b>
1	4	174,63
2	3, 6	164,37
3	1, 2, 6	168,91
4	1, 2, 4, 5	167,56
5	1, 2, 3, 4, 5	169,52
6	1, 2, 3, 4, 5, 6	182,04

Lo primero que llama la atención es que a contar del tamaño tres, los pacientes 1 y 2 están siempre presentes en la mejor combinación. Asimismo, destaca que todas las mejores combinaciones, incluidas las extremas, presentan mejores resultados que el punto de comparación de la función objetivo clásica sin prohibiciones. Además, salvo el grupo de tamaño cuatro, todo el resto de las mejores combinaciones son las mismas tanto para costos regulares como ponderados.

A continuación se repite el mismo procedimiento pero para el Set 4. Así, la tabla 5.9 es aquella que muestra las mejores combinaciones para cada tamaño de conjunto considerando costos totales, y la tabla 5.10 lo mismo pero para costos ponderados.

Tabla 5.9. Mejor combinación para cada tamaño de conjunto: costos totales Set 4 experimento prohibiciones. En rojo las métricas que no son mejores que el caso base (70,43).

<b>Tamaño</b>	<b>Combinación</b>	<b>Costo Total</b>
1	1	72,62
2	3, 5	72,22
3	2, 3, 5	70,86
4	1, 2, 3, 5	71,15
5	1, 2, 3, 4, 5	75,25

Tabla 5.10. Mejor combinación para cada tamaño de conjunto: costos ponderados Set 4 experimento prohibiciones. En rojo las métricas que no son mejores que el caso base (109,05).

Tamaño	Combinación	Costo Total Ponderado
1	1	111,46
2	3, 5	109,04
3	2, 3, 5	108,97
4	1, 2, 3, 4	109,75
5	1, 2, 3, 4, 5	114,09

De manera similar al caso de estudio anterior, en este caso se observa que todas las combinaciones de mejor desempeño son exactamente las mismas entre los costos regulares y ponderados. Además, en este caso, la gran mayoría de las combinaciones no logra menores costos que el punto de comparación, salvo en el caso ponderado para los tamaños dos y tres.

De los análisis anteriores, se rescata que el experimento de prohibiciones a pacientes con altos requerimientos para los horarios PM logra mejorar en gran medida el desempeño del Set 1, y del Set 4 solamente en unos pocos casos, al notarlo en sus costos totales ponderados.

### 5.2.3. Aumento de Gap de agendamiento para combinaciones de pacientes

Los experimentos anteriores mostraron que, al parecer, penalizar en la función objetivo o prohibir para determinados grupos puede presentar leves mejoras frente a una asignación sin estas técnicas. Además de lo anterior, existe una técnica extra que aún no se ha probado en esta investigación, la que consiste en considerar un mayor *gap* a ciertas combinaciones de pacientes, es decir, agendándolos para un tiempo mayor al esperado (*i.e.* RVE). En particular la figura 5.10 muestra un ejemplo de que para cada una de las mismas combinaciones explicadas en el inciso anterior, a dichos grupos se les asigna dos *slots* por sobre su valor esperado de tiempo de atención. Se escogió dos, por un tema práctico asociado a la

instancia con la que se está trabajando, ya que tres equivale a llegar al límite superior del cáncer tipo 3, por lo que se consideró razonable como punto intermedio un *gap* de dos. Cabe destacar de que aquí no hay horarios predilectos para ningún grupo, por lo que sin importar su horario de asignación estos pacientes serán agendados para dos *slots* por sobre su valor esperado. El resto de los gráficos se encuentran disponibles en el Anexo E.

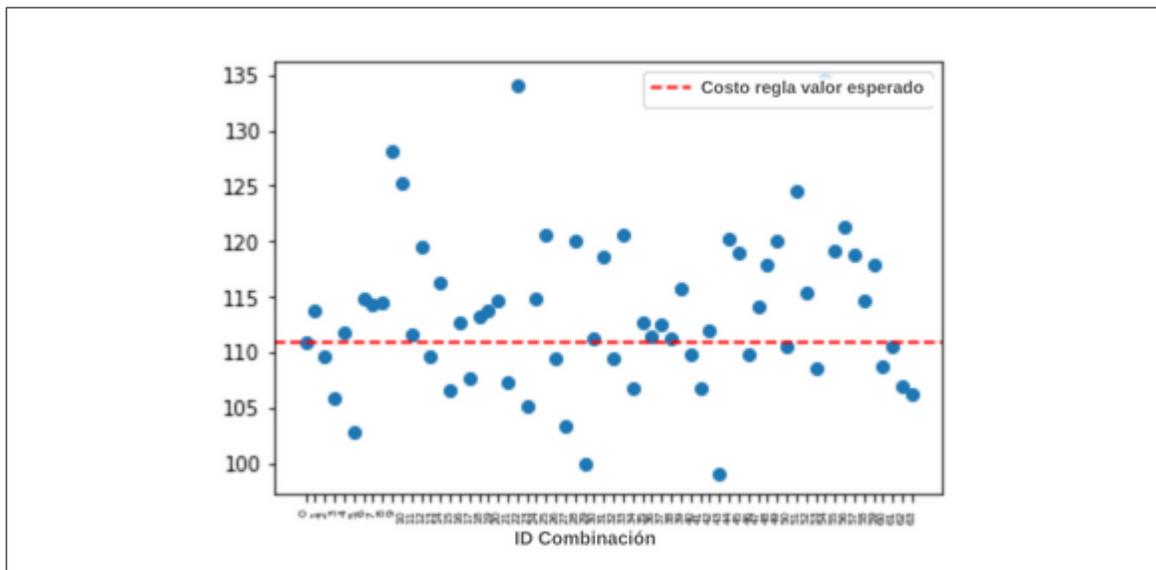


Figura 5.10. Costos totales de pacientes con cáncer de alto requerimiento con *gap* +2 en el Set 1.

Para el Set 1 existe un porcentaje importante de combinaciones que presentan menores costos que nuestra línea base. En particular el que mejor resultados presenta es el 43, es decir, los pacientes 1-2-3-5 agendados con un *gap* extra de dos *slots*, por lo que los tres pacientes con tipo de cáncer 1, además de uno de los con cáncer 2 fueron los escogidos.

De la misma forma, se repite el procedimiento para el Set 4. Nuevamente, al igual que en los experimentos anteriores, este parece ser un caso de estudio mucho más complejo de abordar y mejorar. En este se observa nuevamente que no es posible obtener costos totales inferiores, pero al notar los ponderados sí se alcanzan resultados muy similares al punto de comparación, como se percibe en el gráfico 5.11 de costos totales ponderados.

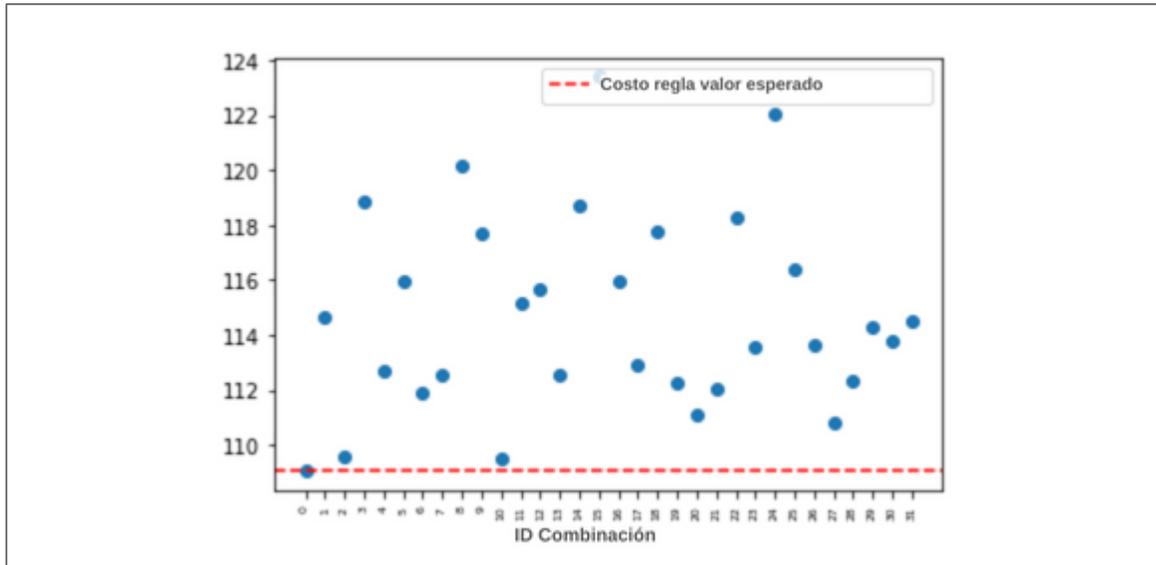


Figura 5.11. Costos totales ponderados de pacientes con cáncer de alto requerimiento con  $gap +2$  en el Set 4.

Los dos puntos de mejor desempeño en esta métrica son las combinaciones 2 y 10, con los pacientes 2 y 2-3 respectivamente, ambos del tipo de cáncer 1, es decir, el con mayores requerimientos de recursos.

La tabla 5.11 representa la información sobre cuáles fueron los pacientes más presentes en las distintas combinaciones, de donde se nota un comportamiento muy similar al del experimento anterior, en que las combinaciones se encuentran bien diversificadas con cada paciente.

Tabla 5.11. ID pacientes y sus frecuencias en las combinaciones que obtuvieron mejor resultado que RVE en experimento *gap*.

Paciente	WGap Set 1	Gap Set 1	WGap Set 4	Gap Set 4
1	13	10	0	0
2	15	12	0	0
3	14	13	0	0
4	13	12	0	0
5	12	13	0	0
6	12	12	-	-

En cuanto al tamaño de los grupos con mejores resultados que el punto de comparación original, se observa que nuevamente se repite el patrón: el grupo intermedio (tamaño tres) es el que más presente está entre los mejores resultados, y hacia los extremos se aprecia una baja considerable, a partir de la tabla 5.12.

Tabla 5.12. Cantidad de pacientes de los conjuntos que obtuvieron mejor resultado que RVE en experimento *gap*.

# Pacientes	WGap Set 1	Gap Set 1	WGap Set 4	Gap Set 4
1	3	3	0	0
2	7	4	0	0
3	9	8	0	0
4	5	4	0	0
5	2	3	0	0
6	1	1	-	-

A continuación se presentan las tablas de las mejores combinaciones para cada tamaño. Así, la tabla 5.13 lo hace para los costos totales y la tabla 5.14 para los costos ponderados, ambas para el Set 1.

Tabla 5.13. Mejor combinación para cada tamaño de conjunto: costos totales Set 1 experimento *gap*. Costo total caso base 110,91.

Tamaño	Combinación	Costo Total
1	5	102,81
2	2, 6	106,6
3	1, 4, 5	99,89
4	1, 2, 3, 5	98,99
5	2, 3, 4, 5, 6	106,98
6	1, 2, 3, 4, 5, 6	106,17

Tabla 5.14. Mejor combinación para cada tamaño de conjunto: costos ponderados Set 1 experimento *gap*. Costo total caso base 174,92.

<b>Tamaño</b>	<b>Combinación</b>	<b>Costo Total Ponderado</b>
1	3	169,47
2	3, 5	168,74
3	1, 4, 5	166,04
4	1, 2, 3, 5	164,77
5	2, 3, 4, 5, 6	169,25
6	1, 2, 3, 4, 5, 6	170,06

Destaca el hecho de que absolutamente todos los tamaños presentan al menos una combinación con mejores resultados que el punto base de comparación original. También es posible notar que las combinaciones de tamaño tres a seis son idénticas, mientras que las de los dos primeros tamaños son levemente distintas. En un caso tenemos pacientes de tipo de cáncer 2 y 1-3, mientras que en el otro tenemos tipo 1 y 1-2. En el caso de los costos ponderados, el paciente 5 está prácticamente en todos los mejores grupos, salvo en el de tamaño uno, mientras que en los costos regulares la excepción es en el tamaño dos.

Repitiendo el procedimiento para el Set 4, se presenta la tabla 5.15 con las mejores combinaciones de cada tamaño según costos totales, y la tabla 5.16 para los costos ponderados.

Tabla 5.15. Mejor combinación para cada tamaño de conjunto: costos totales Set 4 experimento *gap*. En rojo las métricas que no son mejores que el caso base (70,43).

<b>Tamaño</b>	<b>Combinación</b>	<b>Costo Total</b>
1	2	73,77
2	2, 3	73,99
3	1, 3, 5	73,31
4	1, 2, 3, 4	77,24
5	1, 2, 3, 4, 5	83,99

Tabla 5.16. Mejor combinación para cada tamaño de conjunto: costos ponderados Set 4 experimento *gap*. En rojo las métricas que no son mejores que el caso base (109,05).

Tamaño	Combinación	Costo Total Ponderado
1	2	109,55
2	2, 3	109,49
3	1, 3, 5	111,08
4	1, 2, 3, 5	110,83
5	1, 2, 3, 4, 5	114,5

En cuanto a este caso de estudio, ocurre lo contrario: absolutamente todas las combinaciones no logran ser mejor que la comparación original. Asimismo, también destaca de que los mejores resultados se encuentran en las mismas combinaciones para ambos casos ponderado y regular.

#### 5.2.4. Mezcla de técnicas: APM y Gap

Dado que las distintas técnicas presentaban algunas mejoras leves, lo siguiente que es si acaso mezclándolas se podrá obtener mejores resultados. Así, se replicaron los experimentos pero esta vez aplicando la técnica de *gap* +2, además de una función objetivo modificada tipo APM. La figura 5.12 presenta los costos totales no ponderados o regulares para el Set 1, mientras que la figura 5.13 hace lo mismo para el Set 4.

Se destaca que con el uso de esta técnica, por primera vez en todos los experimentos, fue posible disminuir los costos no ponderados del Set 4 bajo la línea de comparación clásica. Asimismo, se da cuenta que para el caso del Set 1, las combinaciones de más a la izquierda (*i.e.*: las con menores tamaños) en el gráfico parecen presentar menores costos. En particular para el primer caso de estudio, la mejor combinación la comparten la 2 con la 12, las que se traducen en: paciente 2 y pacientes 2-3, todos del tipo de cáncer 1. Por el lado del Set 4, son la 19 y la 11 las mejores, las que representan los pacientes 1-3-4 y 2-4, mezclando tanto pacientes de tipo cáncer 1 como del 2.

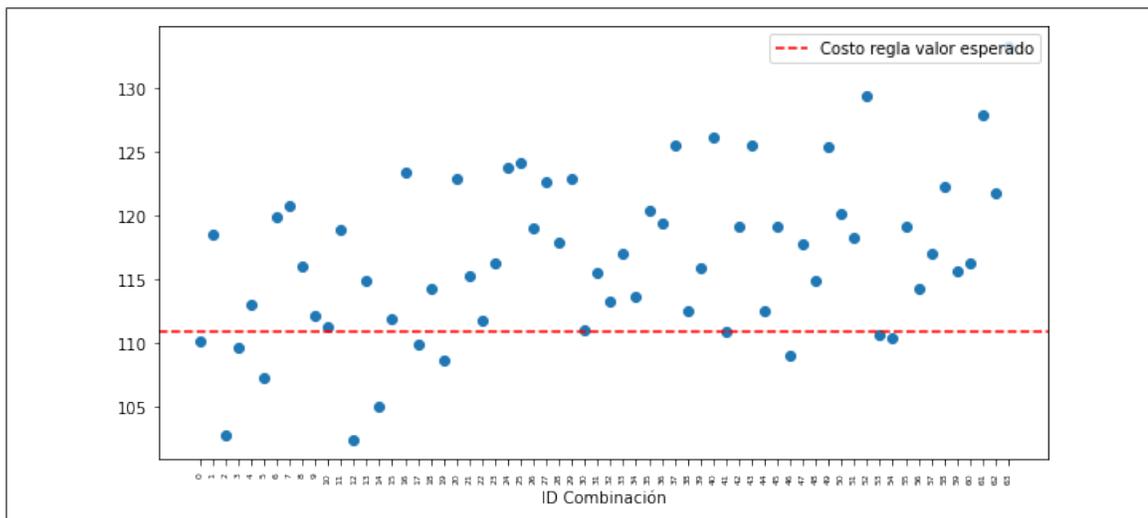


Figura 5.12. Costos totales de pacientes con cáncer de alto requerimiento con *gap* +2 y regla APM para Set 1.

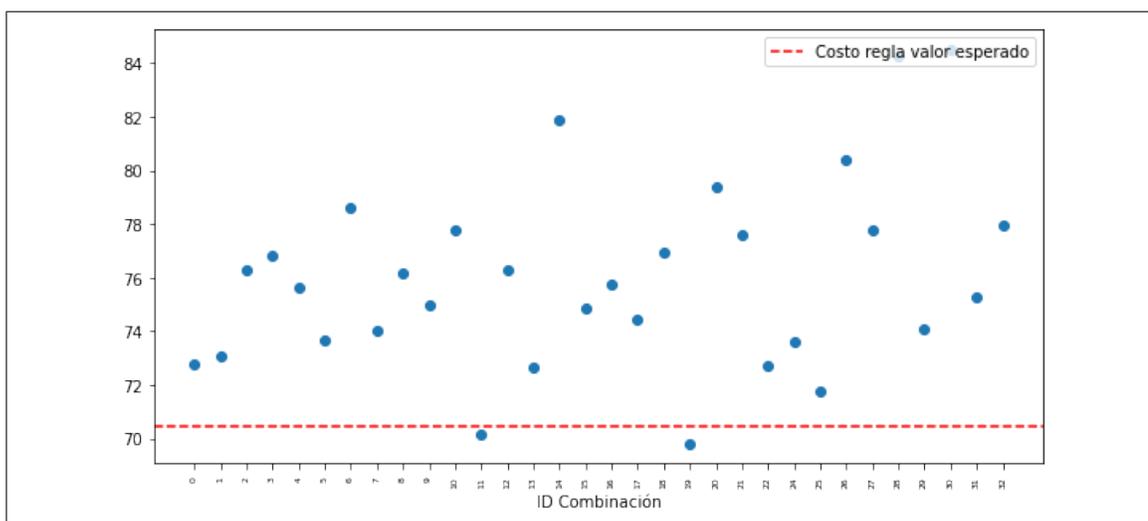


Figura 5.13. Costos totales de pacientes con cáncer de alto requerimiento con *gap* +2 y regla APM para Set 4.

A continuación se presenta la tabla 5.17 relacionada a los pacientes que fueron escogidos en las combinaciones que lograron mejores resultados que la línea comparativa. El detalle de todos los costos se encuentra en el Anexo F.

Tabla 5.17. ID pacientes y sus frecuencias en las combinaciones que obtuvieron mejor resultado que RVE en experimento APM Gap.

<b>Paciente</b>	<b>WAPMGap Set 1</b>	<b>APMGap Set 1</b>	<b>WAPMGap Set 4</b>	<b>APMGap Set 4</b>
1	2	1	1	1
2	6	4	3	3
3	4	3	2	3
4	3	2	4	5
5	3	4	1	1
6	3	1	-	-

A diferencia de en casos anteriores, para el Set 1 la balanza parece estar más inclinada a los pacientes de menores ID, es decir, los con tipos de cáncer de mayores requerimientos, mientras que para el Set 4 están más centrados entre pacientes del grupo de cáncer 1 y 2.

En cuanto a los tamaños de las combinaciones, lo que se representa en la tabla 5.18, para el Set 1 se observa lo que se comentaba del gráfico 5.12: las mejores combinaciones parecen ser las de tamaños más pequeños. Por otra parte, para el otro caso de estudio aquí expuesto, se percibe una mezcla entre pacientes del grupo cáncer 1 y 2, pero con mayor inclinación hacia el grupo central.

Tabla 5.18. Cantidad de pacientes de los conjuntos que obtuvieron mejor resultado que RVE en experimento APM Gap.

<b># Pacientes</b>	<b>WAPMGap Set 1</b>	<b>APMGap Set 1</b>	<b>WAPMGap Set 4</b>	<b>APMGap Set 4</b>
1	3	3	0	0
2	2	4	1	2
3	2	0	3	3
4	2	1	0	0
5	0	0	0	0
6	0	0	-	-

Por último, a continuación se presentan las tablas con los datos de las mejores combinaciones por tamaño del conjunto. Para el Set 1, la tabla 5.19 es para los costos totales, mientras que la tabla 5.20 para los costos ponderados.

Tabla 5.19. Mejor combinación para cada tamaño de conjunto: costos totales Set 1 experimento APM Gap. En rojo las métricas que no son mejores que el caso base (110,91).

Tamaño	Combinación	Costo Total
1	2	102,74
2	2, 3	102,45
3	4, 5, 6	110,94
4	1, 2, 4, 6	109,07
5	1, 2, 3, 5, 6	115,68
6	1, 2, 3, 4, 5, 6	133,33

Tabla 5.20. Mejor combinación para cada tamaño de conjunto: costos ponderados Set 1 experimento APM Gap. En rojo las métricas que no son mejores que el caso base (174,92).

Tamaño	Combinación	Costo Total Ponderado
1	2	167,05
2	2, 3	170,88
3	1, 2, 3	172,28
4	1, 2, 4, 6	172,04
5	1, 2, 3, 4, 5	177,5
6	1, 2, 3, 4, 5, 6	202,6

De aquí se extrae que el único conjunto distinto entre mejores costos regulares y ponderados es el de tamaño tres. Se observa también que más de la mitad de los tamaños de conjunto cuentan con al menos una combinación que presenta mejores resultados que la función clásica sin aplicar ninguna técnica extra.

Repitiendo el procedimiento para el Set 4, la tabla 5.21 con los costos totales y la tabla 5.22 para los costos ponderados.

Tabla 5.21. Mejor combinación para cada tamaño de conjunto: costos totales Set 4 experimento APM Gap. En rojo las métricas que no son mejores que el caso base (70,43).

Tamaño	Combinación	Costo Total
1	1	73,06
2	2, 4	70,16
3	1, 3, 4	69,81
4	1, 2, 4, 5	74,08
5	1, 2, 3, 4, 5	77,96

Tabla 5.22. Mejor combinación para cada tamaño de conjunto: costos ponderados Set 4 experimento APM Gap. En rojo las métricas que no son mejores que el caso base (109,05).

Tamaño	Combinación	Costo Total Ponderado
1	5	111,65
2	2, 4	108,44
3	1, 3, 4	106,01
4	2, 3, 4, 5	110,51
5	1, 2, 3, 4, 5	109,82

Por primera vez se encuentran combinaciones con costos bastante menores a los de la línea base comparativa, lo que es un muy buen avance. También se observa que entre costos regulares y ponderados, las diferencias de la mejor combinación son los de tamaño uno y cuatro. En ambos casos, el paciente 4 está presente en todas las mejores combinaciones salvo en la de tamaño uno.

### 5.3. Discusión

A lo largo de este capítulo se expusieron distintos experimentos computacionales con los casos de estudio generados en la sección 4.

Los primeros resultados interesantes parten también del experimento más sencillo: poner a prueba tres reglas básicas de asignación, las que fueron asumir un tiempo esperados de atención (*i.e.* RVE), muy pesimista (*i.e.* RLS) y muy optimista (*i.e.*: RLI) para todos los pacientes por igual. Esto se corrió para cada uno de los *sets* de estudio ya definidos, y se analizó tanto a nivel individual por cada métrica como a nivel agregado considerando costos totales y costos totales ponderados. En este experimento la principal conclusión fue que, de acuerdo a las métricas propuestas, la regla de Valor Esperado es la que menores costos presenta, tanto totales como ponderados. Así, por simple que suene, pareciera no ser tan malo considerar que todo paciente demorará su valor esperado de *slots* de atención según su tipo de cáncer.

A partir de este primer resultado, se buscó generar otras técnicas mediante las cuales poder obtener aún mejores resultados que la regla básica de asignar a todos con su tiempo esperado de tratamiento. Con lo anterior se llegó al segundo experimento, que consistió en modificar la función objetivo del modelo de optimización. Como recordatorio, el modelo original de Turkcan et al. (2012) tiene como objetivo minimizar el *makespan* total del sistema. A este término se le añadieron distintas componentes asociadas a penalizar a ciertos grupos de pacientes (con altos o bajos requerimientos en tiempo de atención) para ciertos periodos del día. En otras palabras, se procedió a penalizar la asignación de un conjunto de pacientes para algunos *slots* del día. Bajo este experimento que contó con otras cuatro configuraciones de función objetivo, el principal resultado fue que los mejores resultados (y de pasada levemente mejores que la RVE para un caso representativo de estudio) los consiguió la función Alto-PM (APM). Esta consiste en penalizar a los grupos de pacientes con mayores requerimientos (*i.e.*: cáncer tipo 1, 2 y 3) frente a iniciar su tratamiento durante los *slots* de más tarde en el día.

Con el hallazgo extraído del experimento anterior, se propusieron dos nuevos experimentos, ambos basados en el hecho de que en la práctica intentar tomar resguardos o ser más conservador con una gran cantidad de pacientes resultará muy costoso, por lo que es importante poder priorizar solamente a los que más nos interesen. Así, el primer

experimento consistió en probar para todas las combinaciones de pacientes de mayores requerimientos el prohibirles su asignación durante los *slots* de la tarde. Por otra parte, el segundo experimento consistió en que, a las mismas combinaciones de conjuntos de pacientes se les asignara con un cierto *gap* de dos *slots* por sobre su valor esperado de atención. Cabe destacar de que en cuanto a los resultados de ambos experimentos, ninguno fue capaz de lograr mejoras para el Set 4 en costos totales no ponderados, que resultó ser el más difícil de mejorar. Aún así, los principales hallazgos del experimento de prohibición fueron que los conjuntos de tamaño intermedio parecieran presentar mejores rendimientos que los muy pequeños o muy grandes, al menos dentro de los pacientes con altos requerimientos. Para el caso del experimento de *gaps*, esto también resultó cierto. Además, se observó que se encontraban menores costos y por ende mejores asignaciones cuando se consideraban conjuntos de pacientes con los más altos requerimientos (*i.e.*: cáncer 1 o máximo 2), a diferencia de lo que se encontró en el experimento de prohibiciones, en que los de requerimientos intermedios (*i.e.*: cáncer 2) parecieran obtener mejores resultados.

Con lo anterior, se planteaba la duda de cuáles serán los mejores conjuntos a tratar, y con qué técnica. Así, finalmente y dado que los resultados de los experimentos anteriores daban luces de que podrían encontrarse mejoras, se procedió a realizar una mezcla de dos de los experimentos que mejor rendimiento presentaron: función objetivo APM y *gaps* de dos *slots* para conjuntos de pacientes de alto requerimiento. Con esta técnica sí fue posible lograr mejoras tanto para el Set 1 como para el Set 4 en los costos totales no ponderados. En este sentido, los principales hallazgos de este experimento fueron validar los tamaños de conjuntos a tratar de forma especial, ampliándolo eso sí también no solo a los tamaños intermedios sino que también a los un poco más bajos. Por otra parte, también se condice con los resultados del experimento de *gaps* en cuanto a la composición de dichos conjuntos con los pacientes de mayores requerimientos de todos.

De todo el análisis y resultados anteriores, cabe destacar lo siguiente. Primero, el aporte metodológico realizado, comenzando a partir de una regla básica de decisión e incrementando su eficiencia, sin perder de vista el hecho de querer mantener su simplicidad

para efectos de contar con la facilidad para una potencial implementación práctica. Así, por un lado se logra validar que la solución de asignar mediante tiempos esperados a los pacientes resulta incluso mejor que algunas otras técnicas ya sea más optimistas o pesimistas, mientras que por otro lado se encuentran hallazgos sobre a quiénes se debiera dar un trato diferencial a la hora de hacer asignaciones. Con esto, los resultados arrojan que a los pacientes con altos requerimientos se debiera tener cuidado con su asignación durante las tardes. Además, resulta positivo considerar un pequeño *gap* extra en la asignación de *slots* de los pacientes de mayores requerimientos de todos, de manera de anticiparse frente a posibles cambios en sus realizaciones, y es ideal que esto se realice en grupos de no más de cinco personas para un mismo día (considerando centros con atención para alrededor de 40 pacientes diarios).

## **6. CONCLUSIONES Y TRABAJO FUTURO**

En este capítulo se presentan las principales conclusiones de la investigación, las que se encuentran en la sección 6.1, para finalizar en la sección 6.2 con algunas propuestas e ideas de cómo continuar distintas líneas de investigación a partir de lo aquí encontrado.

### **6.1. Conclusiones**

Esta investigación parte con la motivación de poder ayudar en la resolución de un problema de salud a nivel mundial: la gran dificultad que presenta el agendamiento de pacientes de quimioterapia. Para su tratamiento se requieren de muchos recursos conjuntos, por lo que la Investigación Operativa puede tomar un rol crucial en apoyar para una mejor toma de decisiones en sus asignaciones. Lo fundamental en este caso no solamente es encontrar un modelo de optimización que pueda realizar el agendamiento, sino que también es muy relevante la capacidad que tenga dicho modelo o metodología para poder ser fácilmente implementable en la práctica.

A lo largo de la investigación, se pudo completar un análisis detallado del problema en sus respectivos casos de estudio. Se comenzó con una reformulación del modelo original de Turkcan et al. (2012) para un manejo más directo y simple de las variables de tiempos de atención. Con esto, se propuso una metodología de análisis de las reglas de decisión más clásicas, la que partió con un estudio de factibilidad para poder definir de forma precisa los casos de estudio y entender el contexto sobre el cuál el problema se enmarca. Posteriormente, se procedió a realizar, con tres reglas básicas de decisión, los agendamientos de los respectivos pacientes asociados a cada caso de estudio, para finalmente simular su comportamiento teórico en un contexto realista.

Con los resultados computacionales se procedió a realizar un análisis acabado de cada regla, tanto por separado como en comparativa. Los principales resultados de este primer acercamiento fueron que, tanto considerando costos ponderados como costos regulares, la

Regla de Valor Esperado (RVE), o agendar a los pacientes con sus tiempos esperados de atención, resultaba en mejores agendamientos.

Luego de aquello, se buscaron formas de mejorar los agendamientos internamente para obtener menores costos totales en los casos de estudio. Así, la primera técnica evaluada fue la de modificar la función objetivo del problema, con tal de permitir penalizar factores como la hora de inicio de algunos pacientes. Con esto se propusieron cuatro distintas funciones objetivos, dentro de las cuales la que más destacó fue la Alto-PM o APM, que consiste en penalizar la asignación de los pacientes con tiempos de atención esperados más altos durante los *slots* de más tarde en el día.

Con esto en mente, se procedió a ahondar aún más en una segunda técnica, la que consistió en prohibir a distintas combinaciones de los pacientes de mayores requerimientos el inicio de sus horas para la tarde. Lo principal que de aquí se extrae fue que sus mejores resultados iban de la mano con prohibir conjuntos de algunos pocos pacientes de requerimiento intermedio (dentro de los que tienen altos requerimientos ya). También resalta el hecho de que las mejores combinaciones tenían tamaños intermedios: ni extremos en conjuntos tan pequeños, ni tan grandes en conjuntos de la mayoría de los pacientes de alto requerimiento. Es decir, una gran parte de los mejores resultados se presentaba en conjuntos de tamaño tres (de un total máximo de seis).

Luego, se procedió a evaluar el comportamiento de los agendamientos en presencia de mayores *gaps* de atención solo para algunas combinaciones de pacientes. En otras palabras, a dichos pacientes seleccionados a partir del grupo de los con mayores tiempos de atención, se les agendó no por su tiempo esperado, sino que por su tiempo esperado más dos *slots* extra por precaución. Los resultados de esta técnica fueron que los mejores resultados se encontraron en pacientes de los más altos requerimientos, a diferencia de lo que proponía la técnica anterior. Además, se mantenía el hecho de que las combinaciones de tamaños intermedios tendían a ser la mayoría dentro de los mejores resultados de cada *set*.

Por último, y en vista de los leves avances de cada técnica evaluada de forma independiente, se procedió a revisar el comportamiento de la mezcla de dos de ellas: agendar mediante la función objetivo APM, pero también otorgando a alguna combinación de pacientes del mismo grupo de altos requerimientos un *gap* extra de dos *slots*. Esta fue sin duda la técnica con mejores resultados, entre los que destacan el haber logrado disminuir los costos totales no ponderados, por primera vez en los análisis, tanto para el Set 1 como el 4. A partir de esto, también se extrajo el hecho de que pareciera ser mejor inclinarse por los conjuntos de tamaño intermedio y bajo, más que intentar modificar los agendamientos con cinco o más pacientes. Esto se traduce en un hallazgo bastante relevante, que tiene relación con que pareciera mostrarse que no es necesario que tomemos medidas de precaución con los agendamientos de tantos pacientes (lo que sin duda es más costoso para los centros de atención), sino que puede que baste con tomar a los pocos que sean parte de los grupos de mayores requerimientos y a ellos aplicarles algunas medidas especiales.

Se logró completar los objetivos propuestos inicialmente, pudiendo levantar información relevante sobre este problema complejo del agendamiento de pacientes de quimioterapia. A través de los análisis y hallazgos principales, se puede concluir en la relevancia que tiene el poseer reglas de decisión sencillas con pequeñas modificaciones, de forma que sean fácilmente aplicables, pero levemente conservadoras. Esto permitió encontrar mejoras a partir de una regla tan básica como lo es el agendar a cada paciente con su respectivo tiempo esperado de atención (RVE). Por otra parte, la metodología propuesta, desde las métricas utilizadas en las simulaciones hasta el estudio de factibilidad y el diseño de los casos de estudio, también suponen un aporte relevante a la literatura. Esta metodología puede ser extrapolada y utilizada en otros ámbitos en los que se desconozca inicialmente los tamaños de instancias que serían relevantes para analizar, o incluso puede servir para el diseño de requerimientos y recursos.

## 6.2. Trabajo futuro

Una de las primeras propuestas que se tienen es repetir el análisis con mayor flexibilidad de los datos, por ejemplo tomando en cuenta la distinta variabilidad que pueden tener los diferentes tipos de cáncer. Así, cada cáncer podría tener porcentajes o (*bounds*) diferentes en sus tiempos de atención, o se podría tener datos más adaptables y flexibles según se necesite.

Además, se expone la necesidad de incrementar este mismo análisis, tanto en casos de estudio de otros centros y/o países, como enriquecerlo con un análisis de sensibilidad de sus distintos parámetros externos, como los que hacen relación con los recursos del centro de atención, los ponderadores de costos, entre otros.

Siempre resulta relevante desafiar algunos de los supuestos. En particular, se propone como a futuro analizar cómo afectarían a los resultados de esta misma metodología el hecho de que se pudiesen reagendar pacientes para otro día, en vez de incurrir en costos extra irregulares.

Por otra parte, a modo de poner a prueba el modelo de optimización aquí formulado, se propone resolver este problema con técnicas de optimización estocástica o robusta de forma directa, tal que puedan aprovechar las ventajas computacionales de la liberación de los parámetros estocásticos de los subíndices.

Finalmente, no se puede dejar de mencionar el gran aporte que significaría también considerar en paralelo la asignación inter-día de pacientes, la que supone sus propios y complejos desafíos, de modo de poder tener contar con todo el *set-up* para implementar los aprendizajes aquí obtenidos en un contexto real. Si bien esto sería un ideal, aún así se puede seguir abordando el problema por separado de manera de lograr resolver el subproblema intra-día de forma independiente, logrando también buenos resultados y hallazgos relevantes.

## REFERENCIAS

- Alvarado, M., y Ntaimo, L. (2018). Chemotherapy appointment scheduling under uncertainty using mean-risk stochastic integer programming. *Health Care Management Science*, 21(1), 87–104. doi: 10.1007/s10729-016-9380-4
- Bastos, L. S., Marchesi, J. F., Hamacher, S., y Fleck, J. L. (2019). A mixed integer programming approach to the patient admission scheduling problem. *European Journal of Operational Research*, 273(3), 831–840. doi: 10.1016/j.ejor.2018.09.003
- Ben Bachouch, R., Guinet, A., y Hajri-Gabouj, S. (2012). An integer linear model for hospital bed planning. *International Journal of Production Economics*, 140(2), 833–843. doi: 10.1016/j.ijpe.2012.07.023
- Carreras-García, D., Delgado-Gómez, D., Baca-García, E., y Artés-Rodríguez, A. (2020). A Probabilistic Patient Scheduling Model with Time Variable Slots. *Computational and Mathematical Methods in Medicine*, 2020. doi: 10.1155/2020/9727096
- Castaing, J., Cohn, A., Denton, B. T., y Weizer, A. (2016). A stochastic programming approach to reduce patient wait times and overtime in an outpatient infusion center. *IIE Transactions on Healthcare Systems Engineering*, 6(3), 111–125. doi: 10.1080/19488300.2016.1189468
- Chabot, G., y Fox, M. (2005). The creation of a patient-classification system in an outpatient infusion center setting. *Oncology nursing forum*, 32, 535-8. doi: 10.1188/05.ONF.535-538
- Dobish, R. (2003). Next-day chemotherapy scheduling: A multidisciplinary approach to solving workload issues in a tertiary oncology center. *Journal of Oncology Pharmacy Practice*, 9(1), 37–42. doi: 10.1191/1078155203jp105oa

Fondo de Investigación Mundial de Cáncer. (2021). *Cancer rates by human development index*. Extraído de <https://www.wcrf.org/cancer-trends/cancer-rates-human-development-index/>

Gallivan, S., Utley, M., Treasure, T., y Valencia, O. (2002). Booked inpatient admissions and hospital capacity: mathematical modelling study. *BMJ (Clinical research ed.)*, 324(7332), 280–282. doi: 10.1136/bmj.324.7332.280

Gruber, M., Kane, K., Flack, L., Abbotoy, J., Recchio, J., Williamson, K., Horan, K., y Mccarthy, P. (2003). A "perfect day" work redesign in a chemotherapy and infusion center. *Oncology nursing forum*, 30, 567-8. doi: 10.1188/03.ONF.567-568

Hahn-Goldberg, S., Beck, J. C., Carter, M. W., Trudeau, M., Sousa, P., y Beattie, K. (2014). Solving the chemotherapy outpatient scheduling problem with constraint programming. *Journal of Applied Operational Research*, 6(3), 135–144.

Heshmat, M., y Eltawil, A. (2016). Solution methods for the planning and scheduling problems of outpatient chemotherapy units. *IEEE International Conference on Industrial Engineering and Engineering Management, 2016-Janua*, 1318–1322. doi: 10.1109/IEEM.2015.7385861

Heshmat, M., y Eltawil, A. (2018). A new sequential approach for chemotherapy treatment and facility operations planning. *Operations Research for Health Care*, 18, 33–40. doi: 10.1016/j.orhc.2017.06.002

Heshmat, M., Nakata, K., y Eltawil, A. (2017). Modified formulation for the appointment scheduling problem of outpatient chemotherapy departments. *2017 4th International Conference on Industrial Engineering and Applications, ICIEA 2017*, 192–196. doi: 10.1109/IEA.2017.7939205

Issabakhsh, M., Lee, S., y Kang, H. (2020). Scheduling patient appointment in an infusion center: a mixed integer robust optimization approach. *Health Care Management Science*.

doi: 10.1007/s10729-020-09519-z

Kong, Q., Li, S., Liu, N., Teo, C.-p., y Yan, Z. (2020). Appointment Scheduling Under Time-Dependent Patient Appointment Scheduling Under Time-Dependent Patient. *Management Science*, 66(8), 3480–3500.

Lara, B. A., Cataldo, A., Castro, R., Aguilera, P. R., Ruiz, C., y Andresen, M. (2016). Medicina de urgencia y unidades de cuidados intensivos: Una alianza necesaria en busca de la mejoría de la atención de pacientes críticos TT - The impact of a better coordination between emergency and intensive care units in the care of critically ill pa. *Revista médica de Chile*, 144(7), 911–917.

Lv, M., Li, Y., Kou, B., y Zhou, Z. (2017). Integer programming for improving radiotherapy treatment efficiency. *PLoS ONE*, 12(7), 1–9. doi: 10.1371/journal.pone.0180564

Maister, D. H. (1985). The psychology of waiting lines. *The Service Encounter: Managing Employee/Customer Interaction in Service Businesses*, 113-123.

Majidi, F., Enterline, J. P., Ashley, B., Fowler, M. E., Ogorzalek, L. L., Gaudette, R., Stuart, G. J., Fulton, M., y Ettinger, D. S. (1993). Chemotherapy and treatment scheduling: the Johns Hopkins Oncology Center Outpatient Department. *Symposium on Computer Application in Medical Care*, 154–158.

Marquinez, J. T., Sauré, A., Cataldo, A., y Ferrer, J. C. (2019). Identifying dynamic ICU patient admission, transfer and diversion policies in a public-private hospital network.

Ministerio de Salud Chile. (2018). *Plan nacional del cáncer 2018-2028*.

National Library of Medicine. (2019). *Cancer treatments*. Extraído de <https://medlineplus.gov/ency/patientinstructions/000901.htm>

Organización Mundial de la Salud. (2017). *World's health ministers renew commitment to cancer prevention and control*. Extraído de <https://www.who.int/cancer/>

media/news/cancer-prevention-resolution/en/

Pan, X., Geng, N., y Xie, X. (2019). A Benders Decomposition Approach for Appointment Scheduling of Unpunctual Patients in a Multi-Server Setting. *IEEE International Conference on Industrial Engineering and Engineering Management*, 64–68. doi: 10.1109/IEEM44572.2019.8978696

Pan, X., Geng, N., y Xie, X. (2020). A stochastic approximation approach for managing appointments in the presence of unpunctual patients, multiple servers and no-shows. *International Journal of Production Research*, 0(0), 1–21. doi: 10.1080/00207543.2020.1744766

Podgorelec, V., y Kokol, P. (1997). Genetic algorithm based system for patient scheduling in highly constrained situations. *Journal of Medical Systems*, 21(6), 417–427. doi: 10.1023/A:1022828414460

Ramos, C., Cataldo, A., y Ferrer, J. C. (2020). Appointment and patient scheduling in chemotherapy: a case study in Chilean hospitals. *Annals of Operations Research*, 286(1-2), 411–439. doi: 10.1007/s10479-018-3085-7

Riff, M. C., Cares, J. P., y Neveu, B. (2016). RASON: A new approach to the scheduling radiotherapy problem that considers the current waiting times. *Expert Systems with Applications*, 64, 287–295. doi: 10.1016/j.eswa.2016.07.045

Sadki, A., Xie, X., y Chauvin, F. (2011). Appointment scheduling of oncology outpatients. *IEEE International Conference on Automation Science and Engineering*, 513–518. doi: 10.1109/CASE.2011.6042417

Santibanez, P., Aristizabal, R., Puterman, M., Chow, V., Huang, W., Kollmannsberger, C., Nordin, T., Runzer, N., y Tyldesley, S. (2012). Operations research methods improve chemotherapy patient appointment scheduling. *Joint Commission Journal on Quality and Patient Safety*, 38(12), 541–553. doi: 10.1016/s1553-7250(12)38071-9

- Sauré, A., Begen, M. A., y Patrick, J. (2020). Dynamic multi-priority, multi-class patient scheduling with stochastic service times. *European Journal of Operational Research*, 280(1), 254–265. doi: 10.1016/j.ejor.2019.06.040
- Sevinc, S., Sanli, U. A., y Goker, E. (2013). Algorithms for scheduling of chemotherapy plans. *Computers in Biology and Medicine*, 43(12), 2103–2109. doi: 10.1016/j.combiomed.2013.10.012
- Shehadeh, K. S., Cohn, A. E., y Jiang, R. (2020). Using stochastic programming to solve an outpatient appointment scheduling problem with random service and arrival times. *Naval Research Logistics*(November 2019), 1–23. doi: 10.1002/nav.21933
- Shuang, M., Songlin, C., y Xiaotian, C. (2019). A Two-stage Stochastic Programming Model for Outpatient Appointment Scheduling. *IEEE International Conference on Industrial Engineering and Engineering Management*, 79–83. doi: 10.1109/IEEM44572.2019.8978589
- Sufan, S., Cataldo, A., Lorca, , Andresen, M., Sánchez, C., y Sauré, A. (2022). Multi-stage process for chemotherapy scheduling and effective capacity determination. *International Transactions in Operational Research*, n/a(n/a).
- Tsai, P. F. J., y Teng, G. Y. (2014). A stochastic appointment scheduling system on multiple resources with dynamic call-in sequence and patient no-shows for an outpatient clinic. *European Journal of Operational Research*, 239(2), 427–436. doi: 10.1016/j.ejor.2014.04.032
- Turkcan, A., Zeng, B., y Lawley, M. (2012). Chemotherapy operations planning and scheduling. *IIE Transactions on Healthcare Systems Engineering*, 2(1), 31–49. doi: 10.1080/19488300.2012.665155
- Wiers, V. C. (1997). A review of the applicability of OR and AI scheduling techniques in practice. *Omega*, 25(2), 145–153. doi: 10.1016/S0305-0483(96)00050-3

**ANEXOS**

## A. VISUALIZACIÓN DE AGENDAMIENTOS POR REGLA Y SET

En este anexo se presentan las visualizaciones de los agendamientos asociados a cada *set* de estudio, con cada una de las reglas básicas Regla Valor Esperado (RVE), Regla Límite Inferior (RLI) y Regla Límite Superior (RLS), siempre que haya presentado resultados factibles.

### A.1. Set 1

La figura A.1 presenta el agendamiento para el Set 1 mediante la regla de asignación de tiempos esperados de atención.

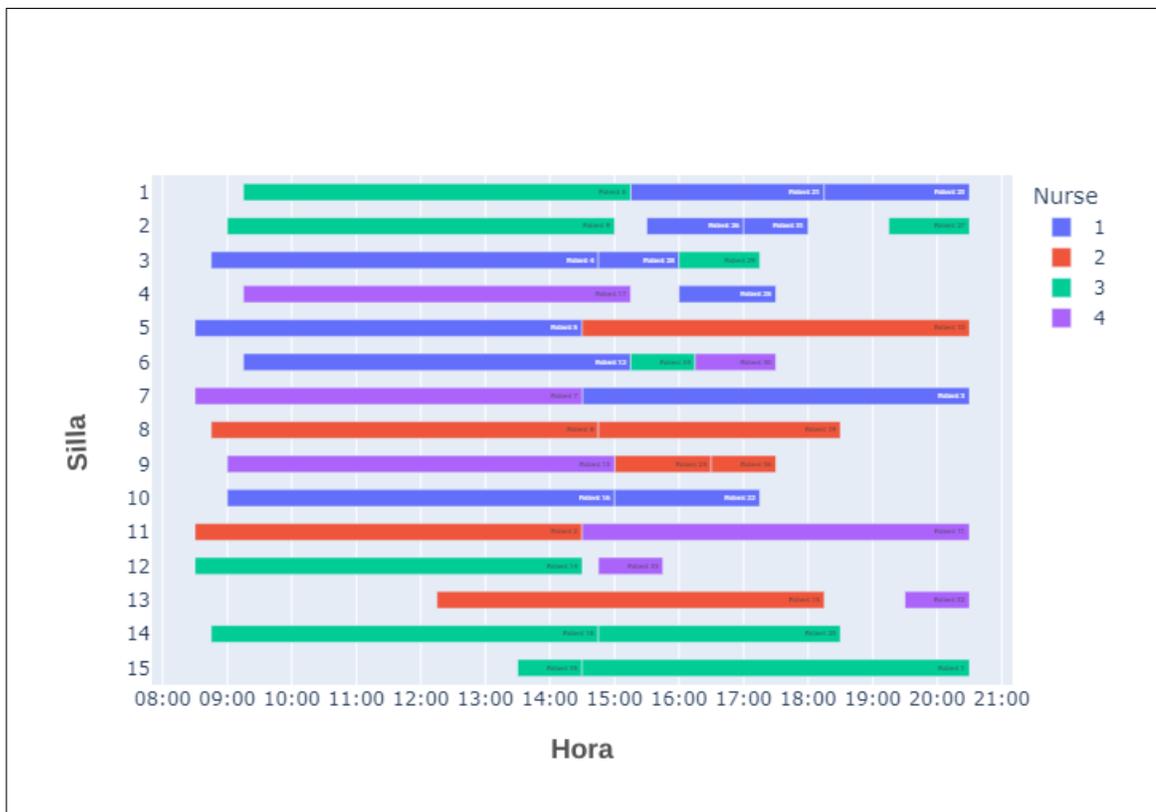


Figura A.1. Agendamiento Set 1 con regla Regla Valor Esperado (RVE).

La figura A.2 presenta el agendamiento para el Set 1 mediante la regla de asignación optimista de los menores tiempos posibles de atención.

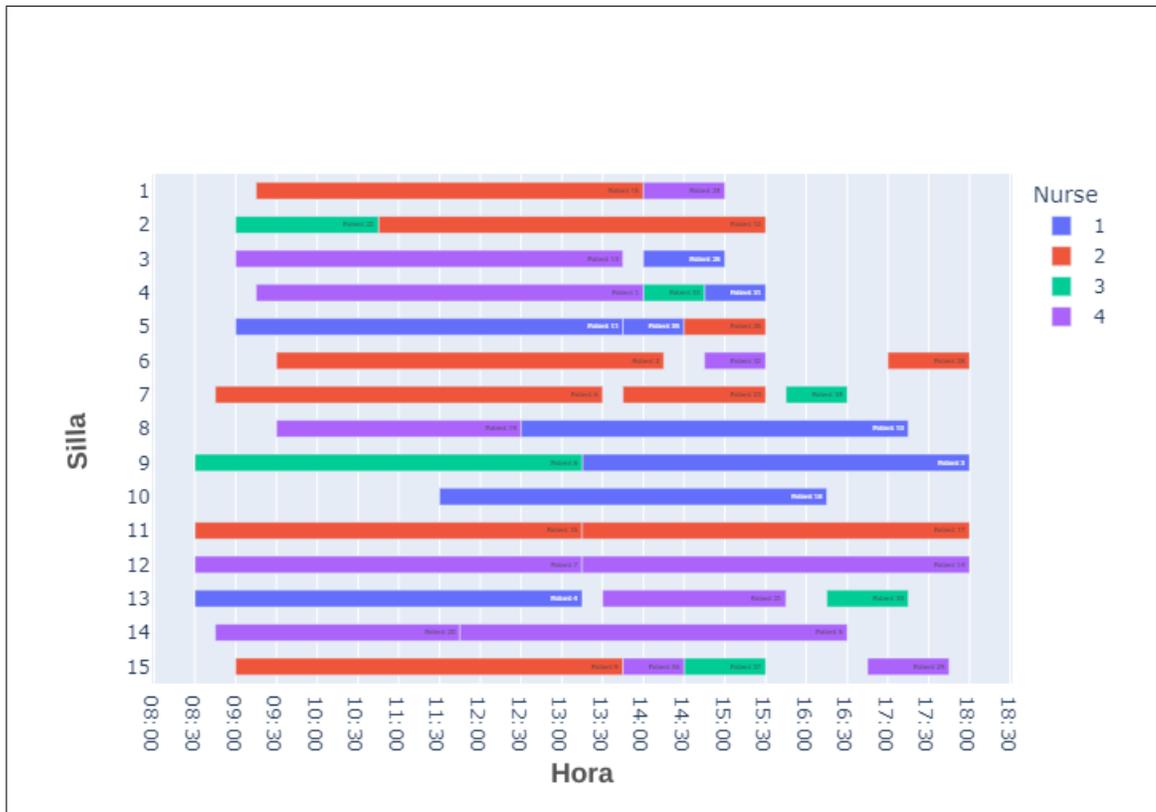


Figura A.2. Agendamiento Set 1 con Regla Límite Inferior.

## A.2. Set 2

La figura A.3 presenta el agendamiento para el Set 2 mediante la regla de asignación de tiempos esperados de atención.

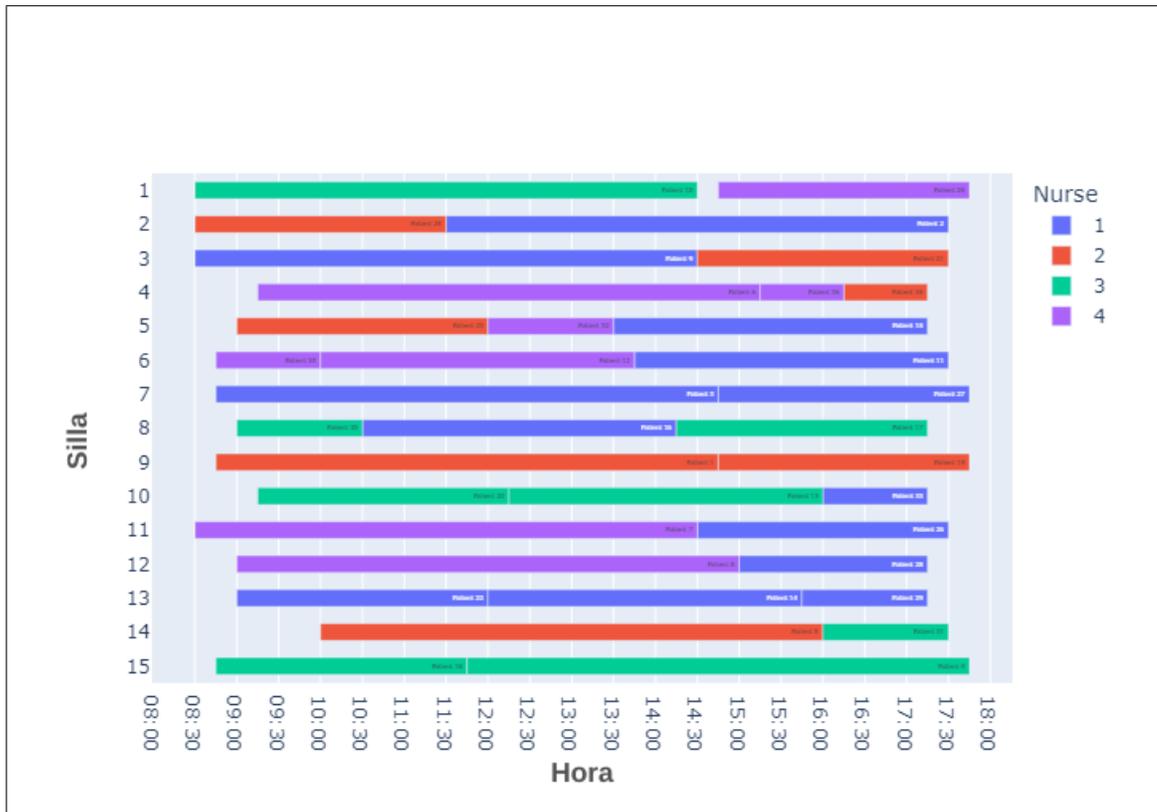


Figura A.3. Agendamiento Set 2 con Regla Valor Esperado.

La figura A.4 presenta el agendamiento para el Set 2 mediante la regla de asignación de optimista de los menores tiempos posibles de atención.

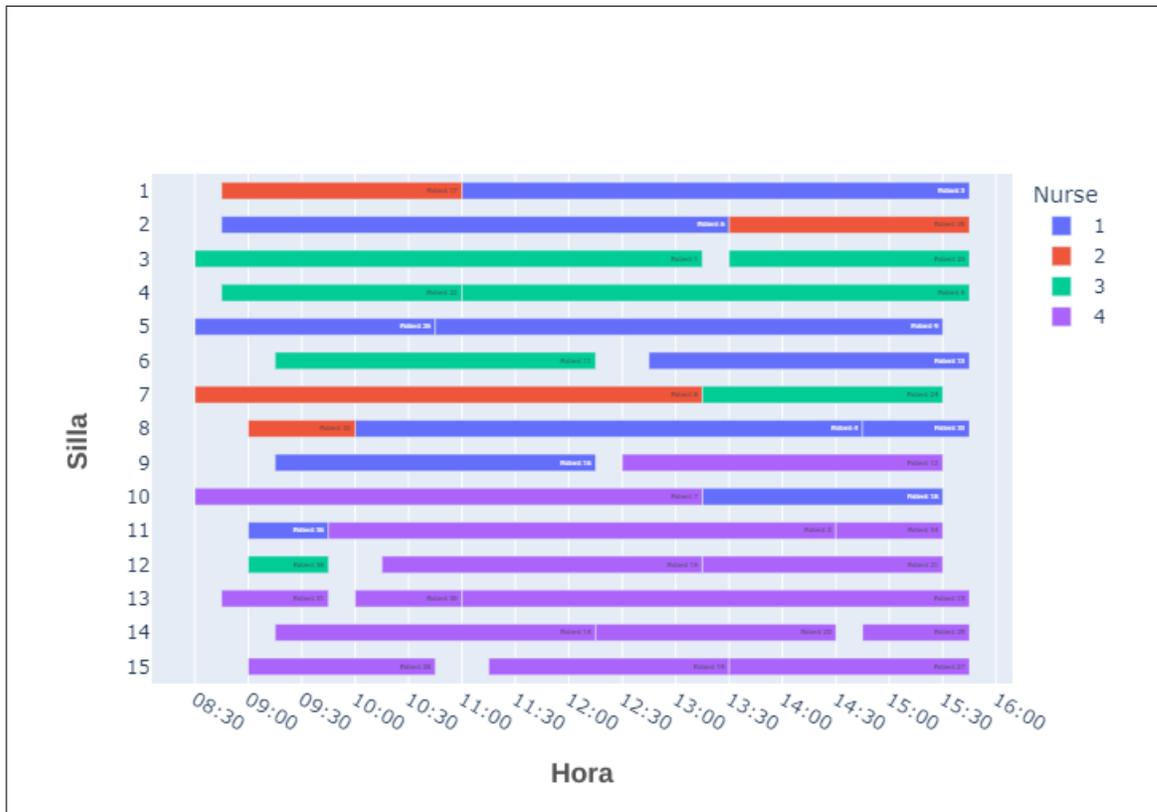


Figura A.4. Agendamiento Set 2 con Regla Límite Inferior.

La figura A.5 presenta el agendamiento para el Set 2 mediante la regla de asignación pesimista de los mayores tiempos posibles de atención.

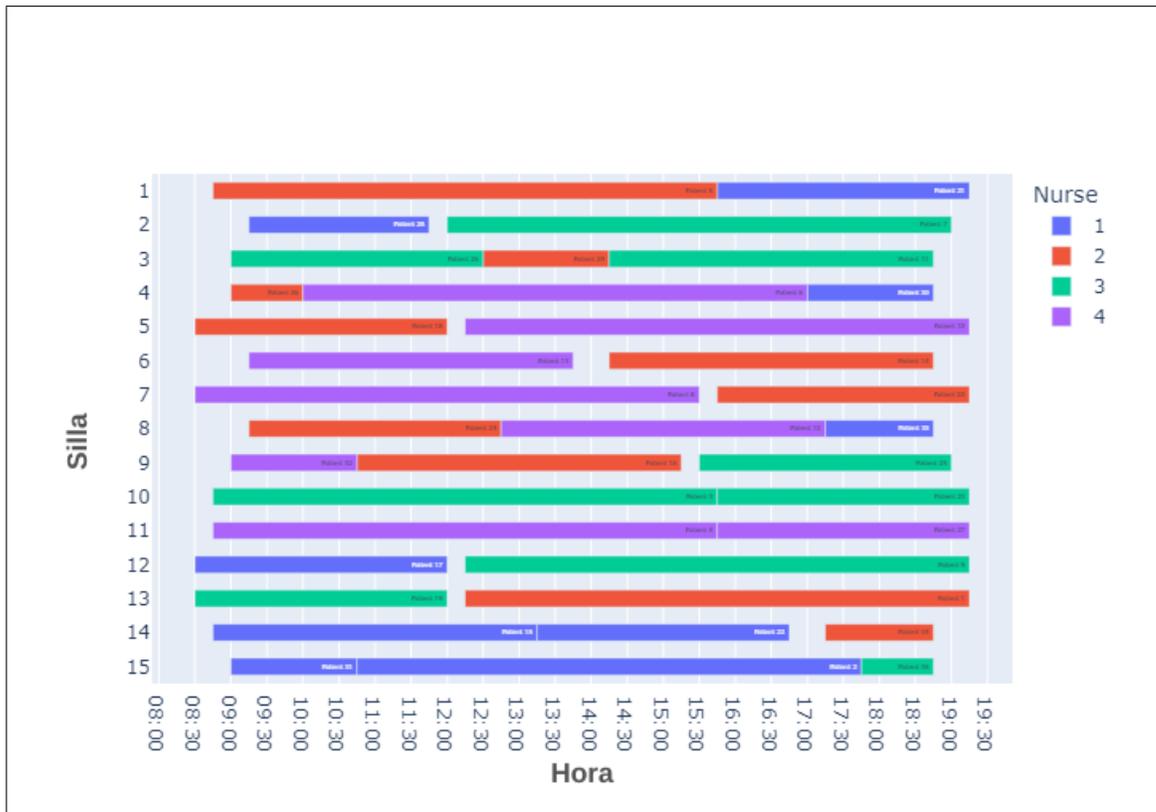


Figura A.5. Agendamiento Set 2 con Regla Límite Superior.

### A.3. Set 3

La figura A.6 presenta el agendamiento para el Set 3 mediante la regla de asignación de tiempos esperados de atención.

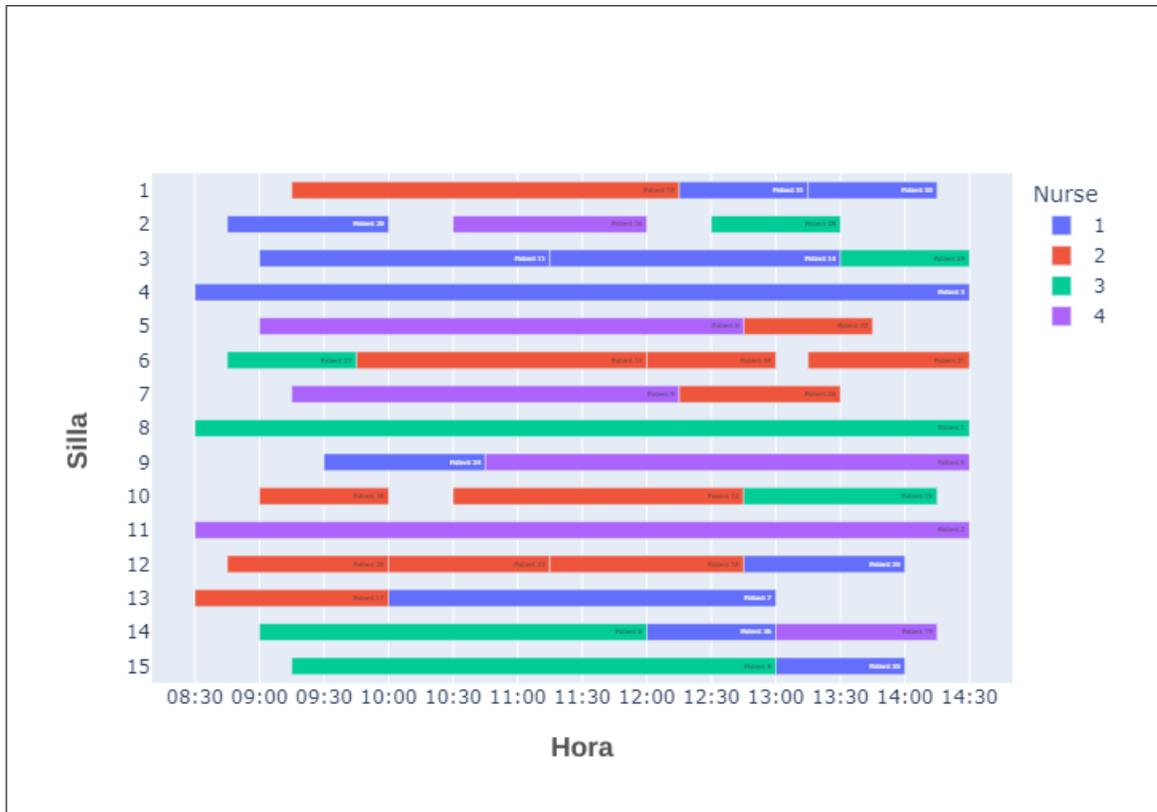


Figura A.6. Agendamiento Set 3 con Regla Valor Esperado.

La figura A.7 presenta el agendamiento para el Set 3 mediante la regla de asignación optimista de los menores tiempos posibles de atención.

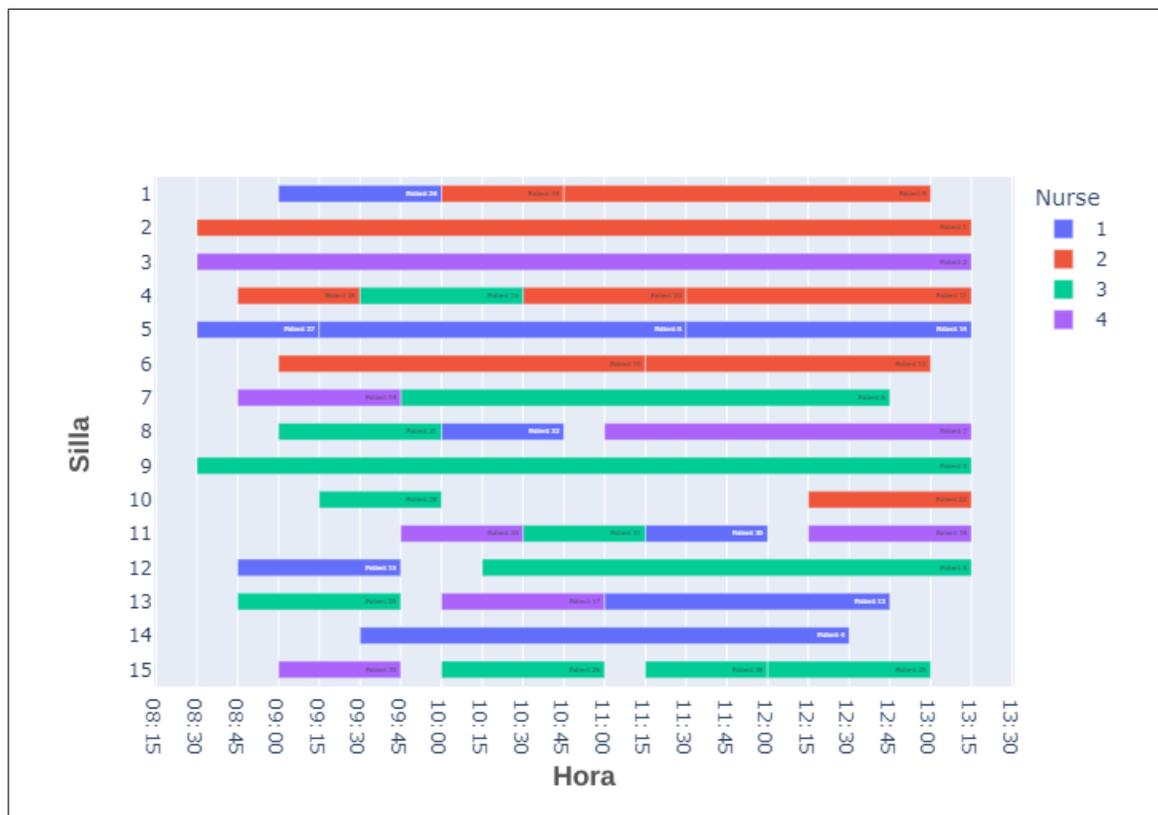


Figura A.7. Agendamiento Set 3 con Regla Límite Inferior.

La figura A.9 presenta el agendamiento para el Set 3 mediante la regla de asignación pesimista de los mayores tiempos posibles de atención.

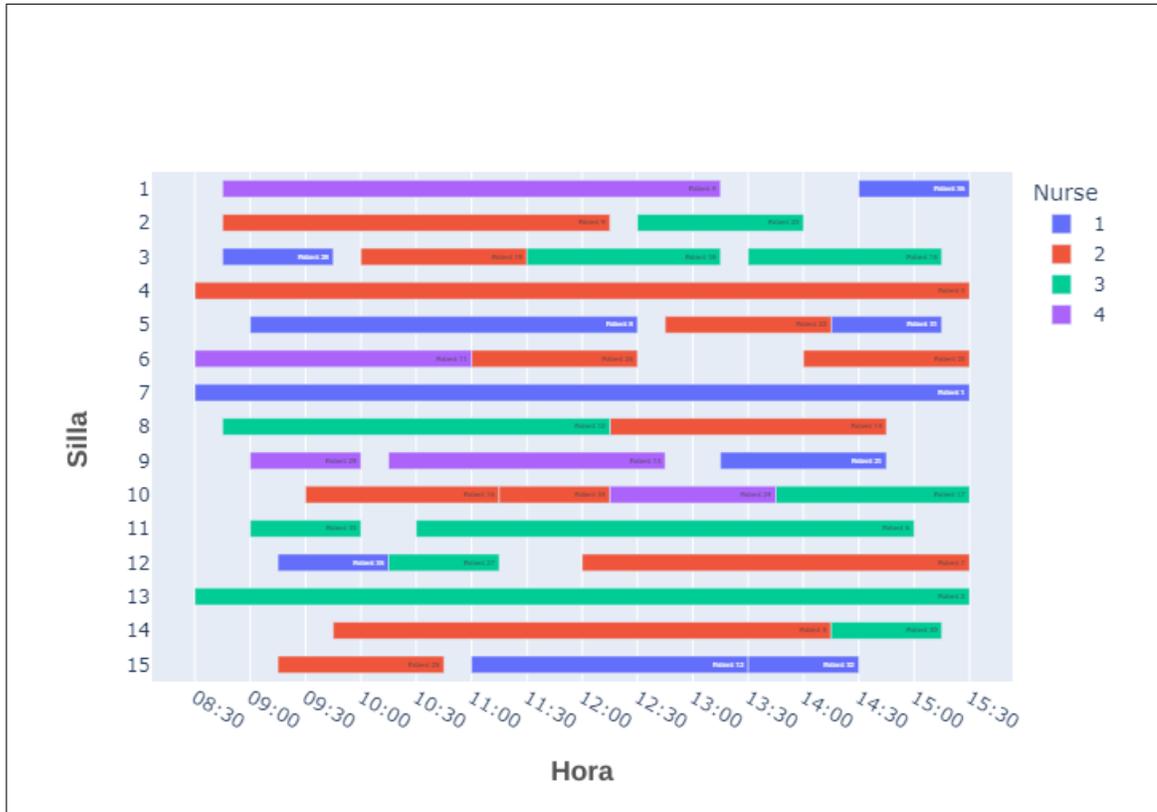


Figura A.8. Agendamiento Set 3 con Regla Límite Superior.

#### A.4. Set 4

La figura A.9 presenta el agendamiento para el Set 4 mediante la regla de asignación de tiempos esperados de atención.

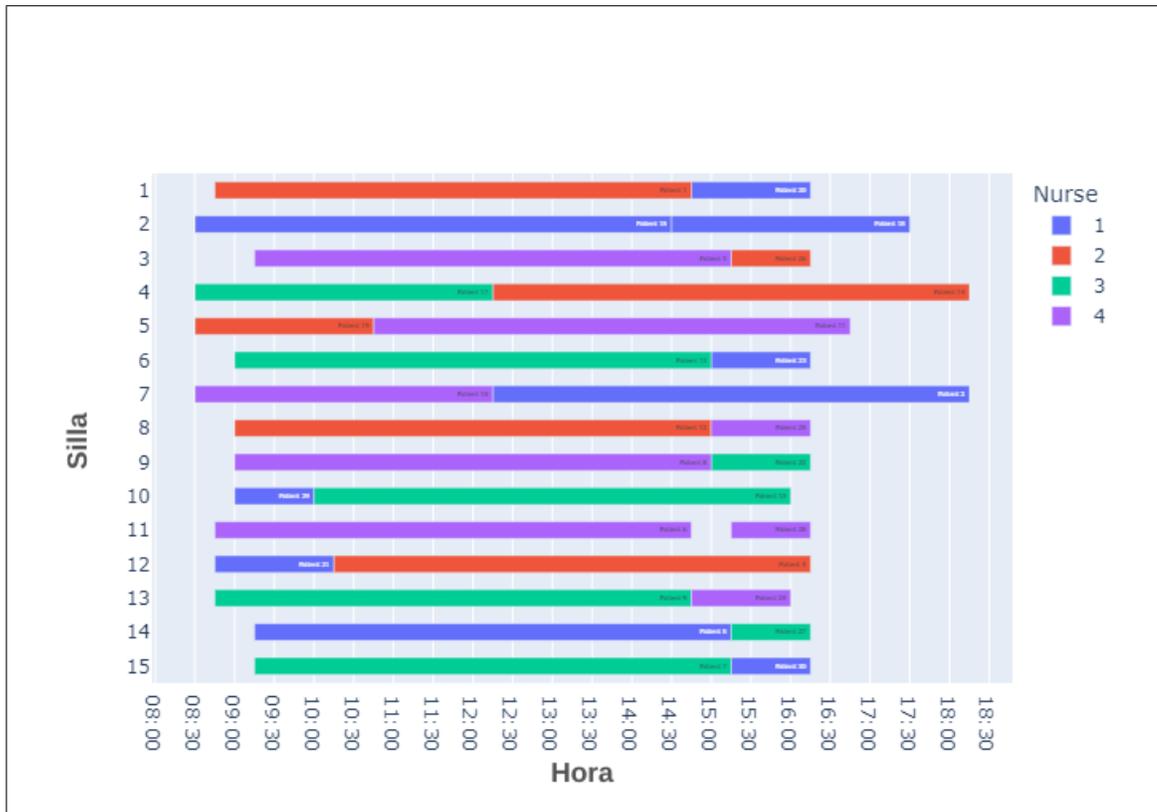


Figura A.9. Agendamiento Set 4 con Regla Valor Esperado.

La figura A.10 presenta el agendamiento para el Set 4 mediante la regla de asignación optimista de los menores tiempos posibles de atención.

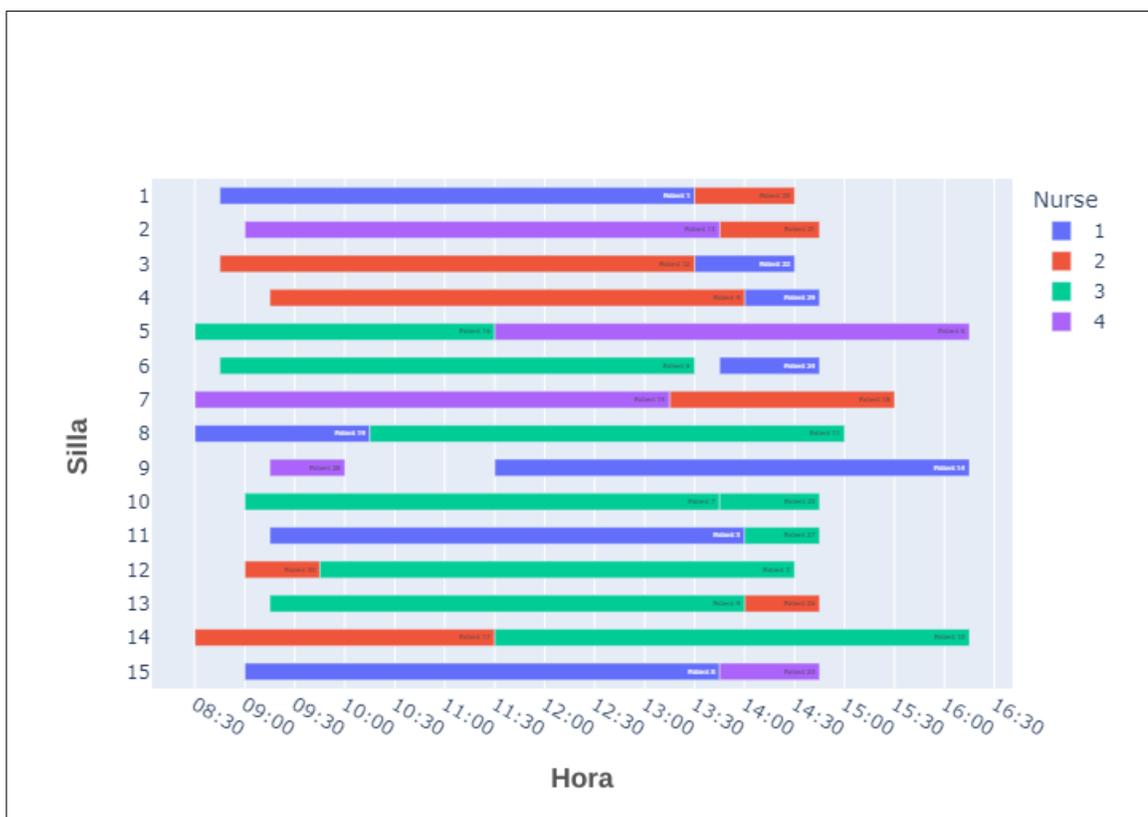


Figura A.10. Agendamiento Set 4 con Regla Límite Inferior.

### A.5. Set 5

La figura A.11 presenta el agendamiento para el Set 5 mediante la regla de asignación de tiempos esperados de atención.

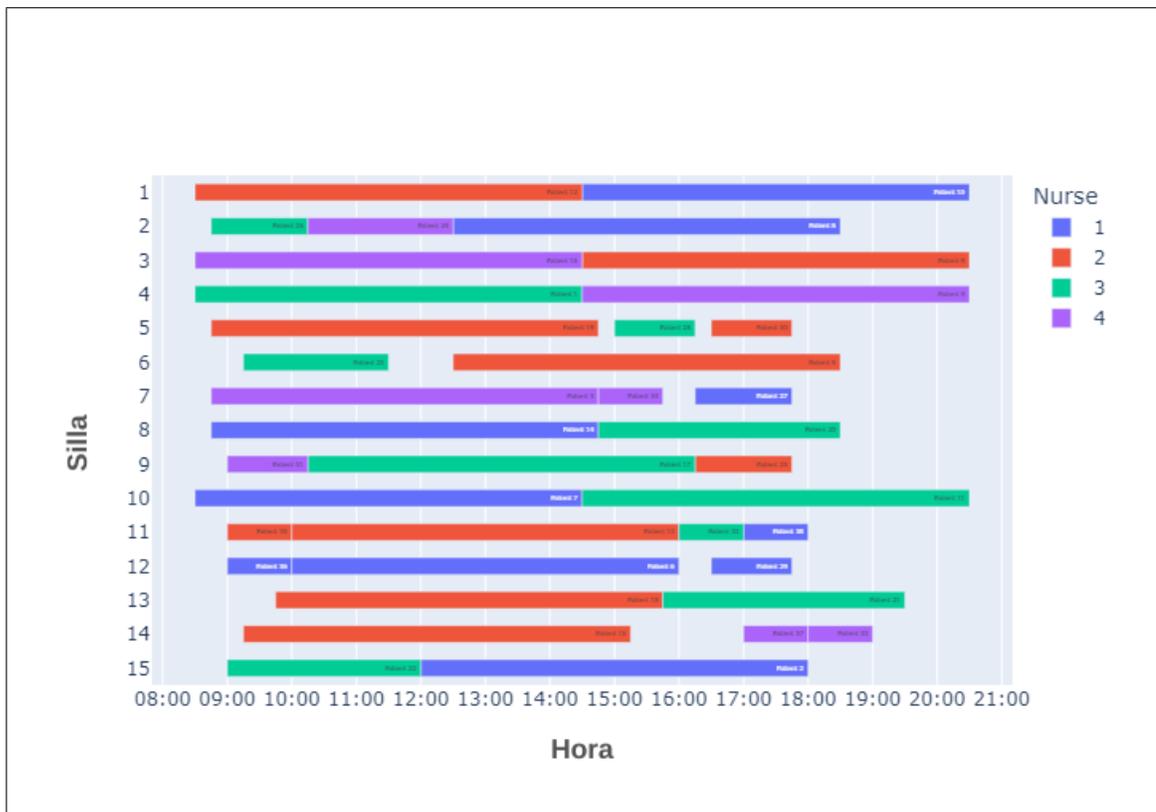


Figura A.11. Agendamiento Set 5 con Regla Valor Esperado.

La figura A.12 presenta el agendamiento para el Set 5 mediante la regla de asignación optimista de los menores tiempos posibles de atención.

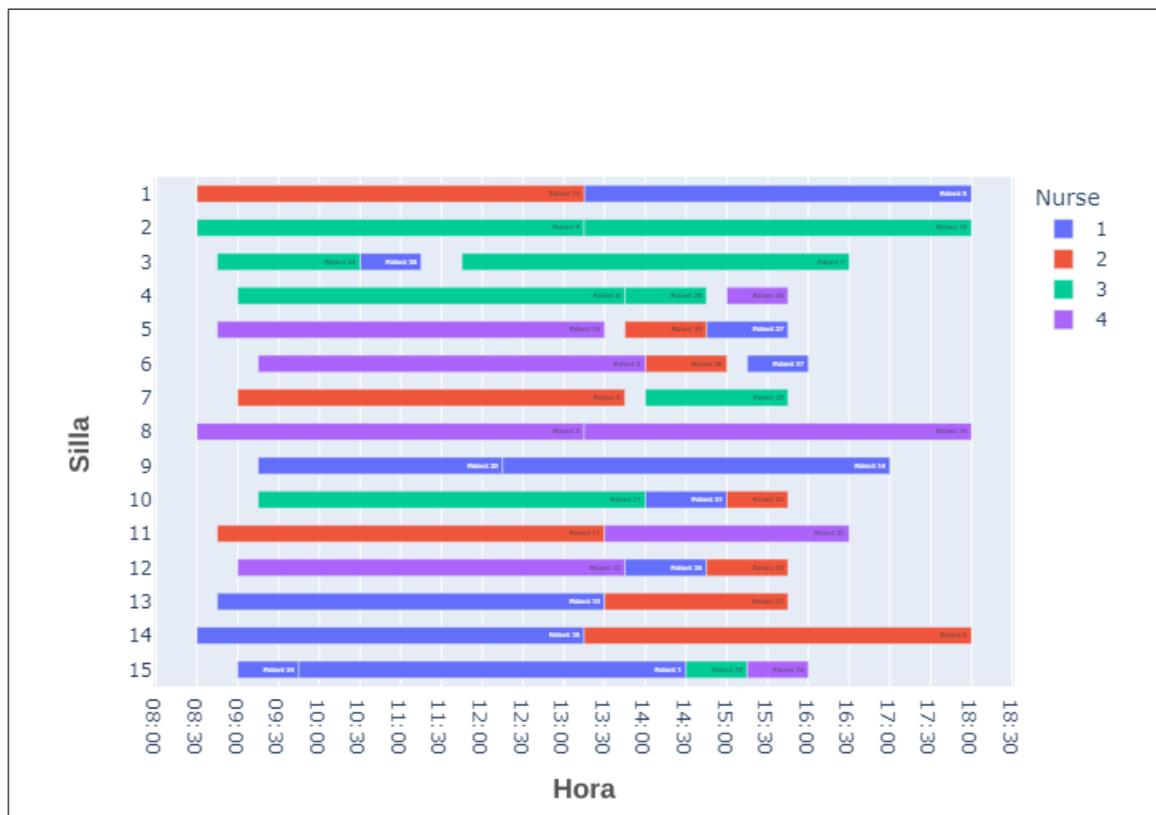


Figura A.12. Agendamiento Set 5 con regla Regla Límite Inferior.

## B. MÉTRICAS DE EXPERIMENTO CON FUNCIONES OBJETIVO

Este anexo presenta los resultados de las 1000 simulaciones a través de sus respectivas métricas para cada uno de los experimentos de modificación de función objetivo. La notación utilizada es la siguiente:

- **Alto-PM (APM)**: a los pacientes de grupos de cáncer de mayores requerimientos (*i.e.*: grupos 1, 2 y 3) se les penaliza por comenzar sus tratamientos en los últimos 30 *slots*.
- **Alto-AM (AAM)**: idéntico al anterior, pero para los inicios de tratamiento que comiencen en los primeros 30 *slots*.
- **Bajo-PM (BPM)**: contrario al primer punto, al resto de los pacientes (*i.e.*: grupos 5 al 7) se les penaliza por comenzar en los *slots* de más tarde.
- **Bajo-AM (BAM)**: mismo concepto, pero en los *slots* de más temprano.
- **Regla Valor Esperado (RVE)**: la regla clásica usada inicialmente, en que todos los pacientes se asignan según su valor esperado de atención.

La tabla B.1 presenta los resultados para el Set 1 con cada función objetivo propuesta.

Tabla B.1. Resultados Set 1 para experimento funciones objetivo. En verde el menor costo por métrica.

Set 1	APM	BPM	AAM	BAM	RVE
<b>Costo Total</b>	<b>95,77</b>	<b>106,23</b>	<b>145,76</b>	<b>195,49</b>	<b>110,91</b>
<b>Costo de Empuje</b>	15,83	14,83	<b>7,62</b>	8,82	14,41
<b>Costo de Inactividad</b>	62,86	<b>53,1</b>	101,13	137,46	64,99
<b>Costo Extra</b>	30,69	<b>27,38</b>	31,52	41,89	29,67
<b>Costo Extra Irregular</b>	2,22	10,92	5,49	7,32	<b>1,84</b>

La tabla B.2 presenta los resultados para el Set 2 con cada función objetivo propuesta.

Tabla B.2. Resultados Set 2 para experimento funciones objetivo. En verde el menor costo por métrica.

Set 2	APM	BPM	AAM	BAM	RVE
<b>Costo Total</b>	<b>132,25</b>	<b>133,58</b>	<b>143,48</b>	<b>140,38</b>	<b>134,4</b>
<b>Costo de Empuje</b>	21,62	14,76	16,4	18,13	22,68
<b>Costo de Inactividad</b>	51,43	59,2	66,27	62,16	50,75
<b>Costo Extra</b>	42,65	41,61	42,11	44,1	47,01
<b>Costo Extra Irregular</b>	16,55	18,01	18,7	15,99	13,96

La tabla B.3 presenta los resultados para el Set 3 con cada función objetivo propuesta.

Tabla B.3. Resultados Set 3 para experimento funciones objetivo. En verde el menor costo por métrica.

Set 3	APM	BPM	AAM	BAM	RVE
<b>Costo Total</b>	<b>73,99</b>	<b>98,76</b>	<b>181,46</b>	<b>242,33</b>	<b>76,45</b>
<b>Costo de Empuje</b>	15,35	7,62	5,68	3,54	12,85
<b>Costo de Inactividad</b>	50,42	64,4	144,68	203,44	53,85
<b>Costo Extra</b>	8,22	24,39	26,6	32,02	9,75
<b>Costo Extra Irregular</b>	0	2,35	4,5	3,33	0

La tabla B.4 presenta los resultados para el Set 4 con cada función objetivo propuesta.

Tabla B.4. Resultados Set 4 para experimento funciones objetivo. En verde el menor costo por métrica.

<b>Set 4</b>	<b>APM</b>	<b>BPM</b>	<b>AAM</b>	<b>BAM</b>	<b>RVE</b>
<b>Costo Total</b>	<b>76,35</b>	<b>84,22</b>	<b>197,65</b>	<b>221,72</b>	<b>70,43</b>
<b>Costo de Empuje</b>	13,15	10,25	10,31	<b>3,37</b>	13,37
<b>Costo de Inactividad</b>	51,08	52,14	142,84	186,06	<b>45,26</b>
<b>Costo Extra</b>	12,08	16,73	36,11	27,49	<b>11,76</b>
<b>Costo Extra Irregular</b>	<b>0,04</b>	5,1	8,39	4,8	<b>0,04</b>

La tabla B.5 presenta los resultados para el Set 5 con cada función objetivo propuesta.

Tabla B.5. Resultados Set 5 para experimento funciones objetivo. En verde el menor costo por métrica.

<b>Set 5</b>	<b>APM</b>	<b>BPM</b>	<b>AAM</b>	<b>BAM</b>	<b>RVE</b>
<b>Costo Total</b>	<b>126,37</b>	<b>106,31</b>	<b>165,4</b>	<b>169,52</b>	<b>126,05</b>
<b>Costo de Empuje</b>	17,2	16,78	<b>12,17</b>	14,4	19,7
<b>Costo de Inactividad</b>	60,41	<b>57</b>	95,38	98,02	57,8
<b>Costo Extra</b>	42,51	<b>30,3</b>	47,07	45,32	43,03
<b>Costo Extra Irregular</b>	6,25	<b>2,23</b>	10,78	11,78	5,52

### C. TABLA DE COMBINACIONES PARA EXPERIMENTOS

En este anexo se presenta la tabla con los índices de cada combinación para los *sets* 1 y 4. Las comas separan cada ID de paciente. La tabla C.2 es la continuación de la C.1.

Tabla C.1. Combinaciones y sus respectivas asociaciones con los ID de los pacientes. Parte 1.

Índice/ID	Set 1	Set 4
0	-	-
1	1	1
2	2	2
3	3	3
4	4	4
5	5	5
6	6	1,2
7	1,2	1,3
8	1,3	1,4
9	1,4	1,5
10	1,5	2,3
11	1,6	2,4
12	2,3	2,5
13	2,4	3,4
14	2,5	3,5
15	2,6	4,5
16	3,4	1,2,3
17	3,5	1,2,4
18	3,6	1,2,5
19	4,5	1,3,4
20	4,6	1,3,5
21	5,6	1,4,5
22	1,2,3	2,3,4
23	1,2,4	2,3,5
24	1,2,5	2,4,5
25	1,2,6	3,4,5
26	1,3,4	1,2,3,4
27	1,3,5	1,2,3,5
28	1,3,6	1,2,4,5
29	1,4,5	1,3,4,5
30	1,4,6	2,3,4,5
31	1,5,6	1,2,3,4,5

Tabla C.2. Combinaciones y sus respectivas asociaciones con los ID de los pacientes. Parte 2.

<b>Índice/ID</b>	<b>Set 1</b>
32	2,3,4
33	2,3,5
34	2,3,6
35	2,4,5
36	2,4,6
37	2,5,6
38	3,4,5
39	3,4,6
40	3,5,6
41	4,5,6
42	1,2,3,4
43	1,2,3,5
44	1,2,3,6
45	1,2,4,5
46	1,2,4,6
47	1,2,5,6
48	1,3,4,5
49	1,3,4,6
50	1,3,5,6
51	1,4,5,6
52	2,3,4,5
53	2,3,4,6
54	2,3,5,6
55	2,4,5,6
56	3,4,5,6
57	1,2,3,4,5
58	1,2,3,4,6
59	1,2,3,5,6
60	1,2,4,5,6
61	1,3,4,5,6
62	2,3,4,5,6
63	1,2,3,4,5,6

## D. MÉTRICAS DE EXPERIMENTO DE PROHIBICIONES

En este anexo se presentan las métricas de resultados promedio de 1000 simulaciones para cada combinación elegida con el experimento de prohibiciones. Este experimento consiste en seleccionar un conjunto de pacientes dentro de los con mayores requerimientos a los que prohibirles una asignación durante la tarde. Para mayor información de a qué hace referencia cada ID de combinación referirse al Anexo C.

### D.1. Set 1

La figura D.1 presenta los costos de empuje para el experimento de prohibiciones para el Set 1.

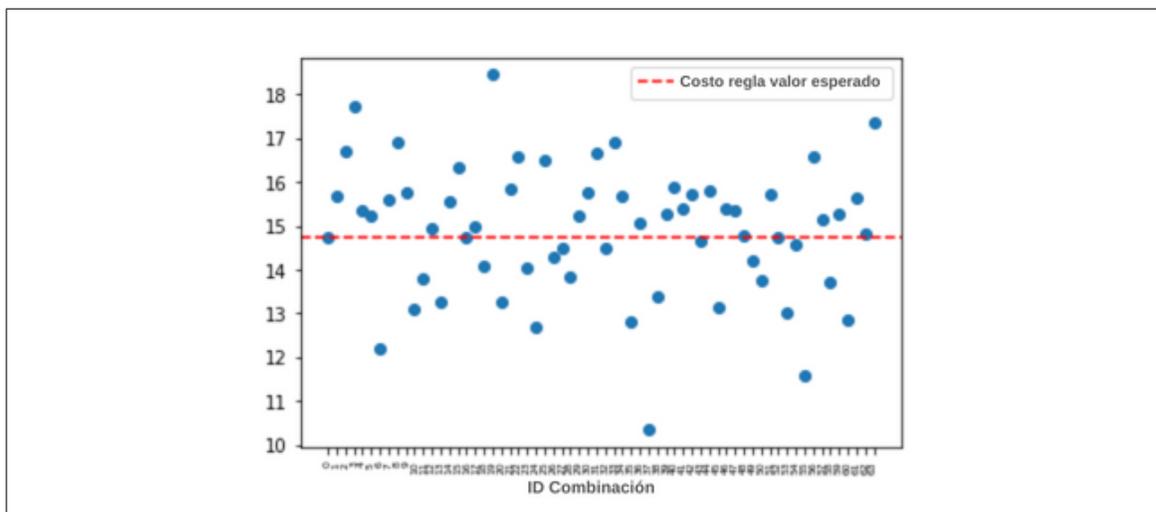


Figura D.1. Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 1.

La figura D.2 presenta los costos de inactividad para el experimento de prohibiciones para el Set 1.

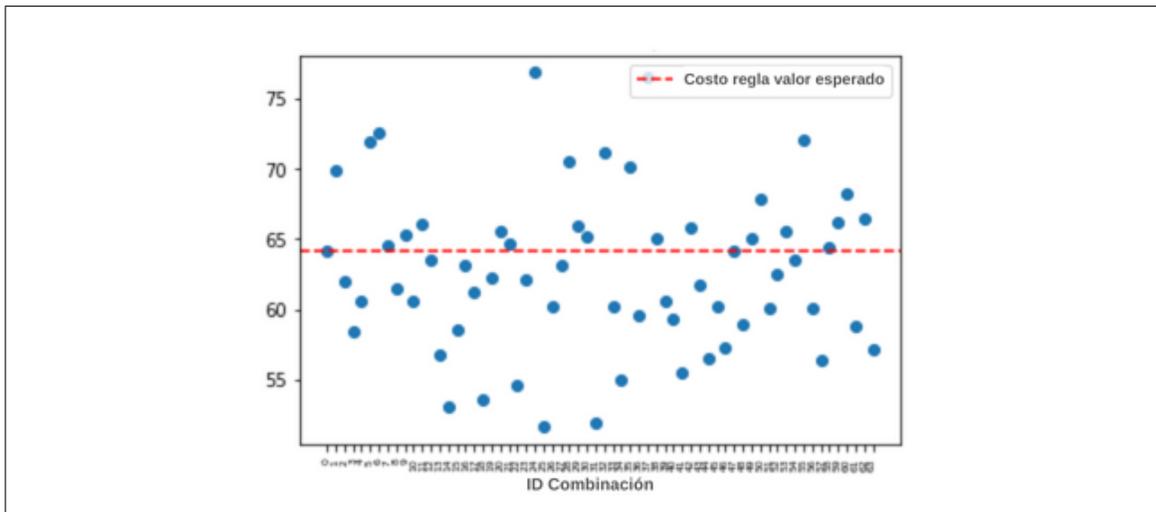


Figura D.2. Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 1.

La figura D.3 presenta los costos extra para el experimento de prohibiciones para el Set 1.

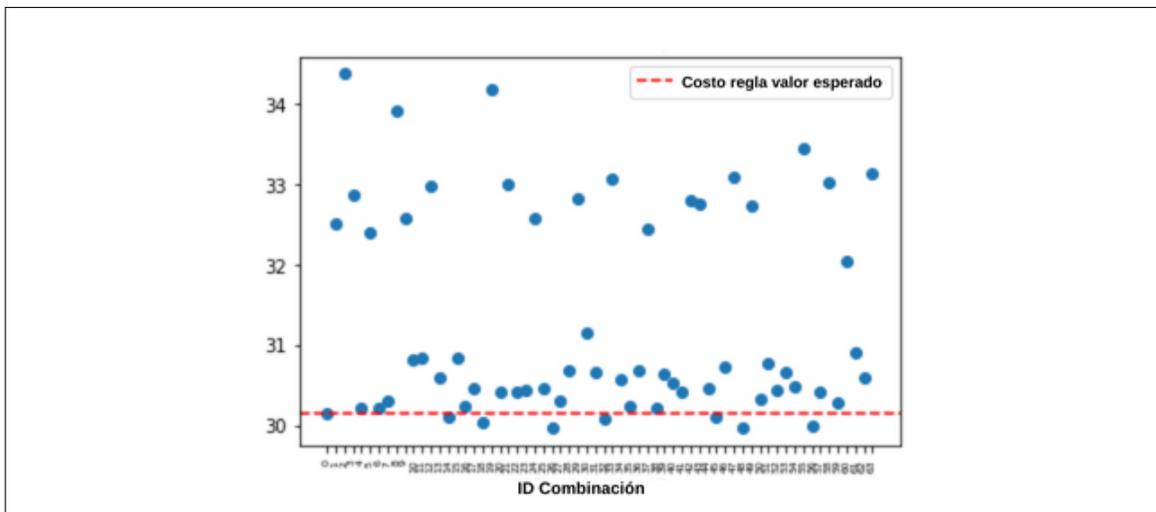


Figura D.3. Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 1.

La figura D.4 presenta los costos extra irregulares para el experimento de prohibiciones para el Set 1.

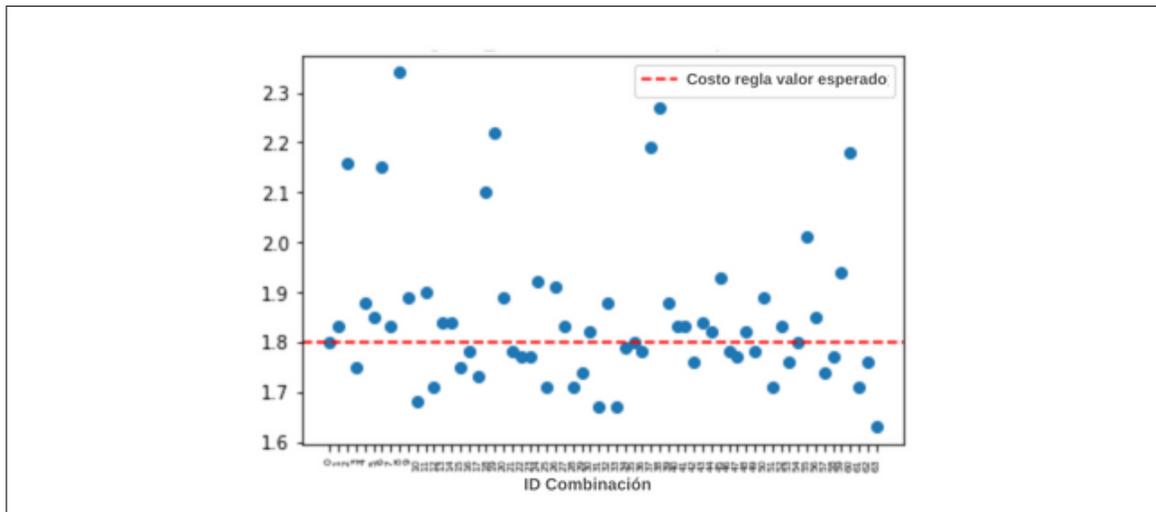


Figura D.4. Costos extra irregulares de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 1.

La figura D.5 presenta los costos totales para el experimento de prohibiciones para el Set 1.

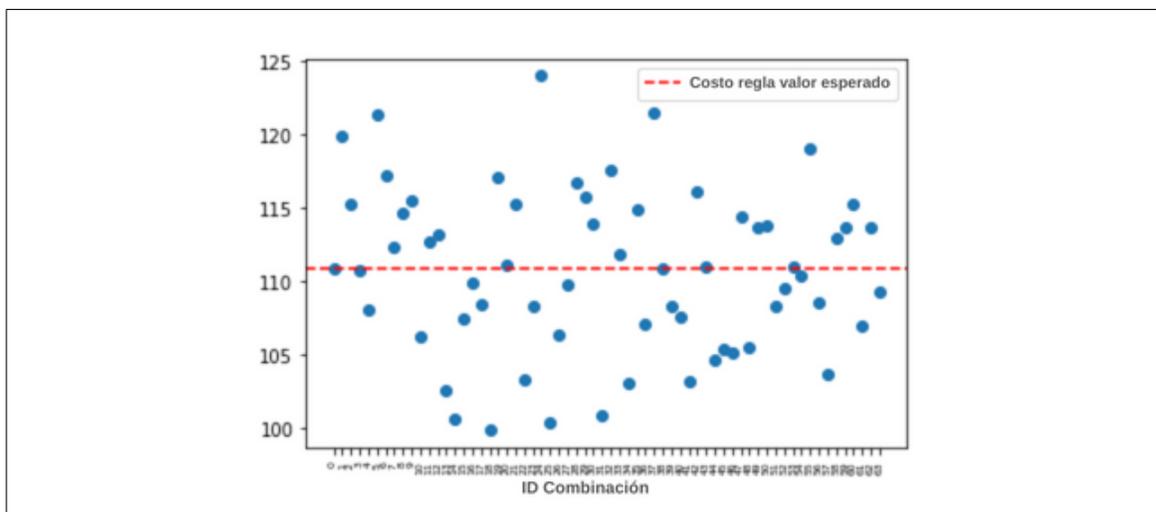


Figura D.5. Costos totales de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 1.

La figura D.6 presenta los costos totales ponderados para el experimento de prohibiciones para el Set 1.

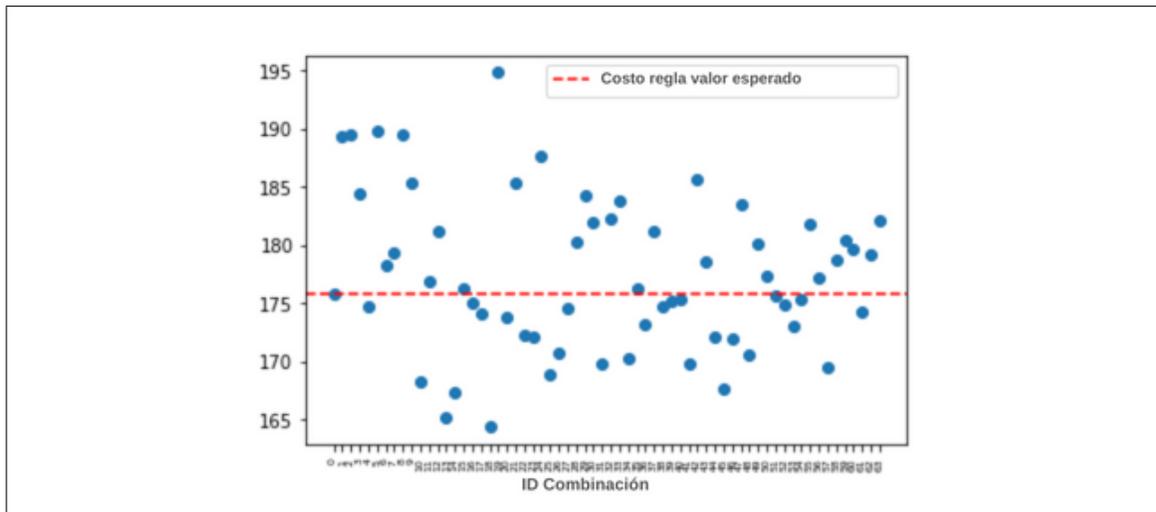


Figura D.6. Costos totales ponderados de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 1.

## D.2. Set 4

La figura D.7 presenta los costos de empuje para el experimento de prohibiciones para el Set 4.

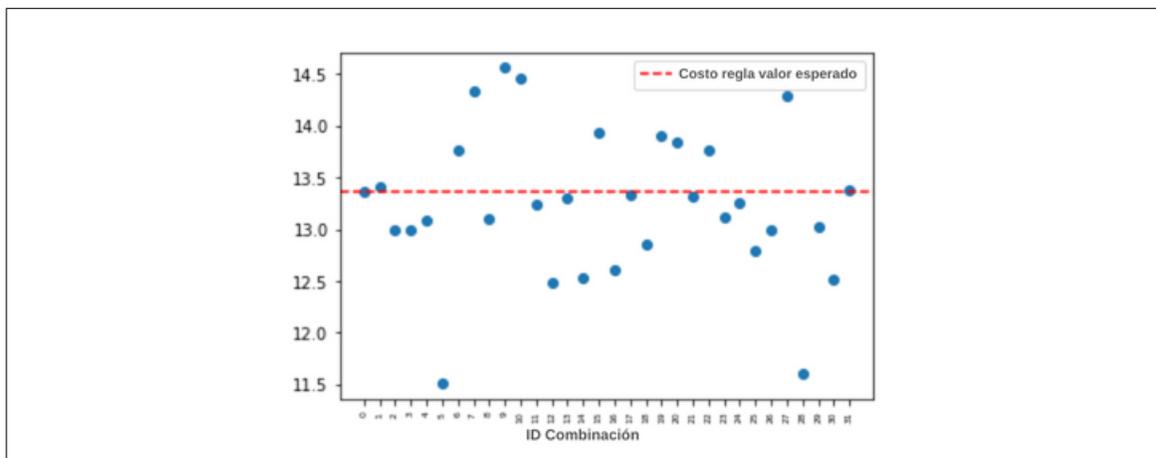


Figura D.7. Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 4.

La figura D.8 presenta los costos de inactividad para el experimento de prohibiciones para el Set 4.

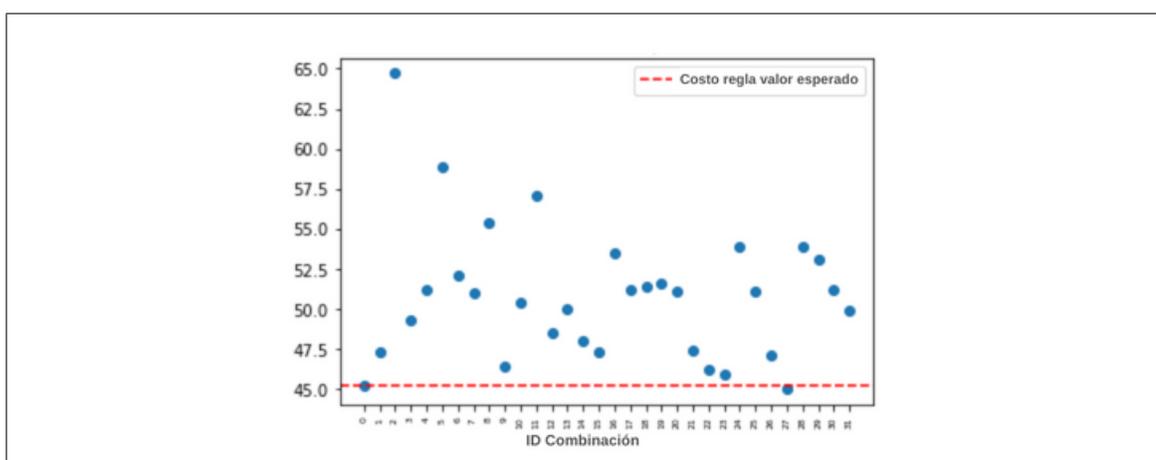


Figura D.8. Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 4.



La figura D.11 presenta los costos totales para el experimento de prohibiciones para el Set 4.

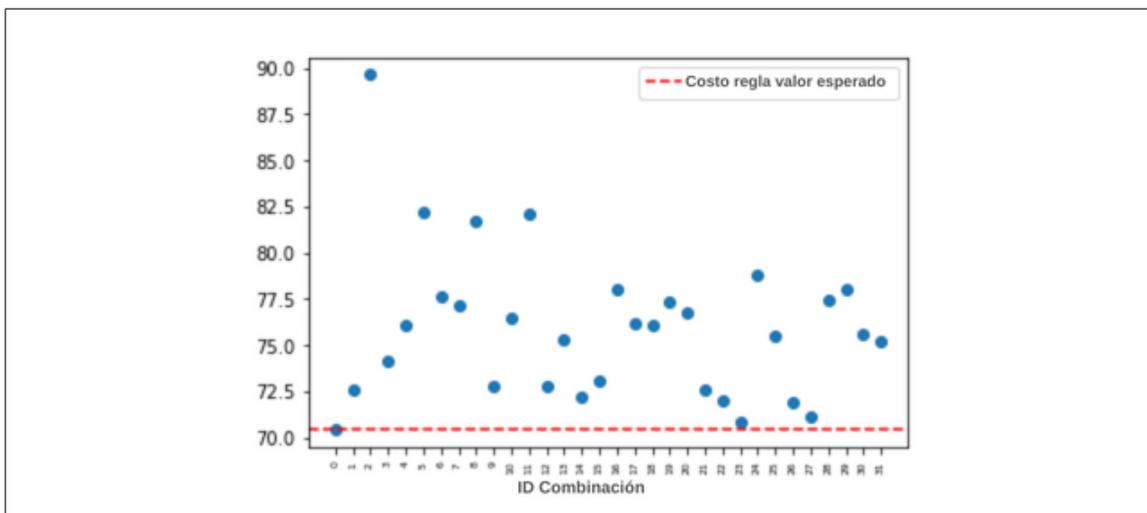


Figura D.11. Costos totales de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 4.

La figura D.12 presenta los costos totales ponderados para el experimento de prohibiciones para el Set 4.

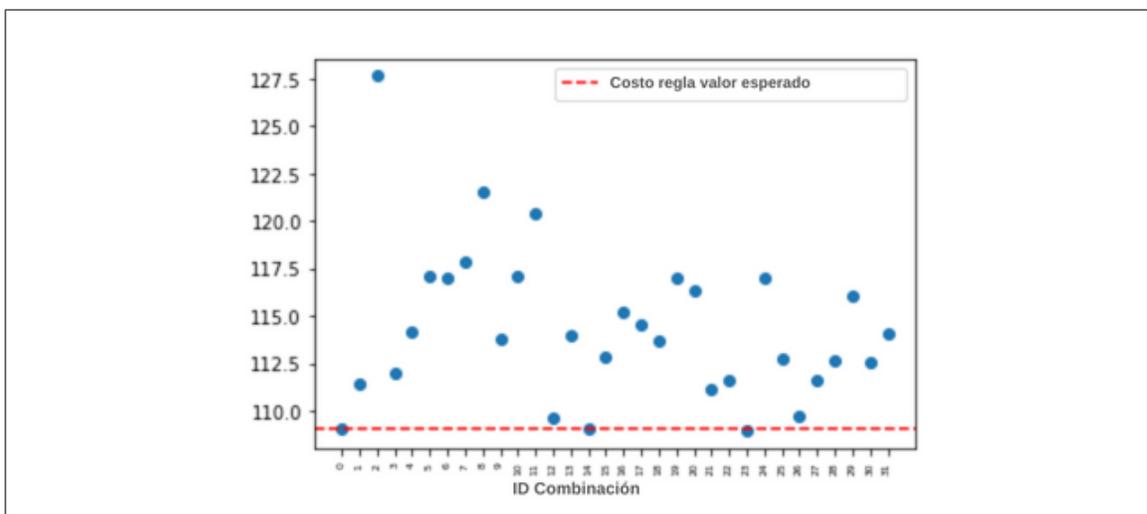


Figura D.12. Costos totales ponderados de pacientes con cáncer de alto requerimiento con *slots* PM prohibidos para Set 4.



La figura E.2 presenta los costos de inactividad para el experimento de *gaps* para el Set 1.

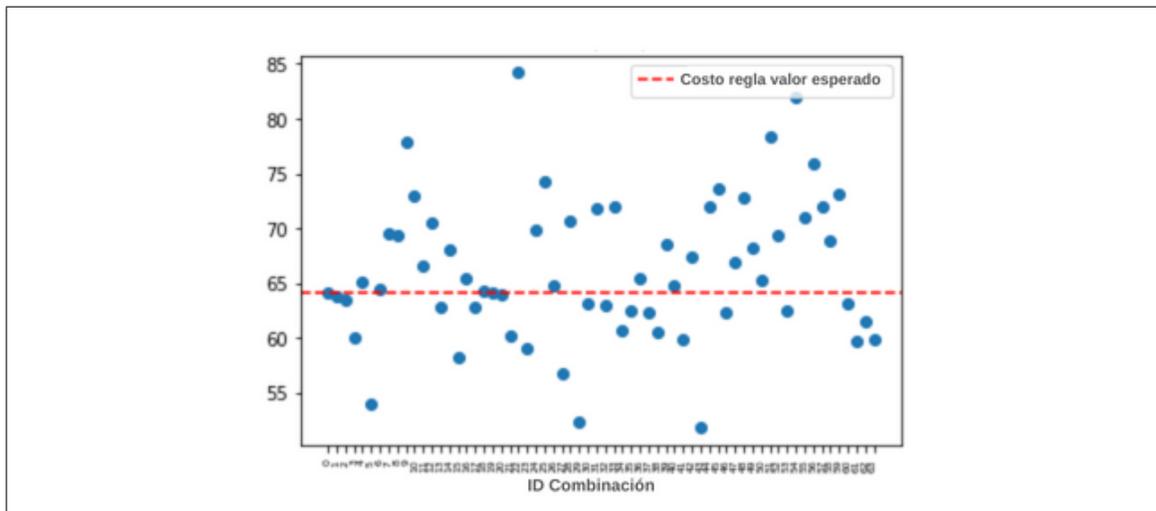


Figura E.2. Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con extra *gap* para Set 1.

La figura E.3 presenta los costos extra para el experimento de *gaps* para el Set 1.

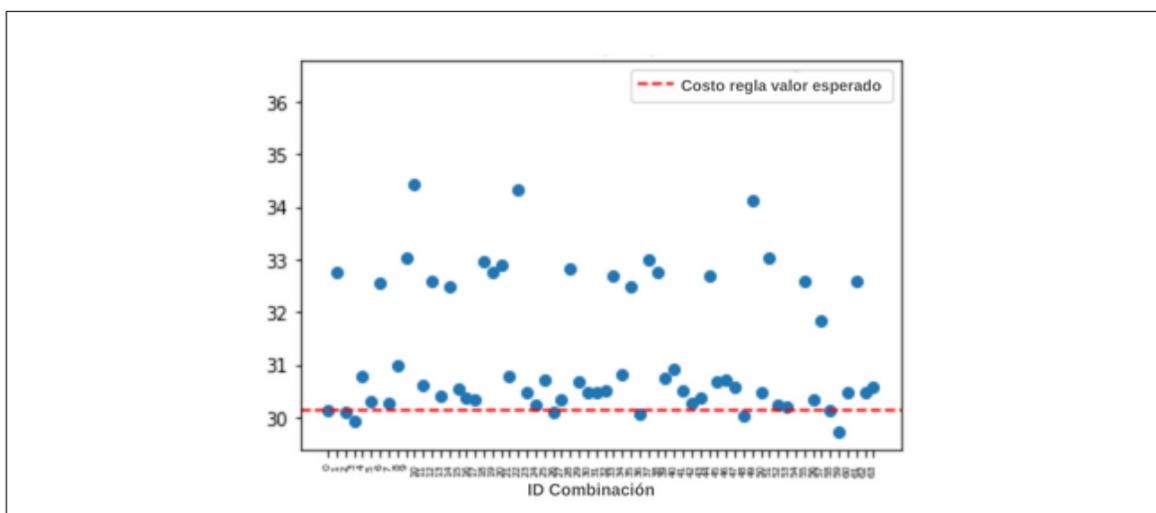


Figura E.3. Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con extra *gap* para Set 1.

La figura E.4 presenta los costos extra irregulares para el experimento de *gaps* para el Set 1.

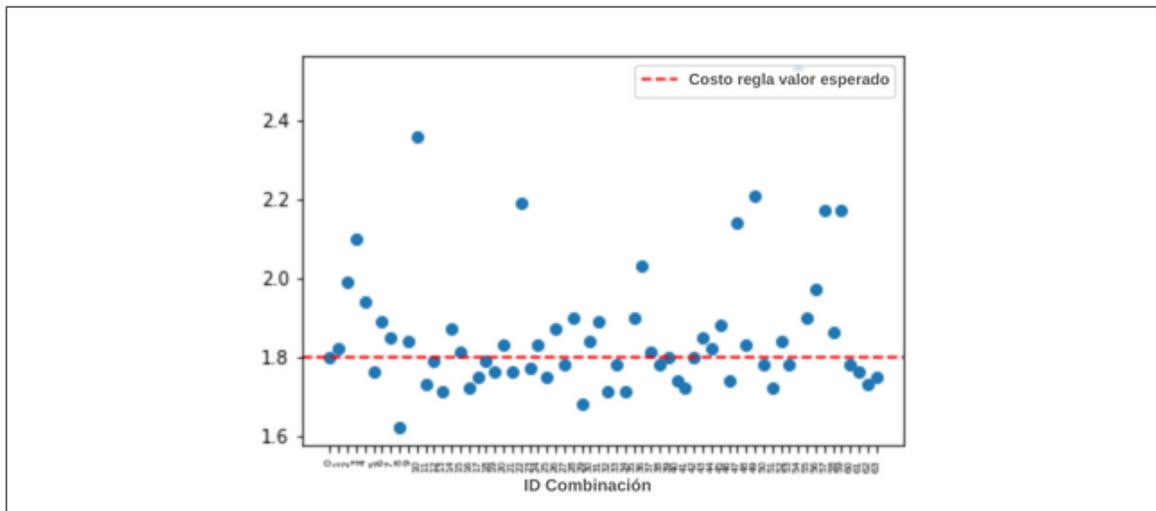


Figura E.4. Costos extra irregulares de pacientes con cáncer de alto requerimiento con extra *gap* para Set 1.

La figura E.5 presenta los costos totales para el experimento de *gaps* para el Set 1.

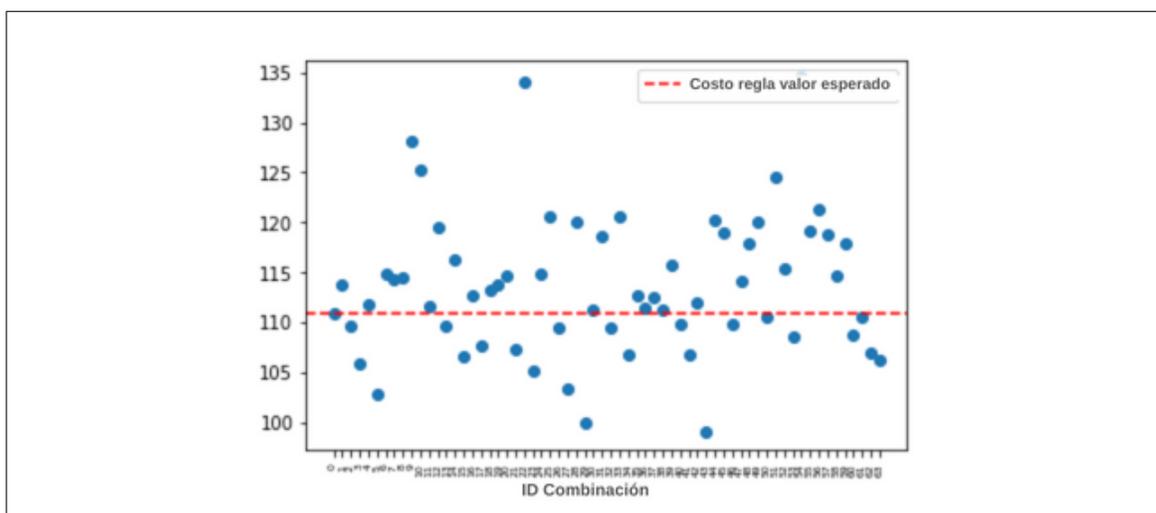


Figura E.5. Costos totales de pacientes con cáncer de alto requerimiento con extra *gap* para Set 1.

La figura E.6 presenta los costos totales ponderados para el experimento de *gaps* para el Set 1.

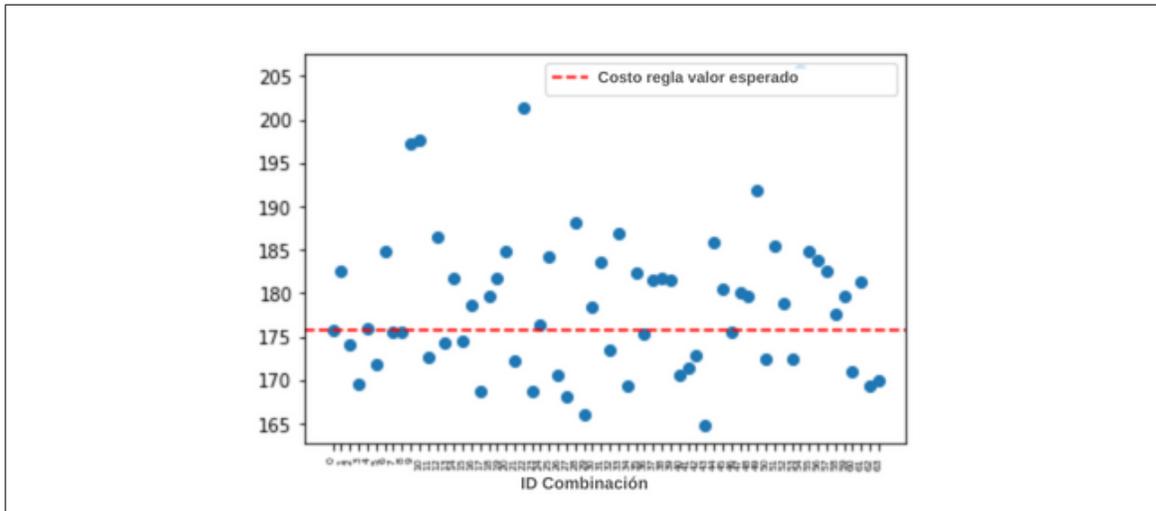


Figura E.6. Costos totales ponderados de pacientes con cáncer de alto requerimiento con extra *gap* para Set 1.

## E.2. Set 4

La figura E.7 presenta los costos de empuje para el experimento de *gaps* para el Set 4.

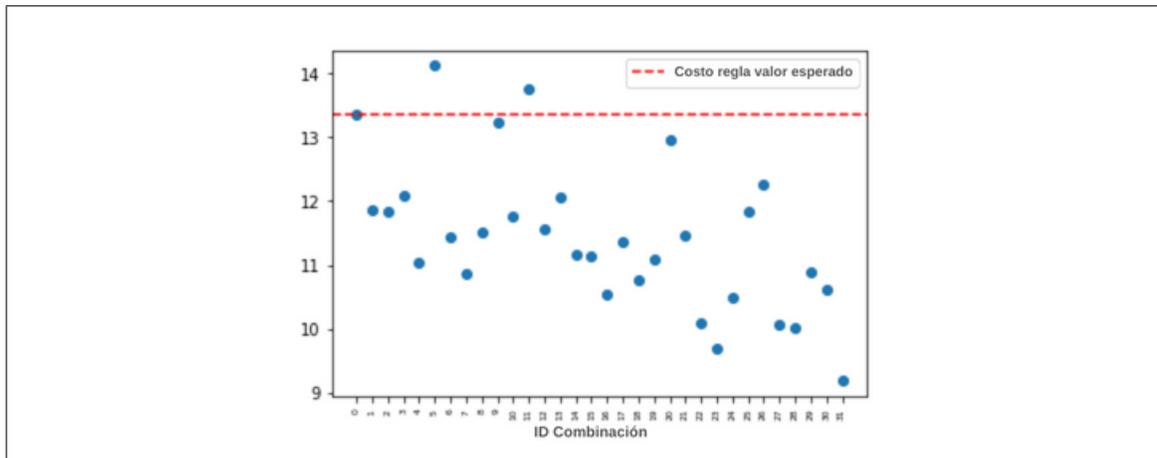


Figura E.7. Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con extra *gap* para Set 4.

La figura E.8 presenta los costos de inactividad para el experimento de *gaps* para el Set 4.

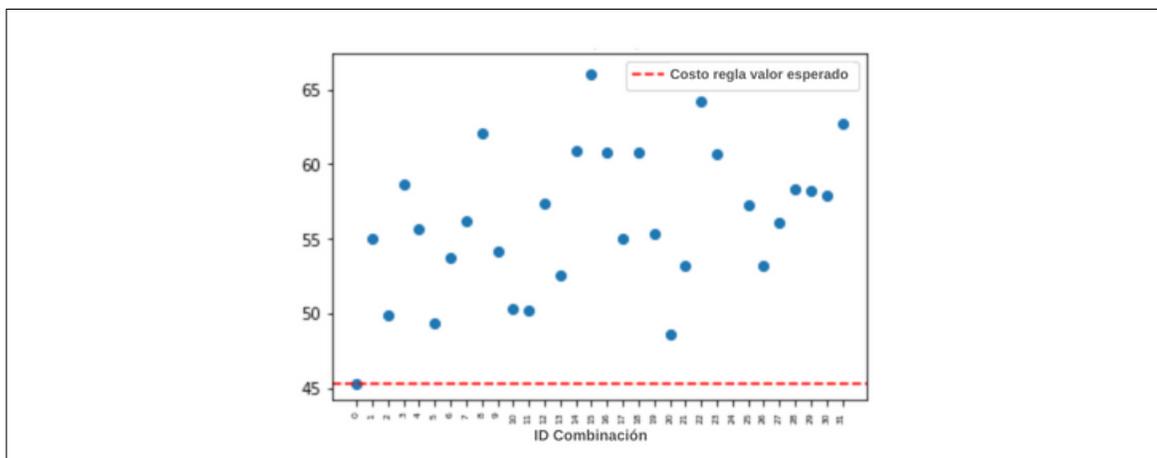


Figura E.8. Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con extra *gap* para Set 4.

La figura E.9 presenta los costos extra para el experimento de *gaps* para el Set 4.

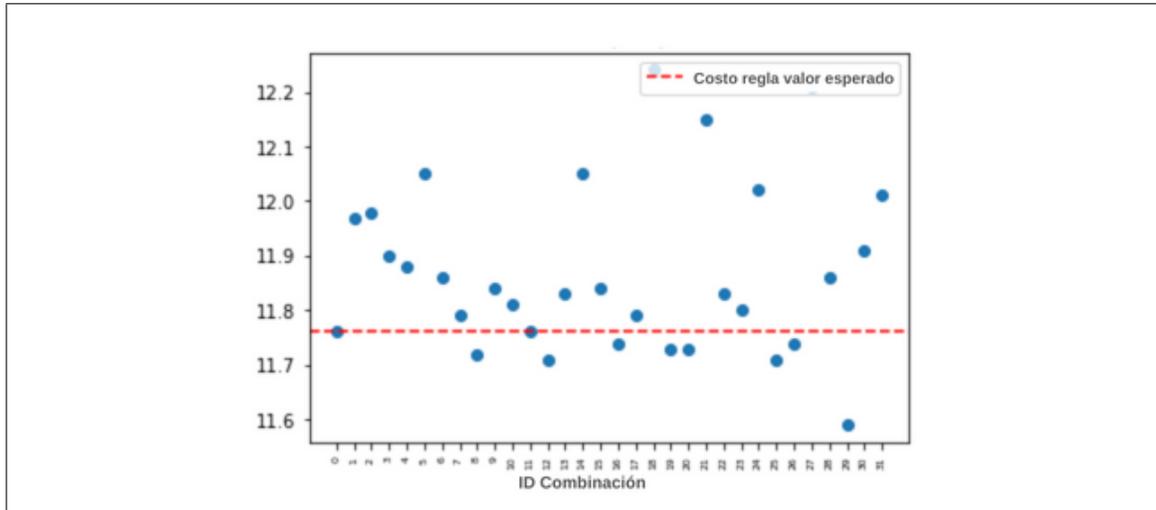


Figura E.9. Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con extra *gap* para Set 4.

La figura E.10 presenta los costos extra irregulares para el experimento de *gaps* para el Set 4.

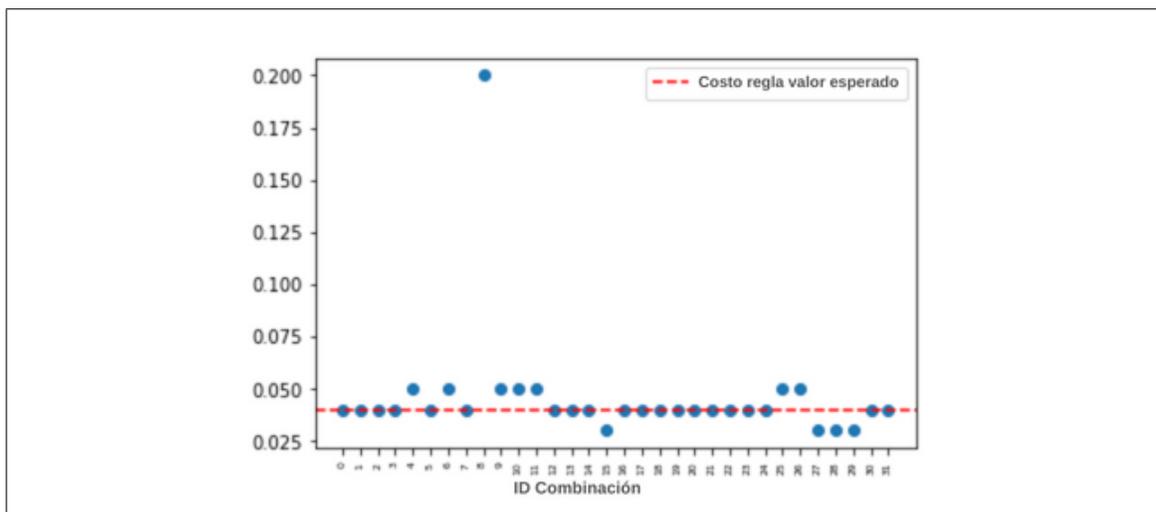


Figura E.10. Costos extra irregulares de pacientes con cáncer de alto requerimiento con extra *gap* para Set 4.

La figura E.11 presenta los costos totales para el experimento de *gaps* para el Set 4.

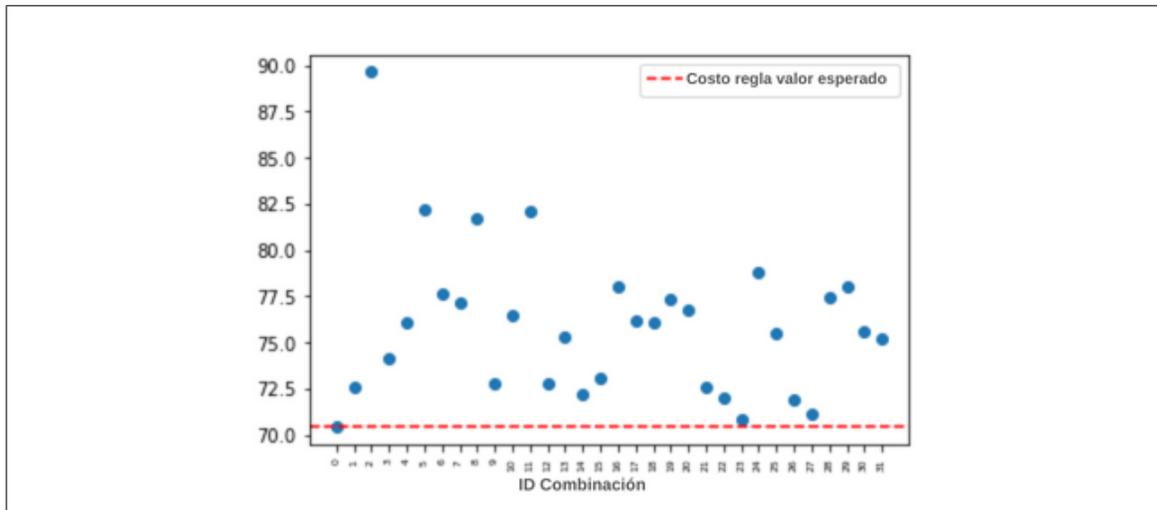


Figura E.11. Costos totales de pacientes con cáncer de alto requerimiento con extra *gap* para Set 4.

La figura E.12 presenta los costos totales ponderados para el experimento de *gaps* para el Set 4.

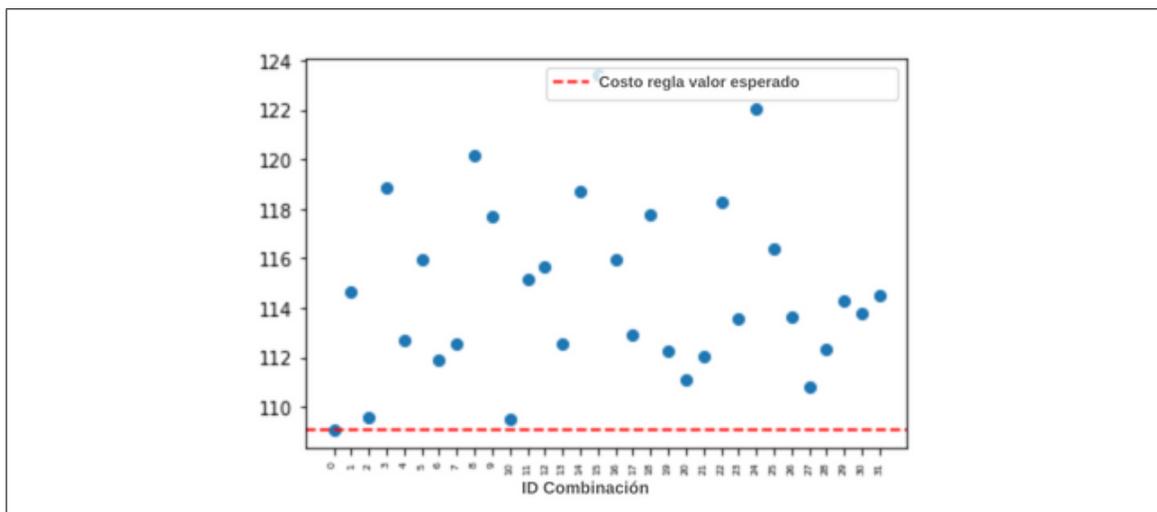


Figura E.12. Costos totales ponderados de pacientes con cáncer de alto requerimiento con extra *gap* para Set 4.

## F. MÉTRICAS DE EXPERIMENTO CONJUNTO HPM Y GAP

En este anexo se presentan las métricas de resultados promedio de 1000 simulaciones para cada combinación elegida con el experimento mixto de *gaps* y función objetivo APM (*High-PM*). Este experimento consiste en seleccionar un conjunto de pacientes dentro de los con mayores requerimientos a los que realizarles una asignación considerando dos *slots* extra por sobre su tiempo esperado de atención. Así, si un paciente tenía un valor esperado de 10 *slots* y fue escogido dentro del conjunto de combinaciones, se le asignará para 12 *slots*. Para mayor información de a qué hace referencia cada ID de combinación referirse al Anexo C. En este experimento además se modifica la función objetivo original del modelo determinístico, para dar paso a una que penaliza las asignaciones de los pacientes de mayores requerimientos si es que son asignados para partir su tratamiento durante la tarde.

### F.1. Set 1

La figura F.1 presenta los costos de empuje para el experimento de *gaps* y APM para el Set 1.

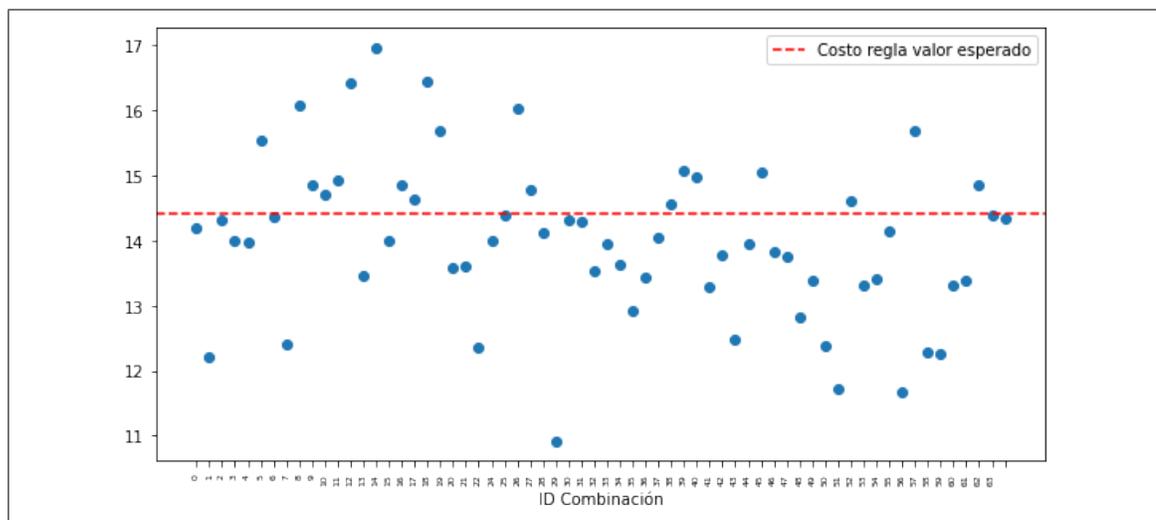


Figura F.1. Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 1.

La figura F.2 presenta los costos de inactividad para el experimento de *gaps* y APM para el Set 1.

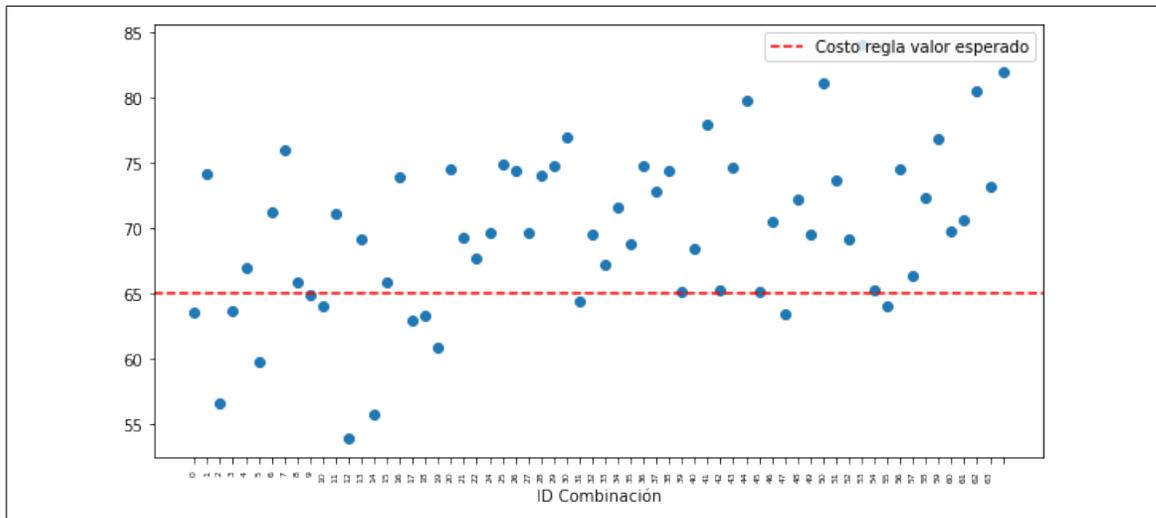


Figura F.2. Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 1.

La figura F.3 presenta los costos extra para el experimento de *gaps* y APM para el Set 1.

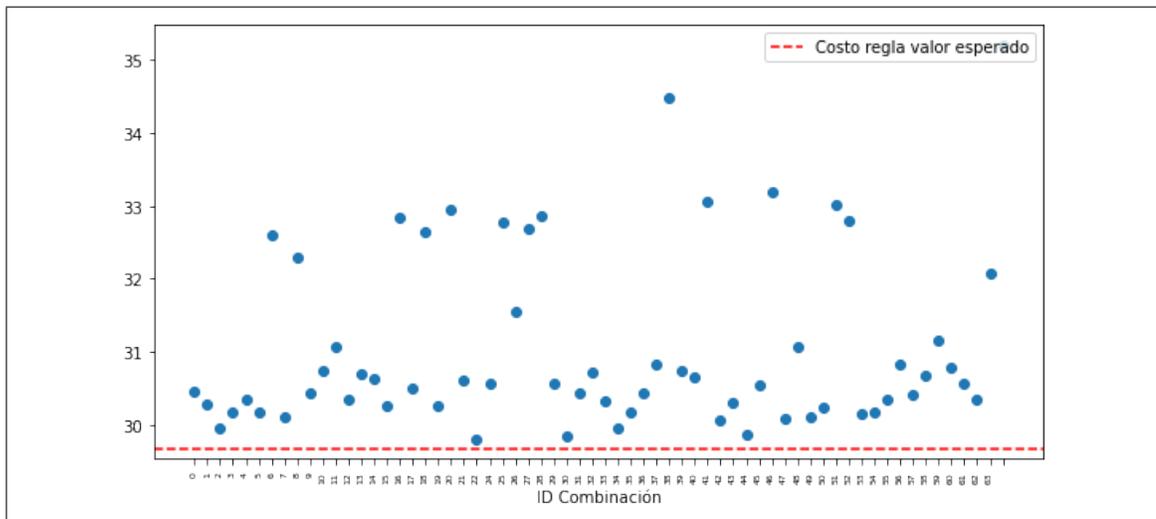


Figura F.3. Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 1.

La figura F.4 presenta los costos extra irregulares para el experimento de *gaps* y APM para el Set 1.

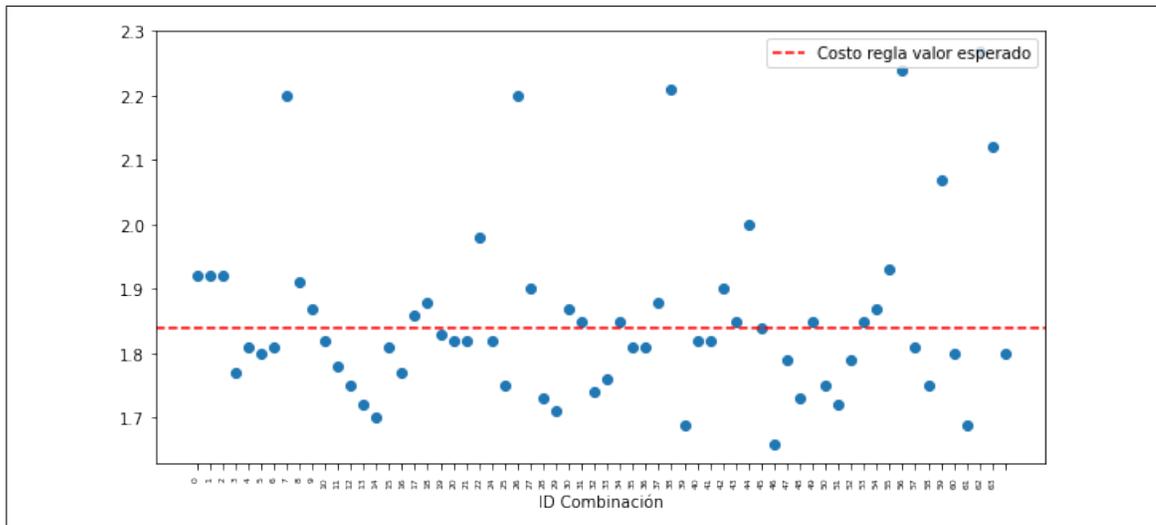


Figura F.4. Costos extra irregulares de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 1.

La figura F.5 presenta los costos totales para el experimento de *gaps* y APM para el Set 1.

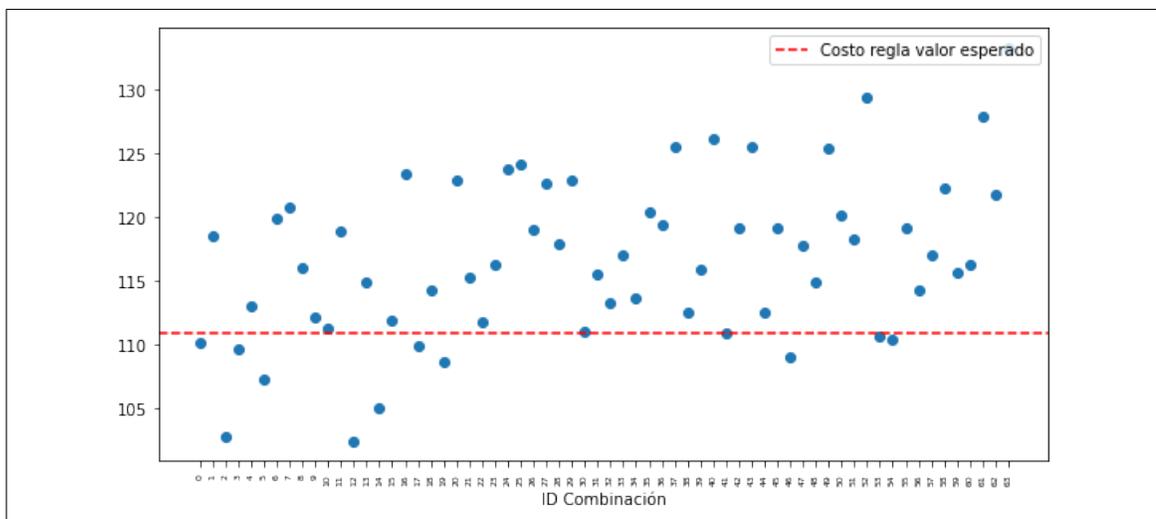


Figura F.5. Costos totales de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 1.

La figura F.6 presenta los costos totales ponderados para el experimento de *gaps* y APM para el Set 1.

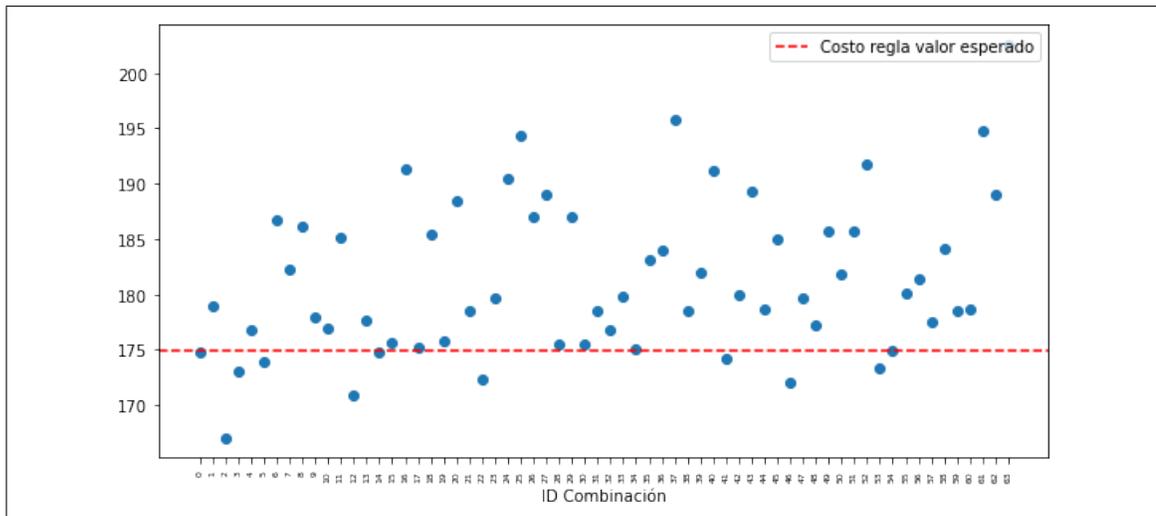


Figura F.6. Costos totales ponderados de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 1.

## F.2. Set 4

La figura F.7 presenta los costos de empuje para el experimento de *gaps* y APM para el Set 4.

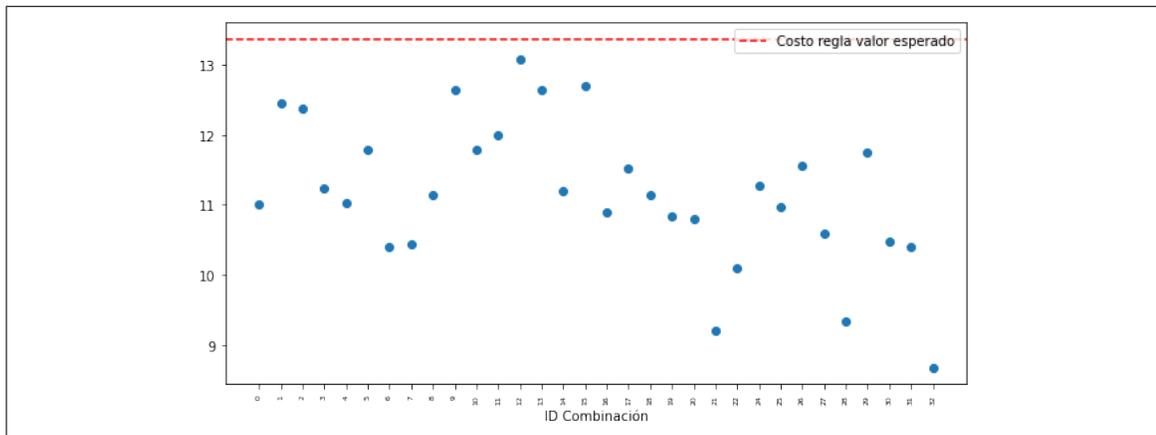


Figura F.7. Costos de empuje de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 4.

La figura F.8 presenta los costos de inactividad para el experimento de *gaps* y APM para el Set 4.

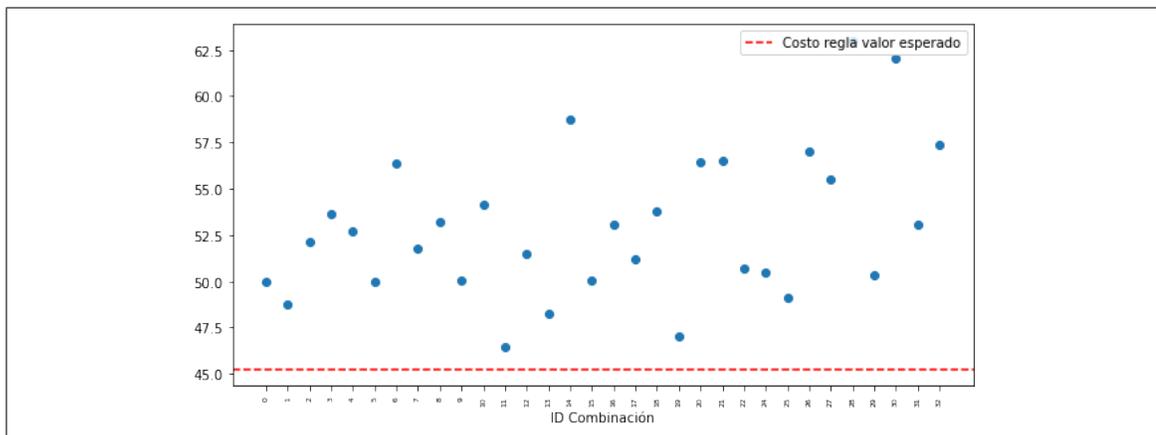


Figura F.8. Costos de inactividad de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 4.

La figura F.9 presenta los costos extra para el experimento de *gaps* y APM para el Set 4.

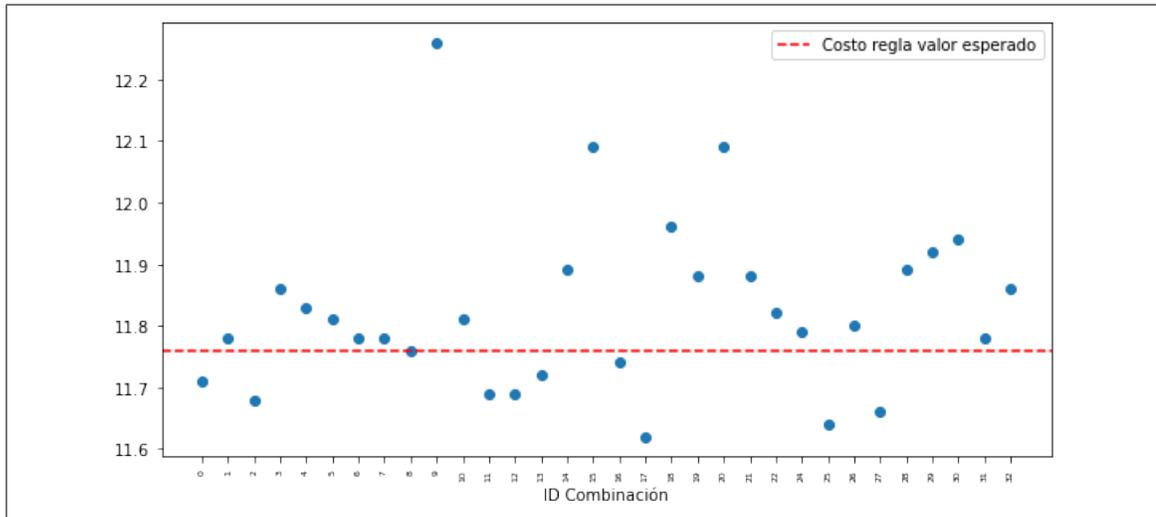
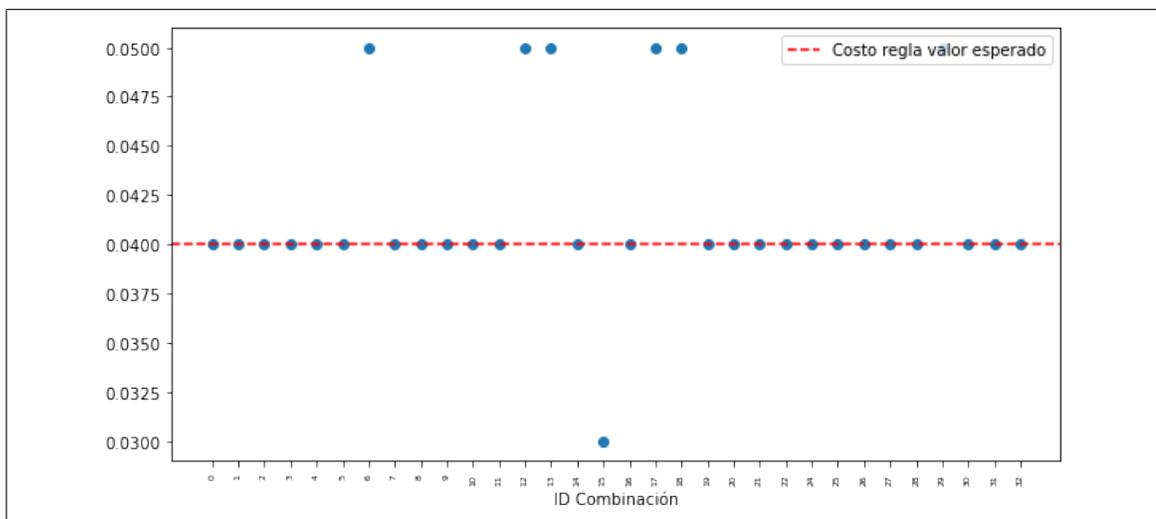


Figura F.9. Costos extra de conjuntos de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 4.

La figura F.10 presenta los costos extra irregulares para el experimento de *gaps* y APM para el Set 4.



La figura F.11 presenta los costos totales para el experimento de *gaps* y APM para el Set 4.

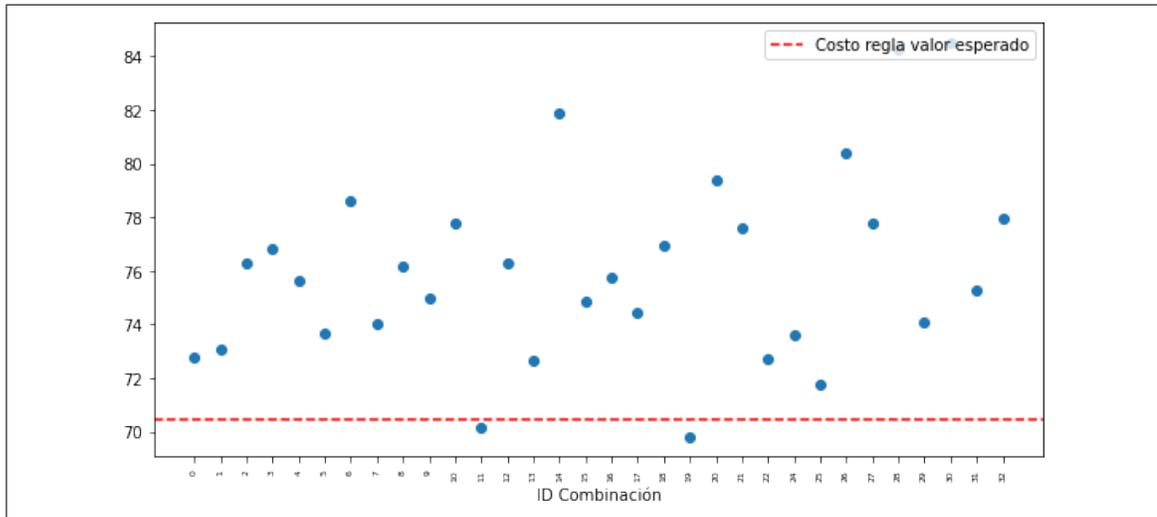


Figura F.11. Costos totales de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 4.

La figura F.12 presenta los costos totales ponderados para el experimento de *gaps* y APM para el Set 4.

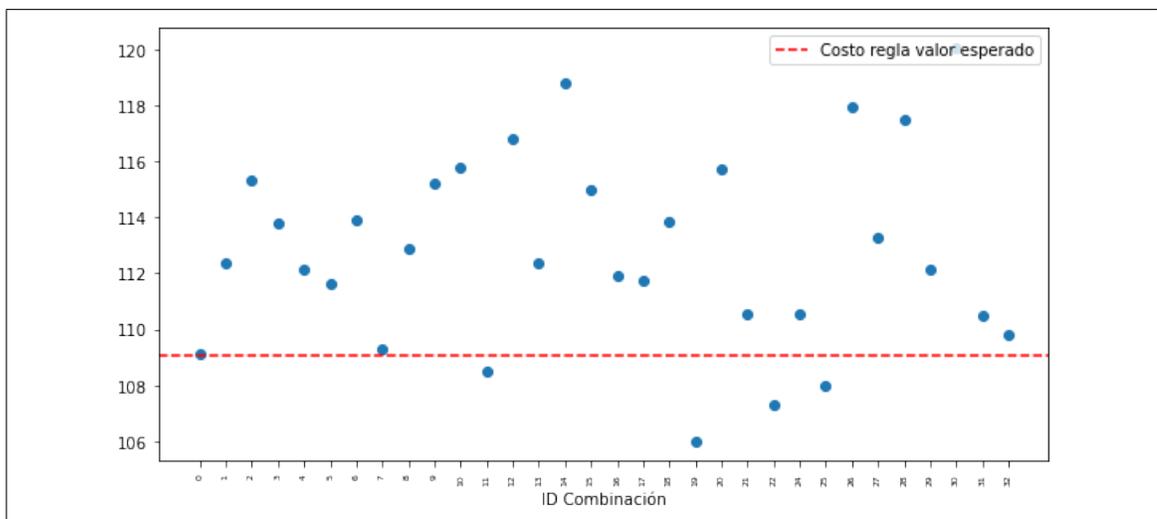


Figura F.12. Costos totales ponderados de pacientes con cáncer de alto requerimiento con regla APM y extra *gap* para Set 4.